

## ПАРАМЕТРИЧЕСКОЕ ИССЛЕДОВАНИЕ МОДЕЛЕЙ ОБНАРУЖЕНИЯ АНОМАЛИЙ ДЛЯ ВЫЯВЛЕНИЯ ДЕФЕКТОВ В ИНФРАКРАСНОЙ ТЕРМОГРАФИИ

© 2023 г. Г.Т. Весала<sup>1,\*</sup>, В. С. Гхали<sup>2</sup>, Ю. Нага Прашанти<sup>2,3</sup>, Б. Суреш<sup>2</sup>

<sup>1</sup>Университет Малларедди, Хайдарабад, Телангана, Индия-500004

<sup>2</sup>Образовательный фонд Конеру Лакшмайя, Ваддесварам, штат Андхра-Прадеш, Индия

<sup>3</sup>Институт инженерии и технологий им. Дханекулы, Гангуру, штат Андхра-Прадеш, Индия

E-mail: \*gopitilak7@gmail.com

Поступила в редакцию 22.07.2023; после доработки 15.08.2023

Принята к публикации 22.08.2023

В ходе революции NDT 4.0 машинное обучение и искусственный интеллект стали основными факторами, способствующими развитию неразрушающего контроля (НК) промышленных компонентов. Однако последние разработки в области активного теплового неразрушающего контроля (ТК) подтверждают его использование в качестве практического метода контроля целого ряда промышленных компонентов. Кроме того, в ходе последних исследований в области постобработки в ТК было разработано несколько моделей машинного обучения, позволяющих заменить взаимодействие с человеком и обеспечить автоматическое обнаружение дефектов. Но меньшая площадь дефектов и связанные с ними несколько тепловых профилей по сравнению с широкой зоной прозвучивания, приводящие к несбалансированности наборов данных, затрудняют обучение с учителем глубокой нейросети. Недавно в ТК были добавлены модели обнаружения аномалий и одноклассовые классификаторы, которые являются широко применяемыми моделями машинного обучения для решения реальных задач. Аккуратность и другие важные показатели при автономном обнаружении дефектов зависят от гиперпараметров этих моделей, таких как коэффициент загрязнения, объем обучающих данных и параметр инициализации соответствующей модели. В данной работе исследуется влияние параметров инициализации на возможности этих моделей в области ТК для автоматической дефектоскопии. С помощью метода отображения квадратичной частотно-модулированной тепловой волны (КЧМТВ) исследован образец полимера, армированного углеродным волокном, с искусственно созданными отверстиями различного размера на разной глубине. После качественного сравнения аккуратности, точности, полноты, F-меры и вероятности контроля был выбран хороший гиперпараметр для автоматической идентификации дефектов.

*Ключевые слова:* модели обнаружения аномалий, автоматическое обнаружение дефектов, выбор гипер-параметра, квадратичная частотно-модулированная тепловая волна и тепловой неразрушающий контроль.

## PARAMETRIC STUDY OF ANOMALY DETECTION MODELS FOR DEFECT DETECTION IN INFRARED THERMOGRAPHY

G.T. Vesala<sup>1,\*</sup>, V.S. Ghali<sup>2</sup>, Y. Naga Prasanthi<sup>2,3</sup>, B. Suresh<sup>2</sup>

<sup>1</sup>Mallareddy University, Hyderabad, Telangana, India-500004.

<sup>2</sup>Koneru Lakshmaiah Educational Foundation, Vaddeswaram, Andhra Pradesh, India.

<sup>3</sup>Dhanekula Institute of Engineering & Technology, Ganguru, A.P, India.

E-mail: \*gopitilak7@gmail.com

In the current NDT 4.0 revolution, machine learning and artificial intelligence have emerged as the major enablers for non-destructive testing and evaluation (NDT&E) of industrial components. However, recent developments in active thermal NDT (TNDT) support its use as a practical method for checking a range of industrial components. Additionally, recent post-processing research in TNDT has developed several machine learning models to replace human interaction and offer automatic defect detection. However, the smaller area of the flaws and their related few thermal profiles than the wide sound area, leading to imbalanced datasets, make it difficult to train a supervised deep neural. Recently added to TNDT are anomaly detection models and one-class classifiers, both of which are commonly applied machine learning models to real-world issues. The accuracy and other important metrics in autonomous defect detection are influenced by the hyper-parameters of these models, such as contamination factor, volume of training data, and initialization parameter of the relevant model. The current paper investigates how initialization parameters affect these models' TNDT capabilities for automated flaw detection. Using quadratic frequency modulated thermal wave imaging (QFMTWI), a carbon fiber-reinforced polymer specimen with variously sized artificially produced back-holes at different depths is examined. A good hyper-parameter for automatic flaw identification is chosen after qualitatively comparing testing accuracy, precision, recall, F-score, and probability.

*Keywords:* anomaly detection models, automatic defect detection, hyper-parameter selection, quadratic frequency modulated thermal wave imaging and thermal non-destructive testing.

DOI: 10.31857/S0130308223120023, EDN: XEZEIV

## ВВЕДЕНИЕ

Машинное обучение и искусственный интеллект стали основными направлениями современной революции в области неразрушающего контроля (NDE 4.0) для автоматизации задач обнаружения и определения характеристик дефектов в различных технологиях неразрушающего контроля [1]. С другой стороны, активный тепловой неразрушающий контроль (ТНК) на основе оптической стимуляции стал эффективным методом неразрушающего контроля для безопасного, дистанционного, бесконтактного контроля различных промышленных компонентов с возможностью проведения контроля в пределах всей поверхности [2]. С момента появления ТНК различные способы стимуляции развивались от высокой пиковой мощности до низкой пиковой мощности и от быстрой до длительной с помощью различных методов модуляции. Регистрируемые тепловые данные являются трехмерными (записываются в виде видеопоследовательности); они отображают информацию о дефекте всеми способами: одномерными временными тепловыми профилями, двухмерными термограммами и трехмерными пространственно-временными данными. В общем случае для получения признаков дефекта и его характеристик используются методы обработки пространственных или временных деталей тепловых данных [3]. Однако последние достижения в области постобработки для автоматизации этих процедур привели к появлению различных моделей машинного обучения (МО) и глубокого обучения (ГО) в ТНК [4]. Эти модели развивались для трех типов тепловых данных для автоматической идентификации дефектов, включая подходы обучения с учителем, без учителя, с частичным привлечением учителя [5—19].

В трехмерной перспективе глубокие признаки или структуры пространственной и временной информации в тепловых данных отдельно извлекаются и объединяются с помощью комбинации сверточных нейронных сетей (СНС) и долгой краткосрочной памяти (ДКП) [5] и только СНС [6] достичь уровня выявления дефектов. В первом случае, временные признаки извлекаются с помощью ДКП, а архитектура СНС U-net предоставляет глубокие признаки пространственной информации. Во втором случае используется псевдо3D внимательная нейросеть с использованием пространственно-временных сверток по главным компонентам, извлеченным из тепловой записи. Как и U-net, контроль дефектов было представлено в виде задач идентификации объектов и семантической сегментации объектов путем извлечения глубинных паттернов на термограммах с использованием подходов трансферного обучения [7—9]. Процедура идентификации объектов осуществляется с помощью региональных моделей СНС, таких как региональная СНС (P-СНС), быстрая P-СНС и сети «you only look once» (YOLO) [7], в то время как задача сегментации решается с помощью предварительно обученной архитектуры U-net [8]. Сочетание идентификации объекта через ограничительную рамку и сегментации объекта через P-СНС с построением масок в совокупности со стратегией обучения функции потерь представлено в [9]. Помимо автоматического обнаружения дефектов, для повышения эффективности обнаружения дефектов используются такие подходы к обучению на основе состязательности, как автокодирование и генеративные состязательные сети [10, 11].

Помимо таких многомерных форматов данных, в настоящей работе основное внимание уделяется одномерным временным тепловым профилям, на основе которых в ТНК было применено МО [12]. Однако в последнее время наблюдается развитие различных моделей МО и ГО в ТНК [13—19]. Хорошо известно, что признаки временных тепловых профилей одинаковы в бездефектных областях и различаются для дефектных областей в зависимости от параметров дефекта. Поэтому для корректного обучения МО- или ГО-моделей необходимо случайным образом выбирать соответствующие обучающие данные как из дефектных, так и из недефектных областей [13—15]. С другой стороны, в работах [16, 17] рассматривается проблема меньшего количества тепловых профилей дефектных областей, приводящая к несбалансированности классов данных для обучения, и применяются подходы, основанные на обучении с частичным привлечением учителя или взвешенной перекрестной энтропии потерь. Данная проблема дисбаланса классов подчеркивается, и задача обнаружения дефектов формулируется как задача обнаружения аномалий или одноклассовой классификации, где отрицательных или аномальных экземпляров очень мало по сравнению с положительными или нормальными данными. Поэтому для автоматического обнаружения дефектов вначале анализируются известные модели обнаружения аномалий (МОА), а затем их более глубокие версии путем обучения только на тепловых профилях недефектных участков [18, 19]. В отличие от моделей сквозного обучения, эти МОА зависят от параметров инициализации, таких как объем обучающих данных, фактор загрязнения и соответствующие параметры инициализации.

В данной работе проводится качественный анализ влияния параметров инициализации МОА для автоматического обнаружения дефектов. Исследование параметров проводится на образце полимера, армированного углеродным волокном (ПАУВ), с дефектами в виде отверстий с плоским дном различных размеров на разной глубине, контролируемых методом квадратичной частотно-модулированной тепловой волны (КЧМТВ). Такие качественные показатели, как количество выявленных дефектов, аккуратность тестирования или классификации, точность, полнота,  $F$ -мера и вероятность обнаружения дефектов, определяют оптимальные параметры инициализации для автоматического распознавания дефектов. Кроме того, еще одним преимуществом МОА является наличие в них коэффициента выброса, которые представляют собой дефекты, похожие на термограммы, при которых можно достичь соотношения сигнал/шум дефекта, что в большей степени подчеркивает возможности МОА по классификации дефектов.

Работа выстроена следующим образом: в разделе 2 обосновывается необходимость анализа параметров инициализации МАО. В разделе 3 представлены материалы, эксперименты и подробное описание тепловых характеристик, а в разделе 4 — результаты и их обсуждение. Наконец, в разделе 5 приводятся краткие выводы по работе.

### МОДЕЛИ ОБНАРУЖЕНИЯ АНОМАЛИЙ

В отличие от обычных задач компьютерного зрения, существует несколько приложений, в которых большинство данных остаются стандартными, а аномалии возникают в редких случаях. К таким случаям относятся обнаружение нововведений, мошеннических операций с кредитными картами, идентификация дефектных объектов, идентификация посторонних объектов и т.д. В общем случае модели МО страдают от нехватки данных, относящихся к классам, достаточным для обучения в таких случаях, и лучшей альтернативой для решения этой проблемы являются модели обнаружения аномалий (МАО) или одноклассовые классификаторы [20]. МАО способны выявлять редкие случаи или выбросы в данных путем обучения только на нескольких нормальных случаях.

В данном случае ТНК представляет собой механизм контроля широкой области, обеспечивающий получение пространственно-временных тепловых данных высокого разрешения, где временная информация на каждом пикселе соответствует тепловому отклику объекта контроля на заданный стимул. В большинстве случаев наблюдается, что большая часть временных тепловых профилей относится к бездефектным областям и лишь немногие из них приходятся на дефектные участки [16]. Кроме того, признаки тепловых профилей практически одинаковы в случае бездефектных областей, в то время как они изменяются в зависимости от параметров дефекта, таких как размер, глубина, тип и геометрическая ориентация. Эти две характеристики тепловых данных обуславливают формулировку задачи обнаружения дефектов как задачи обнаружения аномалий или одноклассовой классификации. Поэтому в наших предыдущих работах [18, 19] исследовалась возможность использования МАО для обнаружения дефектов, когда были рассмотрены и проанализированы известные МАО. В качестве МАО были выбраны одноклассовый метод опорных векторов (ОМОВ) [21], изолированный лес (ИЛ) [22] и локальный коэффициент выбросов (ЛКВ) [23], каждый из которых использует свою специфику для классификации аномальных случаев. Чтобы лучше понять их применимость для ТНК, читателям следует обратиться к [18].

Среди этих методов ОМОВ использует параметрический подход, аналогичный методу опорных векторов, ИЛ использует меры, основанные на расстоянии, а ЛКВ вычисляет отношение плотностей. Таким образом, производительность МАО зависит от параметров инициализации, таких как объем обучающих данных, фактор загрязнения и параметр инициализации. Во-первых, обучающие данные — это нормальный или положительный класс, в данном случае тепловые профили бездефектных участков. Коэффициент загрязнения — общий для всех МАО параметр инициализации, который представляет собой ожидаемое соотношение выбросов, наблюдаемых на практике, и отвечает за формирование порога для классификации аномальных и нормальных случаев. Наконец, параметры инициализации различны для каждого из этих МАО. В ОМОВ для эффективного построения гиперплоскости [21] требуется параметр, похожий на дисперсию, как часть ядра, выбранного для построения гиперплоскости. В ИЛ требуется случайное число, чтобы метод извлекал случайные признаки и вычислял среднюю длину пути для выявления аномалий [22]. С другой стороны, в ЛКВ требуется число «MinPts» — количество ближайших соседей, с которыми вычисляется локальная плотность достижимости, дающая локальный коэффициент выброса [23]. Таким образом, эти параметры играют ключевую роль в обеспечении баланса между эффективностью классификации аномалий и показателями производительности. В данной работе рассматривается оптимальный выбор этих параметров для обнаружения дефектов в ТНК в зависимости от целей

обнаружения дефектов, показателей производительности и ограничений по надежности.

Метрики производительности, которые рассматриваются для получения оптимальных параметров инициализации: для оценки производительности по следующим метрикам берутся предварительно заданные метки:

$$\begin{aligned}
 \text{Аккуратность} &= \frac{\text{ИП} + \text{ИО}}{\text{ИП} + \text{ЛП} + \text{ЛО} + \text{ИО}}; \\
 \text{Точность} &= \frac{\text{ИП}}{\text{ИП} + \text{ЛП}}; \\
 \text{Полнота или ДИПК} &= \frac{\text{ИП}}{\text{ИП} + \text{ЛО}}; \\
 F\text{-мера} &= \frac{(2 \times \text{Точность} \times \text{Полнота})}{(\text{Точность} + \text{Полнота})}; \\
 \text{ДЛПК} &= \frac{\text{ИП}}{\text{ИП} + \text{ЛО}},
 \end{aligned} \tag{1}$$

где ИП — количество пиксельных профилей, правильно предсказанных как дефектные; ИО — количество пиксельных профилей, идеально предсказанных как недефектные. Аналогично, ЛП — количество профилей пикселей недефектного класса, предсказанных как дефектные; а ЛО — количество профилей пикселей дефектного класса, предсказанных как недефектные. Первая метрика — это аккуратность тестирования, которая выражается отношением истинных прогнозов к общему числу прогнозов, взятому в процентах. В отличие от глобального характера аккуратности, точность, полнота и F-мера являются локальными показателями для каждого класса данных, представляющими собой количество истинных предсказаний и ложных срабатываний. F-мера представляет собой сбалансированное арифметическое отношение точности и полноты, которое широко используется для классификации несбалансированных по классам данных [18]. Наконец, Доля ложных положительных классификаций (ДЛПК) — это мера, рассматриваемая для анализа надежности, которая, с другой стороны, рассматривается как вероятность обнаружения дефекта (ВОД) [19]. Здесь ИП дает количество пикселей, присутствующих в дефекте на образце, идентифицированном моделью, а ЛО — количество пикселей в области дефекта, которые модель не может предсказать. ВОД гораздо более локален и дает отношение истинных предсказаний на каждом уровне дефекта, построенное в зависимости от соотношения сторон (диаметр/глубина). Однако пороговым значением для признания модели ГО надежной считается доверительная оценка 75 %. Опять же, квадратная граница, определенная в ходе процедуры маркировки, помогает вычислить ВОД для каждого дефекта.

## ПЛАНИРОВАНИЕ ЭКСПЕРИМЕНТА И ПОДГОТОВКА ДАННЫХ

Материалы и планирование эксперимента. Важной задачей является обнаружение дефектов меньших размеров на больших глубинах, а также анализ и выбор оптимальных параметров для новых методов обработки данных. Поэтому для анализа изменения параметров инициализации МАО при распознавании мелких и крупных дефектов выбраны образцы из углепластика с искусственно просверленными плоскими донными отверстиями разных размеров на разной глубине. Схема конструкции образца представлена на рис. 1а. Лицевая поверхность образца покрыта черной краской с излучательной способностью 0,95 для получения равномерной излучательной способности по всей поверхности [18].

Передняя поверхность образца освещается оптическим импульсом мощностью 2 кВт с квадратичной частотной модуляцией в диапазоне от 0,01 до 0,1 Гц в течение 100 с с помощью набора галогенных ламп пиковой мощностью 1 кВт каждая [18]. Для исключения фазы охлаждения во время эксперимента к возбуждению добавляется смещение по постоянному току. Соответствующий тепловой отклик регистрируется тепловизором FLIRSC655A, работающим в спектральном диапазоне от 7,5 до 14 мкм с погрешностью  $\pm 2$  °С или  $\pm 2$  % от показаний и эквивалентной шуму разностью температур (ЭШРТ) или чувствительностью 30 мк при частоте 6,25 кадра в секунду при полном разрешении 640x480 пикселей. Экспериментальная установка ТНК, размещенная в центре инфракрасной диагностики KLEF, показана на рис. 1б.

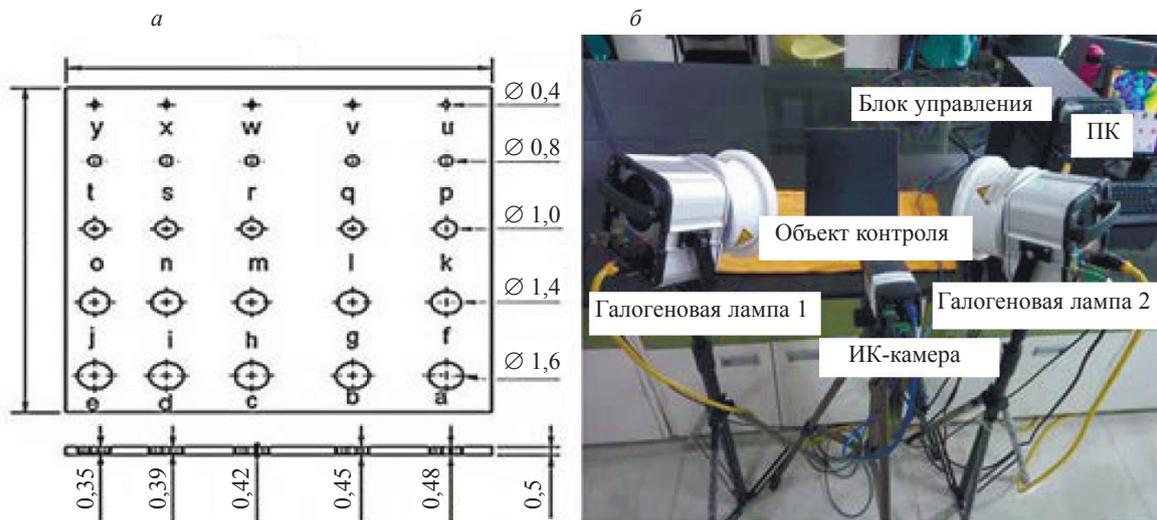


Рис. 1. Схематическое изображение образца (а) (размеры в см) и экспериментальная установка ТНК (б).

**Предобработка данных и их обработка.** Эффективный исходный тепловой отклик образца без фона определяется операцией кадрирования. Эффективная исходная тепловая характеристика только испытуемого образца состоит из 625 тепловых кубов с разрешением  $315 \times 317$  пикселей. Исходный тепловой отклик состоит из статической и динамической составляющих, где статическая составляющая — это среднее повышение температуры, а динамическая составляющая — реальный тепловой отклик. Таким образом, статическая составляющая во временной тепловой картине каждого пикселя в поле зрения устраняется, а среднее значение удаляется с помощью соответствующей процедуры подгонки полинома [18]. Полученный тепловой профиль снова переставляется в соответствующее местоположение пикселя для создания предварительно обработанного теплового куба. Далее линейно подогнанный куб термограмм сопоставляется с истинными метками для проверки предложенной методики.

Поскольку задача формулируется как задача обнаружения аномалий, каждому пикселю присваиваются положительные и отрицательные метки. Тепловые профили в области дефекта связываются с отрицательным классом (-1), а бездефектная область маркируется как положительный класс (+1), что показано на рис. 2а. Эта карта меток добавляется к тепловым данным, подготовленным выше, и далее из них извлекаются обучающие данные. Карта меток состоит из 99855 ( $315 \times 317$ ) пиксельных профилей, из которых 6045 принадлежат области дефектов, а 93810 покрывают область без дефектов. На рис. 2б представлен случайный выбор из тепловых данных

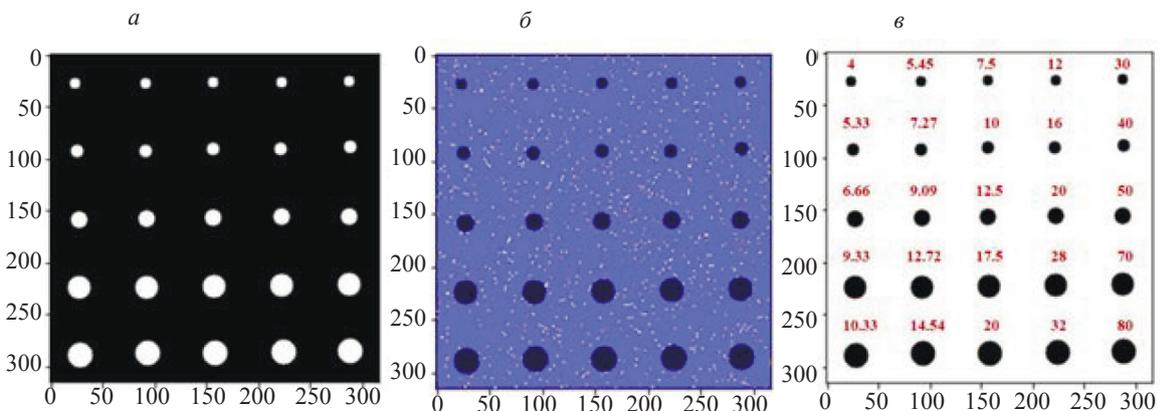


Рис. 2. Эталонные данные (а); случайная выборка обучающих данных из тепловых данных (б); соотношение сторон каждого дефекта (в).

тепловых профилей бездефектных областей, которые покрывают ближайшие участки дефектных областей, для лучшего понимания MAO. Обучающие данные, взятые из бездефектной области, подаются в MAO в виде двумерного вектора, представляющего собой тепловой профиль в каждой строке. Аналогичным образом данные тестирования теплового отклика всего образца преобразуются в двумерный вектор и подаются в MAO в процессе тестирования. В результате тестирования для каждого теплового профиля получаются результаты классификации в виде одномерного вектора, который далее преобразуется в реальное измерение термограммы и визуализируется в виде карты дефектов. Наконец, на рис. 2*в* представлены соотношения сторон всех дефектов, которые представляют собой отношение диаметра дефекта к его глубине для анализа ВОД, как показано в уравнении (1).

### ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Сначала варьируются обучающие данные путем изменения количества случайно выбранных тепловых профилей бездефектных областей от 500 до 8000 (500, 1к, 2к, 4к, 6к и 8к), при этом остальные параметры остаются неизменными. Коэффициент загрязнения остался равным 0,2, а параметры ядра, случайного зерна и «MinPts» для ОМОВ, ИЛ и ЛКВ выбраны равными 0,0001, 42 и 80 соответственно. Метрики эффективности, приведенные в уравнении (1), позволяют лучше понять влияние каждого параметра инициализации на обнаружение дефектов, что проиллюстрировано на рис. 3. Первоначально наблюдение за картами дефектов показало, что в них имеются незначительные различия, но количество обнаруженных дефектов остается неизменным для ОМОВ и ИЛ. ОМОВ не смог обнаружить шесть дефектов в левой верхней части, которые имеют небольшой размер и лежат на глубинах от средних до больших. С другой стороны, ИЛ незначительно превзошел ОМОВ, обнаружив на один дефект больше при 1 тыс. обучающих данных. Однако, как видно из рис. 3*а* и *б*, показатели эффективности для этих двух случаев остаются в основном неизменными или незначительно изменяются.

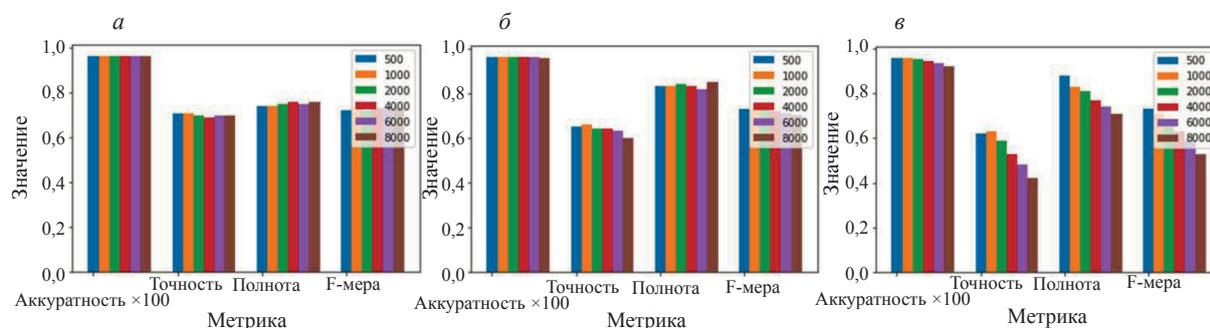


Рис. 3. Оценка эффективности моделей анализа аномалий при варьировании данных для обучения: ОМОВ (*а*); ИЛ (*б*); ЛКВ (*в*).

Значения ВОД для всех дефектов для каждого случая трех MAO рассчитаны и представлены на рис. 4 в виде графиков. В каждой ячейке представлены значения ВОД для всех 25 дефектов в каждом случае с соответствующими медианой, верхней и нижней границами. Из рисунка видно, что для ОМОВ и ИЛ значения ВОД не меняются в зависимости от обучающих данных. С другой стороны, для ВОД наблюдались изменения в показателях эффективности, поскольку при увеличении объема обучающих данных были исследованы почти все дефекты, что привело к компромиссу в отношении ошибочных классификаций. Это еще больше усиливает метрики производительности, наблюдаемые на рис. 3*в*. Это объясняется относительным эффектом ЛКВ по отношению к соседним элементам; с увеличением количества данных увеличивается количество ближайших элементов, что приводит к ошибкам классификации и, соответственно, к падению аккуратности, точности, полноты и ВОД, как видно на рис. 3*в* и 4*в*, соответственно. Аналогично, наблюдая медиану ВОД на рис. 4, можно сделать вывод, что медиана уменьшается, а верхняя и нижняя границы ВОД напоминают увеличение числа ложных срабатываний.

Во-вторых, коэффициент загрязнения изменяется от 0,05 до 0,3 с шагом 0,05 в каждом цикле, при этом остальные параметры остаются неизменными. В качестве обучающих данных использу-

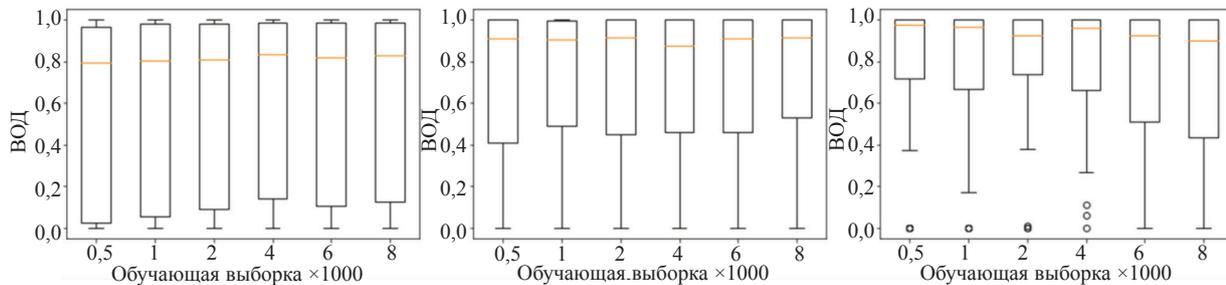


Рис. 4. Анализ ВОД для разных МАО при варьировании данными обучения: ОМОВ (а); ИЛ (б); ЛКВ (в).

ются 1к тепловых профилей, а параметры инициализации соответствующих МАО остаются такими же, как и ранее. Предварительное наблюдение за картами дефектов показывает, что при увеличении коэффициента загрязнения в каждой МАО наблюдается увеличение количества выявленных дефектов. Количество выявленных дефектов при увеличении коэффициента загрязнения выглядит следующим образом: ОМОВ обнаруживает от 16 до 19 дефектов, ИЛ — от 16 до 20 дефектов, а ЛКВ — от 19 до 23 дефектов при изменении коэффициента загрязнения от 0,05 до 0,3. Однако увеличение числа обнаруженных дефектов привело к незначительному снижению аккуратности и точности, но к увеличению полноты и F-меры, как видно из рис. 5. Это свидетельствует о благоприятных показателях МАО при изменении коэффициента загрязнения.

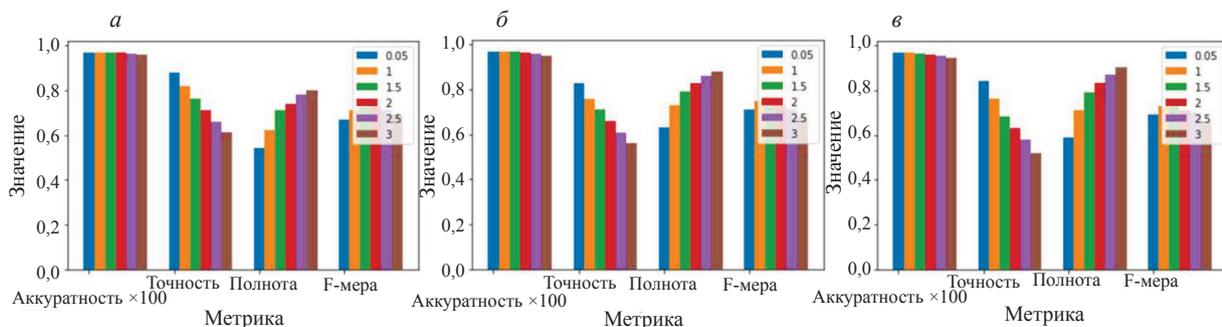


Рис. 5. Оценка эффективности моделей анализа аномалий при варьировании коэффициента загрязнения: ОМОВ (а); ИЛ (б); ЛКВ (в).

Дальнейшее рассмотрение ВОД на рис. 6 показывает, что ВОД для дефектов увеличивается при повышении коэффициента выбросов, так как медианные значения пересекают пороговый уровень (75) для всех случаев после 0,2. Комбинированный анализ метрик эффективности показывает, что увеличение коэффициента загрязнения приводит к снижению точности, но, с другой стороны, увеличивает полноту и F-меру по мере увеличения количества обнаруженных дефектов и обеспечивает лучшую ВОД для всех обнаруженных дефектов. Однако на картах дефектов видно, что увеличение коэффициента загрязнения приводит к снижению порога обнаружения, что приводит к ошибочной классификации бездефектных участков на границах дефектов и на границах образцов как дефектных. Поэтому оптимальный коэффициент загрязнения 0,2 выбирается путем компромисса между возможным максимальным количеством обнаруженных дефектов и меньшим количеством ошибочных классификаций.

Наконец, варьируется отдельный инициализатор трех МАО и анализируется эффективность, при этом количество обучающих данных и коэффициент загрязнения составляют 1000 и 0,2 соответственно. Параметр ядра для ОМОВ изменяется от 0,1 до 0,000001, случайное зерно для ИЛ и «MinPts» для ЛКВ изменяются от 10 до 100 (10, 20, 40, 60, 80 и 100). Соответствующие параметры эффективности и надежности представлены на рис. 7 и 8 соответственно. В первую очередь наблюдение за картами дефектов показывает, что случайное зерно ИЛ характеризуется небольшим

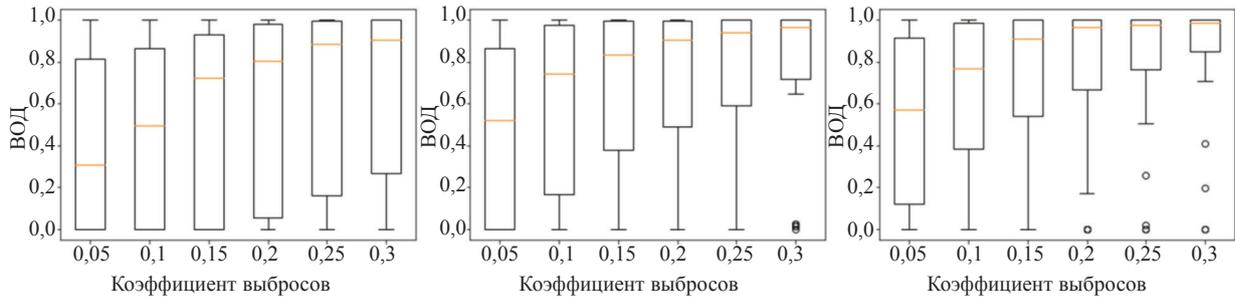


Рис. 6. Анализ ВОД для разных MAO при варьировании коэффициента загрязнения: ОМОВ (а); ИЛ (б); ЛКВ (в).

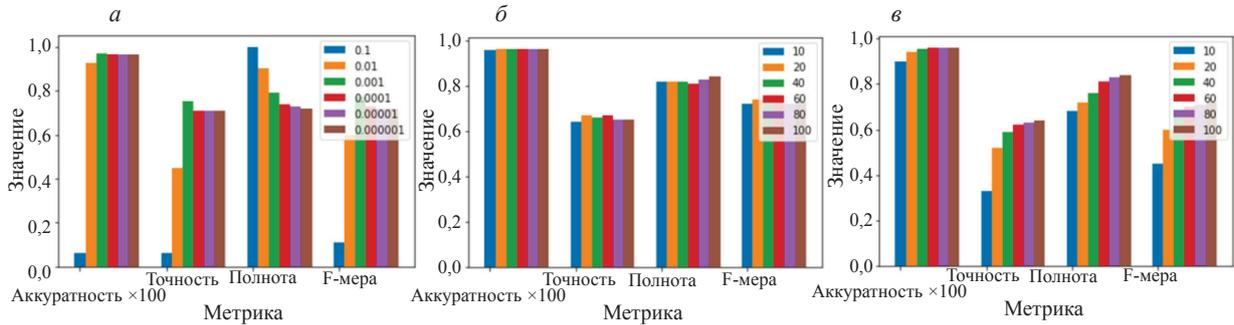


Рис. 7. Оценка эффективности моделей анализа аномалий при варьировании инициализатора для ОМОВ (а); ИЛ (б); ЛКВ (в).

разбросом при обнаружении дефектов, где количество обнаруженных дефектов варьируется в пределах 19-20. Это подтверждается и показателями эффективности и ВОД, представленными на рис. 7б и 8б соответственно. Таким образом, очевидно, что случайное зерно не оказывает существенного влияния на производительность ИЛ.

С другой стороны, параметр ядра существенно влияет на функцию принятия решения ОМОВ, так как при меньших значениях на данные в многомерном пространстве накладываются жесткие замкнутые поверхности, а при больших значениях — свободные [21]. Жесткая оболочка позволяет выделить большую часть данных, в то время как свободная оболочка представляет все данные как единый набор. Таким образом, карты дефектов показывают отсутствие тепловых профилей областей дефектов для самого высокого параметра ядра (0,1), что видно из метрик производительности и ВОД-графиков на рис. 7а и 8а соответственно. Однако можно заметить, что при дальнейшем уменьшении значения параметра ядра значение полноты и медиана ВОД уменьшаются с ростом числа обнаруженных дефектов. Поэтому для сравнительного исследования, представленного в дальнейшей части, выбрано промежуточное значение 0,0001, позволяющее обнаружить 19 дефектов с приемлемым медианным значением ВОД.

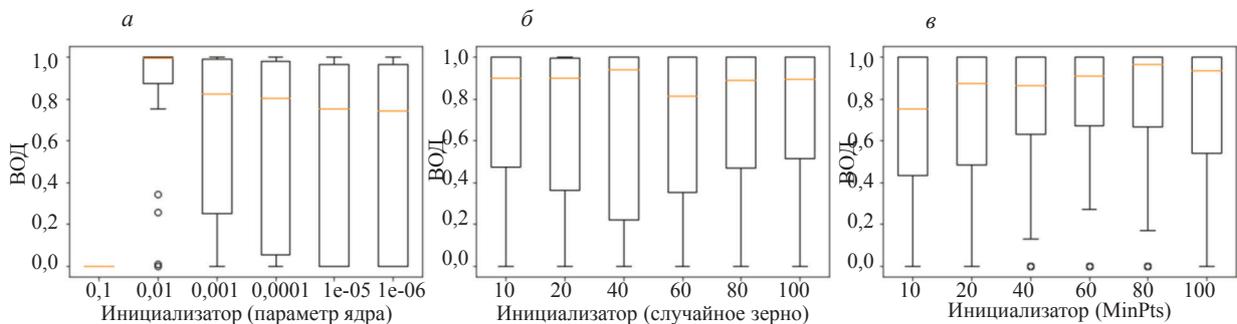


Рис. 8. Анализ ВОД для разных MAO при варьировании инициализатора для ОМОВ (а); ИЛ (б); ЛКВ (в).

В случае ЛКВ первоначально было выбрано значение MinPts, равное 10, поскольку оно является нижней границей для устранения нежелательных статистических флуктуаций и может быть увеличено до достижения оптимального значения [23]. При первичном наблюдении карт дефектов видно, что при меньших значениях 'MinPts' (10 и 20) было обнаружено 22 дефекта с большим количеством ошибок классификации, так как статистические флуктуации в данных все еще влияют на его эффективность. Дальнейшее увеличение значения 'MinPts' приводит к ограничению числа обнаруживаемых дефектов до 22, что снижает количество ложных заключений. Рис. 7*в* и 8*в* еще больше подтверждают это наблюдение, поскольку наблюдается рост эффективности метрик и ВОД. Таким образом, для анализа в предыдущем разделе выбрано подходящее значение «MinPts», равное 80, так как в этом случае получается самая высокая медиана для ВОД.

На основании проведенного анализа были выбраны следующие оптимальные параметры: обучающие данные — 1000 тепловых профилей бездефектной области, коэффициент загрязнения — 0,2, параметр ядра для ОМОВ — 0,0001, случайный инициализатор для ИЛ — 42, а «MinPts» для ЛКВ — 80. Соответствующие карты дефектов для этих оптимальных параметров представлены на рис. 9, где ЛКВ обнаружила наибольшее количество дефектов (22), опередив ОМОВ и ИЛ. С другой стороны, время обучения и тестирования показывает, что ОМОВ затрачивает гораздо меньше времени на обучение и тестирование, в то время как ИЛ и ЛКВ — умеренное и длительное время на обучение и тестирование, соответственно. Однако показатели эффективности, представленные в табл. 1, свидетельствуют о том, что ОМОВ демонстрирует лучшие показатели аккуратности и F-меры, а также высокое значение полноты, по которому ИЛ и ЛКВ превосходят ОМОВ.

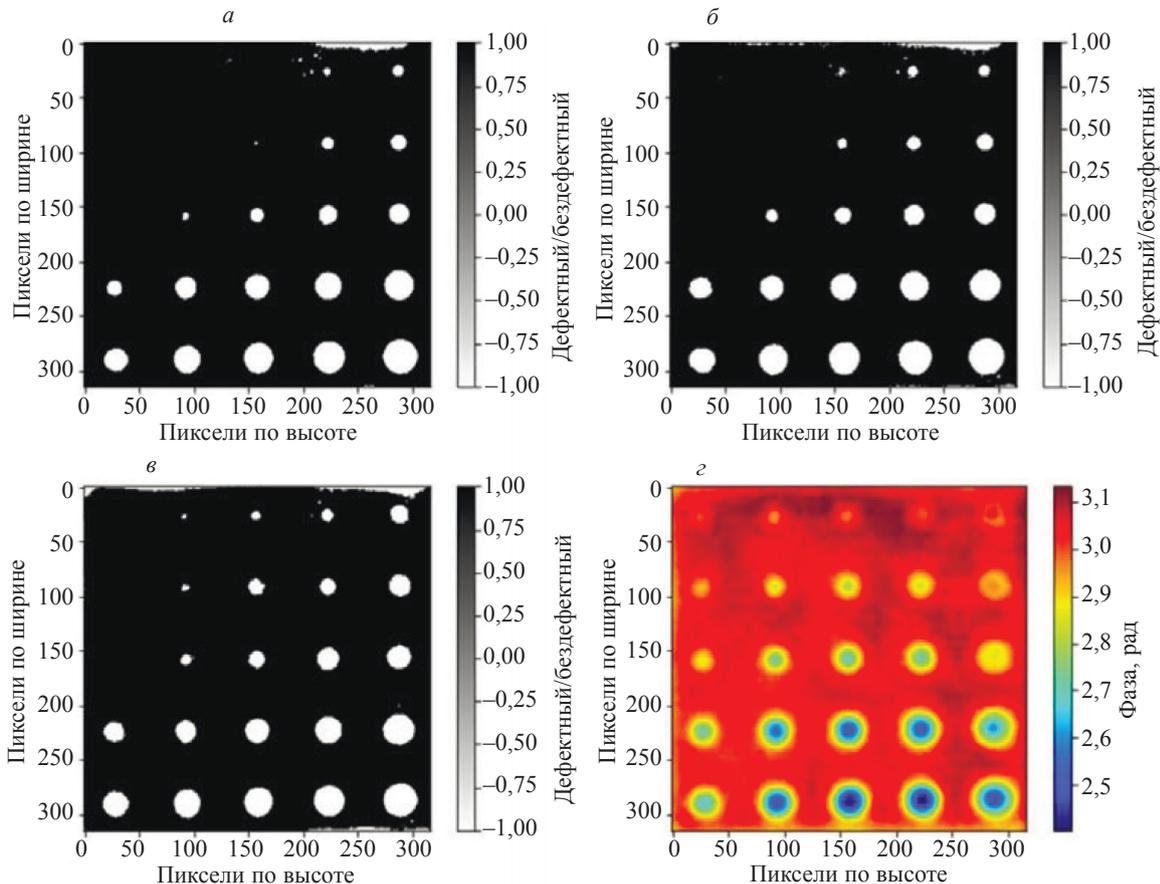


Рис. 9. Контроль дефектов в образце ПАУВ с использованием ОМОВ (*а*); ИЛ (*б*); ЛКВ (*в*) и оптимальная экспериментальная фазограмма для сравнения (*г*).

Как уже отмечалось ранее, МОА в зависимости от соответствующей процедуры генерируют для заданных данных коэффициент выброса, а по фактору загрязнения определяют пороговое

Таблица 1

**Сравнение эффективности различных МОА в целях контроля дефектов в образце ПАУВ с оптимальными параметрами инициализации**

Метод/Метрика		ОМОВ	ИЛ	ЛКВ
Время обучения, с		0,14	1,98	2,21
Время тестирования, с		20,46	27,29	192,1
Аккуратность тестирования, %		96,6	96,33	95,56
Точность	С дефектом	0,71	0,66	0,63
	Без дефекта	0,98	0,98	0,99
Полнота	С дефектом	0,74	0,83	0,83
	Без дефекта	0,98	0,97	0,97
F-мера	С дефектом	0,73	0,73	0,71
	Без дефекта	0,98	0,98	0,98

значение для классификации нормальных и аномальных участков [19—23]. Коэффициент выброса для заданных тестовых данных получается в виде одномерного вектора и далее преобразуется в реальный размер термограммы и представлен на рис. 10. По сравнению с картами дефектов карты коэффициент выбросов позволяют идентифицировать изменения параметров дефектов, таких как размер и глубина, что аналогично преимуществам традиционных методов обработки [3]. На основании первичных наблюдений можно сказать, что значения коэффициента выбросов положительны или больше нуля для тепловых профилей бездефектных областей, а в зависимости от размера и глубины дефектов они становятся отрицательными и еще больше уменьшаются. Самые мелкие и крупные дефекты имеют наименьшие значения коэффициента выброса и становятся близкими к нулю или положительными при уменьшении размера дефекта и увеличении его глубины.

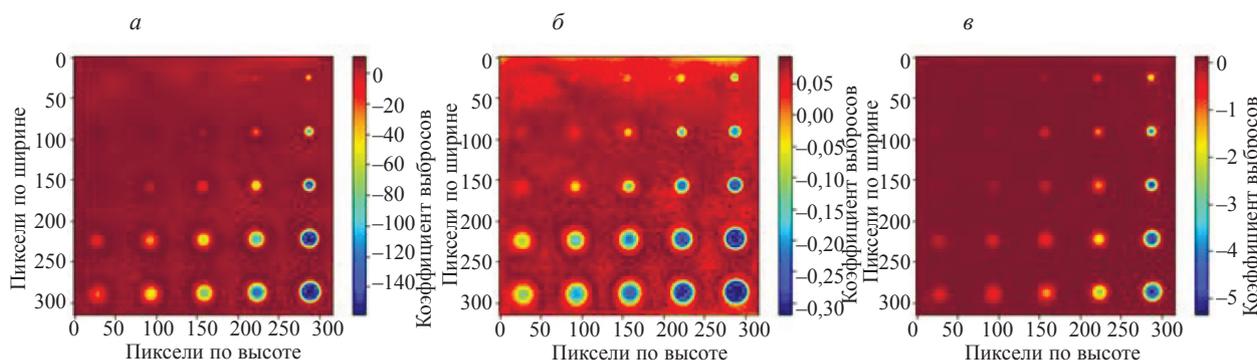


Рис. 10. Карты коэффициентов выброса для образца из ПАУВ CFRP-S15, полученные с помощью ОМОВ (а); ИЛ (б); ЛКВ (в).

В дальнейшем преимущество коэффициента выбросов используется для вычисления отношения сигнал/шум дефекта (ОСШ). Здесь используется обычная методика расчета ОСШ, при которой берется логарифм отношения разности средних значений дефектной и бездефектной областей к стандартному отклонению бездефектной области, как показано в формуле:

$$ОСШ = 20 \log \left( \frac{\text{среднее дефектной области} - \text{среднее бездефектной области}}{\text{стандартное отклонение бездефектной области}} \right) \quad (2)$$

Совместный анализ ВОД для дефектов, выявленных на рис. 9, и ОСШ, рассчитанные для дефектов на рис. 10, показаны на рис. 11а и б соответственно. Соотношение сторон каждого дефекта для справки представлено на рис. 2в. Значения ВОД остаются нулевыми для неидентифицированных дефектов.

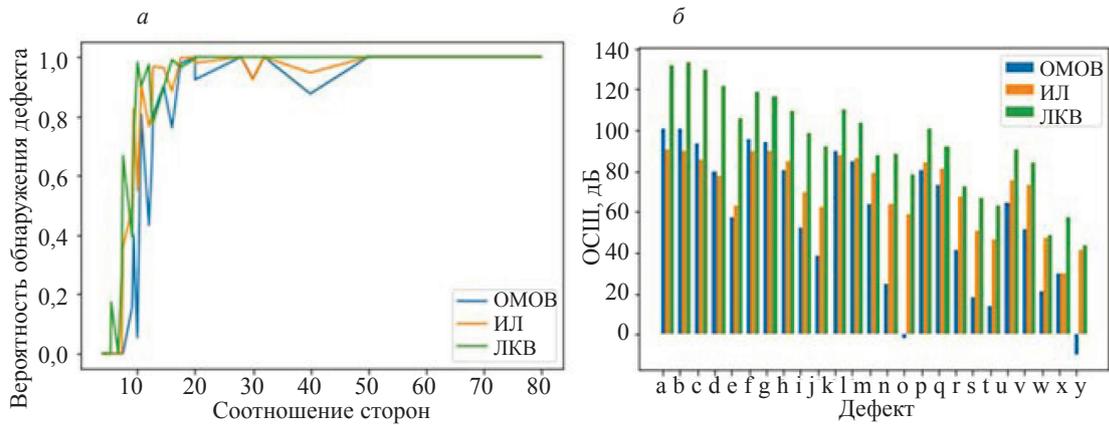


Рис. 11. Вероятность обнаружения дефекта (а) и ОСШ для дефектов (б).

фицированных дефектов (малые размеры и более глубокие дефекты) для каждой МОА, а дефекты с большими размерами (высокое соотношение геометрических параметров) идентифицируются точно и имеют наибольшую ВОД. А для всех дефектов с меньшим отношением сторон ВОД колеблется ниже допустимого предела 0,75 [9]. Однако ИЛ и ЛКВ демонстрируют близкие к допустимому пределу значения ВОД для нескольких дефектов и преодолевают порог для дефектов с отношением сторон более 10. Что касается ОСШ, то можно заметить, что ЛКВ демонстрирует высокий уровень ОСШ для всех дефектов по сравнению с другими МОА. Это объясняется меньшими вариациями коэффициентов выбросов в бездефектной области, что приводит к очень малому стандартному отклонению. Кроме того, неравномерность в левом верхнем углу карты коэффициентов выбросов ИЛ снижает ОСШ для более глубоких и мелких дефектов. Поскольку карты коэффициентов выбросов похожи на результаты способов обработки, зависимость глубины и размера дефекта от коэффициента выбросов представлена на рис. 10 и дополнительно анализируется.

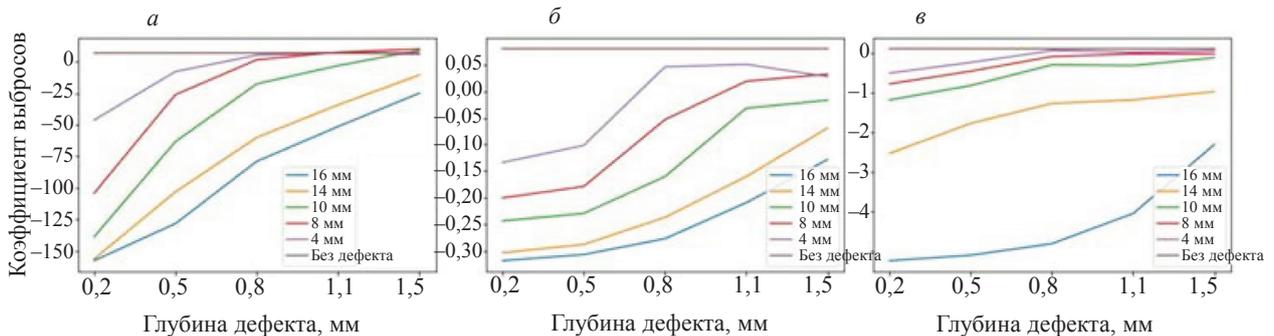


Рис. 12. Зависимость между глубиной/размером дефекта и коэффициентом выбросов для дефектов в образце CFRP-S15, взятого из ОМОВ (а); ИЛ (б); ЛКВ (в).

Коэффициент выброса берется в центральном пикселе для всех дефектов и откладывается в зависимости от глубины для каждого размера. В отличие от вариаций параметров традиционных методов обработки [18, 19], коэффициент выброса представляет собой гибридную характеристику для вариаций глубины и размера. Из ОМОВ и ИЛ на рис. 10а и б видно, что для дефектов больших размеров наблюдается линейная тенденция изменения коэффициента выброса по мере увеличения глубины, а для остальных дефектов — нелинейная. С другой стороны, коэффициент выброса, выраженный в форме ЛКВ, практически повторяет линейную тенденцию для всех размеров дефектов по мере увеличения их глубины. Эти особенности могут способствовать количественной оценке параметров дефектов аналогично традиционным методам обработки [13, 14].

Кроме вышеуказанного образца, с помощью МОА исследован образец из стеклопластика с искусственными тефлоновыми включениями различной формы. Схема расположения включений в образце, опорные данные и выбор обучающих данных представлены на рис. 13 а и б. Процедуры подготовки образцов и проведения экспериментов, этапы извлечения данных, предварительной обработки и задания опорных данных такие же, как и для вышеуказанных примеров. После линейной аппроксимации и удаления средних значений эффективный тепловой отклик образца ПАУВ представлен в виде куба термограмм из 625 кадров с разрешением  $73 \times 154$  пикселя каждый. В ходе тщательного сопоставления тепловых данных с бинарной истиной выяснилось, что из 11242 пиксельных профилей только 376 пиксельных профилей относятся к областям дефектов, а остальные 10866 профилей покрывают бездефектную область. Поскольку МОА должны обучаться индивидуально на соответствующих тепловых данных образца [18], случайным образом выбираются 100 тепловых профилей из бездефектной области, как показано на рис. 13б. Далее, параметры обучения МОА для образца ПАУВ выбирались следующим образом: коэффициент загрязнения — 0,1, параметр ядра ОМОВ — 0,001, случайный инициализатор — 42 для ИЛ и MinPts — 20 для ЛКВ.

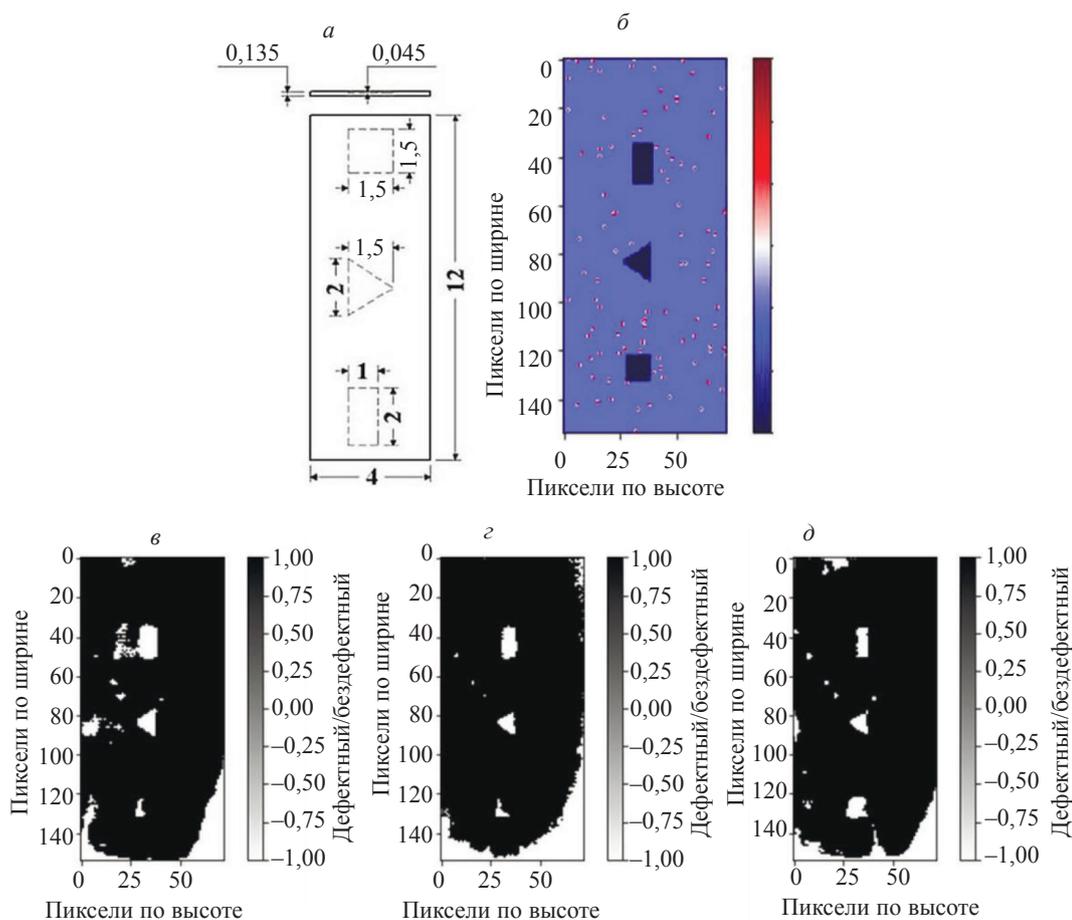


Рис. 13. Схема расположения включений в образце (а); выбор данных для обучения (б), обнаружение дефектов с использованием: ОМОВ (в), ИЛ (г) и ЛКВ-образца ПАУВ (д).

Аналогичные наблюдения получены и для образца ПАУВ, где ОМОВ имеет больше ошибок в классификации, чем другие МОА, а ЛКВ обнаруживает все дефекты с лучшей идентификацией и меньшим количеством ошибок классификации, чем ОМОВ и ИЛ, как показано на рис. 13в—д. Время обучения, время тестирования и другие качественные показатели представлены в табл. 2, где лучшие значения выделены жирным шрифтом, где МОА потребляет очень мало времени на обучение, тестирование и дает лучшие результаты при обнаружении дефектов. Наконец, сравнение данной МОА с нашей предыдущей моделью глубокого обучения с учителем в [15] проводится для

Сравнение эффективности различных МОА для образца ПАУВ

Метод/Метрика		ОМОВ	ИЛ	ЛКВ
Время обучения, с		0,02	0,5	0,08
Время тестирования, с		0,18	2,95	1,72
Аккуратность тестирования, %		91,02	88,51	92,14
Точность	С дефектом	0,21	0,15	0,24
	Без дефекта	0,99	0,98	0,99
Полнота	С дефектом	0,63	0,52	0,6
	Без дефекта	0,92	0,9	0,93
F-мера	С дефектом	0,32	0,23	0,34
	Без дефекта	0,95	0,94	0,96

образцов полимеров, армированных в одном случае углеволокном, а в другом — стекловолокном. Первые модели обучались на тепловом отклике углепластикового образца и, следовательно, обеспечивали лучшую детализацию дефектов. С другой стороны, в данном случае имеет место дисбаланс классов, поэтому трансферное обучение дало неудовлетворительные результаты. Однако способность МОА обучаться на небольшом количестве примеров нормальных классов позволила превзойти модели глубокого обучения с учителем и выявить дефекты, как показано на рис. 13.

### ЗАКЛЮЧЕНИЕ

В настоящем исследовании подчеркивается преимущество обучения на небольшом количестве примеров данных положительного или нормального класса для обучения МОА на простом оборудовании по сравнению со сложными моделями обучения с учителем для обнаружения дефектов. МОА обучаются на небольшом количестве тепловых профилей из области без дефектов, и их эффективность проверяется для различных комбинаций параметров инициализации. Количество обнаруженных дефектов, метрики эффективности и анализ надежности позволяют сделать вывод об оптимальном выборе параметров инициализации. В результате проведенных наблюдений можно сделать вывод, что МОА являются лучшей альтернативой моделям обучения с учителем для автоматического обнаружения дефектов, и при необходимости выявления всех дефектов можно ограничиться аккуратностью и другими показателями. Пользователь может выбрать оптимальные параметры инициализации в зависимости от требований к количеству выявляемых дефектов и точности их обнаружения.

### Сокращения:

НК	Неразрушающий контроль
ТНК	Тепловой неразрушающий контроль
КЧМТВ	Квадратичная частотно-модулированная тепловая волна
МО	Машинное обучение
ГО	Глубокое обучение
СНС	Сверточная нейронная сеть
ДКП	Долгая краткосрочная память
Р-СНС	Региональная сверточная нейронная сеть
YOLO	You only look once («Стоит только раз взглянуть»)
МОА	Модели обнаружения аномалий
ПАУВ	Полимер, армированный углеволокном
ОМОВ	Одноклассовый метод опорных векторов
ИЛ	Изолированный лес
ЛКВ	Локальный коэффициент выбросов
ИП	Истинно положительный
ИО	Истинно отрицательный
ЛП	Ложноположительный
ЛО	Ложноотрицательный
ВОД	Вероятность обнаружения дефекта
ОСШ	Отношение сигнал/шум

## СПИСОК ЛИТЕРАТУРЫ

1. Aldrin C. John. Intelligence augmentation and Human Machine Interface (HMI) best practices for NDT 4.0 reliability / In ASNT Annual Conference, Westgate Las Vegas Resort & Casino, Wsetgs Las Vegas, Nevada. 2019.
2. Maldague X.P.V. Theory and Practice of Infrared Technology for Non-Destructive Testing. New York: Wiley, 2001.
3. Ciampa Francesco, Mahmoodi Pooya, Pinto Fulvio, Meo Michele. Recent advances in active infrared thermography for non-destructive testing of aerospace components // Sensors 18. 2018. No. 2. P. 609.
4. He Yunze, Deng Baoyuan, Wang Hongjin, Cheng Liang, Zhou Ke, Cai Siyuan, Ciampa Francesco. Infrared machine vision and infrared thermography with deep learning: A review // Infrared Physics & Technology. 2021. V. 116. P. 103754.
5. Luo Q, Gao B, Woo WL, Yang Y. Temporal and spatial deep learning network for infrared thermal defect detection // NDT & E International. 2019. V. 108. P. 102164.
6. Hu Bozhen, Gao Bin, Lok Woo Wai, Ruan Lingfeng, Jin Jikun, Yang Yang, Yu Yongjie. A lightweight spatial and temporal multi-feature fusion network for defect detection // IEEE Transactions on Image Processing. 2020. V. 30. P. 472—486.
7. Saeed Numan, King Nelson, Said Zafar, Omar Mohammed A. Automatic defects detection in CFRP thermograms, using convolutional neural networks and transfer learning // Infrared Physics & Technology. 2019. V. 102. P. 103048.
8. Wei Ziang, Fernandes Henrique, Herrmann Hans-Georg, Tarpani Jose Ricardo, Osman Ahmad. A deep learning method for the impact damage segmentation of curve-shaped cfrp specimens inspected by infrared thermography // Sensors 21. 2021. No. 2. P. 395.
9. Fang Qiang, Ibarra-Castanedo Clemente, Maldague Xavier. Automatic defects segmentation and identification by deep learning algorithm with pulsed thermography: Synthetic and experimental data // Big Data and Cognitive Computing 5. 2021. No. 1. P. 9.
10. Wei Ziang, Fernandes Henrique, Tarpani Jose Ricardo, Osman Ahmad, Maldague Xavier. Stacked denoising autoencoder for infrared thermography image enhancement / In 2021 IEEE 19th International Conference on Industrial Informatics (INDIN), IEEE, 2021. P. 1—7.
11. Cheng Liangliang, Kersemans Mathias. Dual-IRT-GAN: A defect-aware deep adversarial network to perform super-resolution tasks in infrared thermographic inspection // Composites Part B: Engineering. 2022. P. 110309.
12. Tretout H., David D., Marin J. Y., Dessendre M., Couet M., Avenas-Payan I. An evaluation of artificial neural networks applied to infrared thermography inspection of composite aerospace structures // NDT and E International 6. 1996. No. 29. P. 392.
13. Lakshmi A. Vijaya, Gopi tilak V., Parvez Muzammil M., Subhani S.K., Ghali V.S. Artificial neural networks based quantitative evaluation of subsurface anomalies in quadratic frequency modulated thermal wave imaging // Infrared Physics and Technology 97. 2019. P. 108—115.
14. Lakshmi A. Vijaya, Ghali V.S., Subhani Sk., Balaji Naik R. Automated quantitative subsurface evaluation of fiber reinforced polymers // Infrared Physics & Technology 110. 2020. P. 103456.
15. Vesala G.T., Ghali V.S., Lakshmi A. Vijaya, Naik R.B. Deep and handcrafted feature fusion for automatic defect detection in quadratic frequency modulated thermal wave imaging // Russian Journal of Nondestructive Testing. 2021. V. 57. No. 6. P. 476—485.
16. Liu Lishuai, Guo Chenjun, Xiang Yanxun, Tu Yanxin, Wang Liming, Xuan Fu-Zhen. A semisupervised learning framework for recognition and classification of defects in transient thermography detection // IEEE Transactions on Industrial Informatics 18. 2021. No. 4. P. 2632—2640.
17. Morelli Davide, Marani Roberto, D'Accardi Ester, Palumbo Davide, Galietti Umberto, D'Orazio Tiziana. A Convolution Residual Network for Heating-Invariant Defect Segmentation in Composite Materials Inspected by Lock-in Thermography // IEEE Transactions on Instrumentation and Measurement. 2021. V. 70. P 1—14.
18. Tilak V. Gopi, Ghali V. S., Lakshmi A. Vijaya, Suresh B., Naik R. B. Proximity based automatic defect detection in quadratic frequency modulated thermal wave imaging // Infrared Physics & Technology. 2021. V. 114. P. 103674.
19. Vesala G.T., Ghali V.S., Sastry DVA Rama, Naik R.B. Deep anomaly detection model for composite inspection in quadratic frequency modulated thermal wave imaging // NDT & E International. 2022. V. 132. P. 102710.
20. Munir Mohsin, Chattha Muhammad Ali, Dengel Andreas, Ahmed Sheraz. A Comparative Analysis of Traditional and Deep Learning-based Anomaly Detection Methods for Streaming Data / In 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA). IEEE, 2019. P. 561—566.
21. Schölkopf Bernhard, Platt John C., Shawe-Taylor John, Smola Alex J., Williamson Robert C. Estimating the support of a high-dimensional distribution // Neural computation. 2001. V. 13. No. 7. P. 1443—1471.
22. Liu Fei Tony, Ting Kai Ming, Zhou Zhi-Hua. Isolation forest / In 2008 eighth IEEE international conference on data mining. IEEE, 2008. P. 413—422.
23. Breunig Markus M., Kriegel Hans-Peter, Ng Raymond T., Sander Jörg. LOF: identifying density-based local outliers / In Proceedings of the 2000 ACM SIGMOD international conference on Management of data. 2000. P. 93—104.