



Научная статья

DOI: 10.15593/perm.mech/2023.1.11

УДК 539.3

ИДЕНТИФИКАЦИЯ ДЕФЕКТОВ В КЛИНЕ С ПОКРЫТИЕМ НА ОСНОВЕ МЕТОДОВ УЛЬТРАЗВУКОВОГО НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ И СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

А.Н. Соловьев, Б.В. Соболев, П.В. Васильев, А.В. Сеничев, А.И. Новикова

Донской государственный технический университет, Ростов-на-Дону, Россия

О СТАТЬЕ

Получена: 20 апреля 2022 г.
Одобрена: 09 февраля 2023 г.
Принята к публикации:
05 апреля 2023 г.

Ключевые слова:

ультразвуковой неразрушающий контроль, сверточные нейронные сети, тонкое покрытие, упругий клин, трещина, дефектоскопия, машинное обучение, искусственные нейронные сети, идентификация дефектов, конечно-элементное моделирование.

АННОТАЦИЯ

Рассматривается идентификация трещиноподобного дефекта в клине, усиленного покрытием на основе ультразвукового неразрушающего контроля. Авторы предлагают подход идентификации дефекта с последующим определением его геометрических параметров. Подход основан на теневом методе ультразвукового неразрушающего контроля в сочетании с технологиями глубокого машинного обучения. Инспектируется клиновидная область на наличие внутреннего дефекта. На одной грани клина расположен источник ультразвуковых колебаний, на противоположной грани – приемник. Проходя через покрытие и тело клина, часть сигнала отражается от неоднородностей и дефектов, которые могут присутствовать в нем. Сигнал, достигший противоположной грани клина, считается приемником. Полученные данные обрабатываются нейросетевой моделью, которая прогнозирует наличие или отсутствие внутреннего дефекта, и в случае его наличия определяет геометрические параметры, такие как размер и положение.

Построена конечно-элементная модель распространения ультразвуковой волны внутри клина. Применяются специальные демпфирующие слои, благодаря которым существенно снижается влияние паразитных отражений сигнала и его дальнейшее распространение в тело клина. На основе построенной модели реализован теневой метод ультразвукового сканирования. Данный метод предполагает, что на одной стороне клина устанавливаются возбуждающие сигнал устройства, а на противоположной стороне – принимающие. С помощью системы распределенных вычислений проведен ряд численных экспериментов для различных комбинаций геометрических параметров клина и дефекта. На основе полученных данных построена и обучена нейросетевая модель, способная идентифицировать дефект и определять его характеристики. На вход модели поступают спектрограммы считанного сигнала, а на выходе получают значения, характеризующие дефект.

© ПНИПУ

© Соловьев Аркадий Николаевич – д.ф.-м.н., проф., зав. каф., email: solovievarc@gmail.com

Соболев Борис Владимирович – д.т.н., проф., зав. каф., email: b.sobol@mail.ru

Васильев Павел Владимирович – ст. преп., email: lyftzeigen@mail.ru

Сеничев Александр Вадимович – асп., email: alexandr.senichev@gmail.com

Новикова Анна Ивановна – ст. преп., email: novikova.ai@gs.donstu.ru

Arkady N. Solovyov – Doctor of Physical and Mathematical Sciences, Professor, Head of Department, email: solovievarc@gmail.com

Boris V. Sobol – Doctor Of Technical Sciences, Professor, Head of Department, email: b.sobol@mail.ru

Pavel V. Vasiliev – Senior Lecturer, email: lyftzeigen@mail.ru

Aleksandr V. Senichev – PhD-student, email: alexandr.senichev@gmail.com

Anna I. Novikova – Senior Lecturer, email: novikova.ai@gs.donstu.ru



Эта статья доступна в соответствии с условиями лицензии Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

IDENTIFICATION OF DEFECTS IN A COATING WEDGE BASED ON ULTRASONIC NON-DESTRUCTIVE TESTING METHODS AND CONVOLUTIONAL NEURAL NETWORKS

A.N. Soloviev, B.V. Sobol, P.V. Vasiliev, A.V. Senichev, A.I. Novikova

Don State Technical University, Rostov-on-Don, Russian Federation

ARTICLE INFO

Received: 20 April 2022
Approved: 09 February 2023
Accepted for publication:
05 April 2023

Keywords:

ultrasonic nondestructive testing, convolutional neural networks, thin coating, elastic wedge, crack, flaw detection, machine learning, artificial neural networks, defect identification, finite element modeling.

ABSTRACT

The paper deals with the identification of a crack-like defect in a coated wedge based on ultrasonic nondestructive testing. The authors propose an approach of defect identification followed by determination of its geometrical parameters. The approach is based on a shadowed ultrasonic nondestructive testing method combined with deep machine learning technologies. A wedge-shaped area is inspected for the presence of an internal defect. On one edge of the wedge there is a source of ultrasonic vibrations, on the opposite edge there is a receiver. Passing through the coating and body of the wedge, part of the signal is reflected from inhomogeneities and defects that may be present in it. The signal reaching the opposite edge of the wedge is read by the receiver. The received data is processed by a neural network model, which predicts the presence or absence of an internal defect and, if present, determines geometric parameters such as size and position.

A finite element model of ultrasonic wave propagation inside the wedge is constructed. Special damping layers are used, due to which the influence of parasitic signal reflections and its further propagation into the wedge body is significantly reduced. Based on the built model, the shadow method of ultrasonic scanning is implemented. This method implies that on one side of the wedge are installed excitation devices, and on the opposite side – receiving devices. Several numerical experiments for various combinations of geometric parameters of the wedge and the defect have been performed using a distributed computing system. Based on the obtained data, a neural network model was built and trained, capable of identifying the defect and determining its characteristics. The input of the model is spectrograms of the readout signal, and the output is values characterizing the defect.

© PNRPU

Введение

Эксплуатация деталей машин и конструкций происходит в условиях возникновения коррозии, больших нагрузок, повышенного изнашивания, когда концентраторы напряжения сосредоточены в поверхностных слоях изделия. Передовые технологии покрытия изделий тонкими накладками призваны повысить коррозионную стойкость, твёрдость, увеличивают надёжность и их эксплуатационные сроки за счет создания на поверхности остаточных напряжений сжатия. Кроме этого метода, повысить износостойкость и увеличить прочность возможно за счет создания соответствующих технологий обработки или использования композиций сплавов. Указанные способы позволяют сохранить пластичность и устойчивость к внутренним трещинообразным включениям, повышают сроки эксплуатации изделий и снижают расходы металла.

Тонкое покрытие представляет собой слой материала, нанесенного на поверхность детали. Толщина покрытия может достигать от десятых долей до сотен микрометров. Материалами покрытий могут быть лаки, краски, металлы, оксиды, полимеры. Выбор материала покрытия и его толщины зависит от назначения детали и покрытия, технологии ее изготовления и условий эксплуатации и строго регламентируется.

Нередко методы машинного обучения применяются в области дефектоскопии или смежных областях науки,

например, в работе [1] авторы проводят исследование композитных материалов с дефектами. Из-за наличия дефектов в композитах их эксплуатационные свойства могут ухудшаться. В каждой точке исследуемого объекта проводится ультразвуковое сканирование. Колебания оцифровываются и затем из них извлекаются характеристики, содержащие информацию об объекте контроля. После проведения анализа данных происходит классификация полученных характеристик с применением искусственных нейронных сетей (ИНС). В результате авторы получают изображение в области дефекта, полученное с помощью специально обученной ИНС, которое отражает характер и степень распространения дефекта. Примененный подход четко идентифицирует область повреждения, и полученное изображение совпадает с визуальными наблюдениями.

В работе [2] авторы применяют техники машинного обучения для работы в области ультразвуковых исследований в медицине. Центральной идеей работы является раскрытие аспектов понимания влияния методологий глубокого обучения в сфере визуализации ультразвуковых исследований. Авторы применяют методы машинного обучения для решения задач формирования ультразвукового луча, восстановления структурированного сигнала, подавления помех и повышения разрешения визуализации.

В работе [3] предложен отличающийся от ранее известных алгоритм многопараметрической идентификации

ции дефектов в стержневых конструкциях. Новизна алгоритма заключается в том, что процедура идентификации дефектов разделена на два этапа: на первом этапе происходит локация дефекта, а на втором – оценка степени поврежденности дефекта. В качестве дополнительной информацией к решению задачи реконструкции дефектов выступает набор собственных частот и форм колебаний исследуемого объекта. Анализ форм колебаний позволяет решить задачу первого этапа, после чего строится аналитическая или конечно-элементная модель конструкции с дефектами и с помощью прямых расчетов решается задача второго этапа. В работе также приведен пример расчета параметров дефекта в упругом консольном стержне на основе эксперимента в конечно-элементном комплексе.

В работе [4] применяется один из методов неразрушающего контроля, а именно метод акустической эмиссии, который является весьма перспективным методом оценки композиционных материалов. Для надежного автоматического контроля повреждений с помощью пленочных датчиков поливинилиденфторида (PVDF) важно идентифицировать сигналы акустической эмиссии, связанные со структурой волокон, при наличии шума. В проведенных экспериментах композиты из многослойного армированного стекловолокна (GFRP) были изготовлены несколькими различными способами. Сигналы акустической эмиссии были сняты с поверхности, покрытой PVDF-пленкой, во время статической нагрузки на растяжение. Сигналы акустической эмиссии классифицировались с использованием искусственной нейронной сети. При этом результаты показывают, что различные механизмы разрушения в композитах могут быть классифицированы с применением аппарата искусственных нейронных сетей.

В работе [5] авторы исследуют обрушения, произошедшие во время раскопок туннелей в тонких и чрезвычайно тонких слоистых породах горной породы на гидроэлектростанции Wudongde в Китае. Для прогнозирования риска и глубины обрушения необходим надежный метод, который и предлагают авторы работы. Однако как теория, так и практика показывают, что единственный критерий не может точно предсказать глубину обрушения. В этом исследовании с использованием ИНС был исследован метод интеллектуального прогнозирования. На основе теоретического и статистического анализа выбраны и использованы шесть входных параметров (глубина покрытия, отношение основных малых напряжений, индекс геологической силы, метод выемки грунта, сила поддержки и ориентация породы). Полученные из туннелей данные на гидроэлектростанции Wudongde, а именно сорок пять учебных образцов и шесть пробных образцов были использованы в обучении модели. Структурные параметры и начальные веса искусственной нейронной сети были оптимизированы с помощью генетического алгоритма. Затем обученная модель была использована для прогнозирования глубины обрушения нескольких уча-

стков раскопок. Прогнозы показывают хорошее соответствие с измерениями на участках.

В работе [18] проводится численная оценка вынужденных колебаний консольной балки с поперечной поверхностной трещиной, равномерно распространяющейся по ширине балки. Основная цель авторов заключается в установлении связи нелинейных резонансов с наличием, расположением и глубиной трещины. Для этого были рассмотрены качественные характеристики, а именно: искажения фазового портрета, суб- и супергармонические компоненты в спектре Фурье и изогнутая форма модальной линии. Кроме того, были измерены количественные параметры, такие как эксцентриситет и экскурсия орбиты, а также амплитуда гармоник в спектре. Затем была предложена процедура идентификации, основанная на пересечении построенных поверхностей, которая позволила определить структурное повреждение.

В работе [19] представлен метод обнаружения множественных трещин в балочных конструкциях путем анализа статического изгиба. Возникшее повреждение приводит к изменению жесткости балки. Это вызывает локализованную сингулярность, которая может быть идентифицирована с помощью вейвлет-анализа отклика смещения. Существование и расположение трещин можно определить по положению пиков в непрерывном вейвлет-преобразовании. Для этого статический профиль балок анализируется с помощью вейвлет-преобразований. Рассматриваются балки при некоторых идеальных граничных условиях и заданной нагрузке. Авторами была смоделирована форма прогиба балки с открытыми и усталостными трещинами. Вычислен прогиб балки с трещинами в закрытой форме для нескольких случаев нагрузок, размеров и расположения трещин, и разработано явное выражение для индекса поврежденности. Численные результаты показывают, что метод может обнаруживать трещины небольшой глубины и быть применим при наличии шума в измерениях.

В работе [20] рассматривается регуляризация градиента деформации в механике сплошных поврежденных. Представлен анализ напряжений и деформаций для численных экспериментов с помощью техники, основанной на методе Галеркина. Моделирование показывает, что нелокальность, придаваемая модели регуляризацией градиента деформации, эффективно решает проблему зависимости от сетки, характерную для стандартных континуальных моделей повреждений, и позволяет достичь сходимости вплоть до режимов деформации, для которых наблюдается эквивалентная отрицательная жесткость. Более того, авторы показывают случай, когда в результате повреждения развиваются новые микроструктуры и, следовательно, более высокие значения модулей второго градиента. Для иллюстрации предполагается простое монотонное правило эволюции для роста вторых градиентных модулей. Таким образом, для этого простого правила моделирование показывает развитие большей диффузной зоны повреждения, размер которой можно контролировать.

В работе [21] авторы рассматривают поведение зернистых материалов при повреждении на основе механических концепций, используя энергетический и вариационный подход. Микромеханика зерен учитывается с помощью уравнения Пиолы и объективных кинематических дескрипторов, полученных для относительного смещения пар зерен в зернистых материалах, подвергающихся конечным деформациям. На основе вариационного подхода получены условия типа Каруша – Кюн–Таккера, обеспечивающие уравнения эволюции поврежденной пары зерен, и уравнения Эйлера – Лагранжа для эволюции относительного смещения пар зерен. Применимость модели проиллюстрирована на численных примерах для конкретной формы функций упругой энергии и диссипации пары зерен. Результаты показывают интересную эволюцию анизотропии, вызванную повреждением, включая возникновение типа хирального поведения и формирование зон конечной локализации.

В работе [22] представлена вариационная модель для анализа эволюции трещин. Метод рассматривает разрывы, которые развиваются в соответствии с принципами механики когезионного разрушения. Представлена новая схема изогометрической интерполяции. Также предложен метод отслеживания разрыва, основанный на локальном искажении параметризации геометрии, полученной при определении положения контрольных точек изогометрической интерполяции как решение подходящей задачи минимизации.

В работе [23] рассмотрены основные физические закономерности процессов термопластической деформации и накопления усталостных повреждений в поликристаллических конструкционных сплавах при различных режимах циклического термомеханического нагружения. Модель состоит из трех взаимосвязанных частей: соотношений, определяющих пластическое поведение материала, учитывающих его зависимость от процесса разрушения; эволюционных уравнений, описывающих кинетику накопления повреждений; критерия прочности поврежденного материала. В качестве определяющих соотношений используется модель пластичности, основанная на понятии поверхности текучести и принципе ортогональности вектора пластической деформации к поверхности текучести. Критерий прочности поврежденного материала основан на достижении критического значения степени повреждения. Представлены результаты численного моделирования циклической термопластической деформации и накопления усталостных повреждений.

В работе [24] авторы представляют модель, в которой движения двух групп балок, составляющих пантографический лист, при описании двумя независимыми полями перемещений позволяют моделировать точки начала разрушения при испытании на осевое растяжение. Энергия деформации моделируется как функция этих независимых перемещений в виде аддитивного квадратичного члена энергии деформации, зависящего от квадратичной нормы их разности. Численные моде-

лирования показали, что наиболее напряженными узлами являются те, где наблюдаются первые разрывы.

В работе [25] исследуется распространение упругих волн в одномерной микроморфной среде, характеризуемой двумя внутренними переменными. Уравнения динамики выводятся в соответствии с двумя различными подходами, а именно с использованием: (i) баланса линейного импульса и неравенства Клаузиуса – Дюэма, и (ii) предполагаемого функционала Лагранжа (включая гироскопическую связь) вместе с вариационным принципом. Получено дисперсионное соотношение и показана возможность возникновения полосовых промежутков в таких микроструктурированных материалах. Также проведены некоторые численные моделирования для того, чтобы подчеркнуть дисперсионную природу исследуемого материала.

В работе [26] автор делает обзор в области вычислительных стратегий, разработанных для анализа обратных задач. Начиная с определения обратной задачи и фокусируясь на трудностях, присущих их решению, представлены и обсуждены различные вычислительные инструменты, разработанные для их решения. Это позволяет осознанно выбрать наиболее эффективные стратегии в отношении решаемой проблемы. Кратко описываются некоторые обратные задачи и подробно обсуждается их численное решение. Это позволяет выявить основные проблемы, которые необходимо преодолеть, и достижимую точность. Наконец, рассматриваются новые и сложные обратные задачи, подробно обсуждаются некоторые современные и классические результаты.

В работе [27] авторы рассматривают обратную задачу восстановления осевой жесткости поврежденного стержня на основе знания конечного числа резонансных частот свободных осевых колебаний в условиях закрепленного конца. Повреждение описывается как уменьшение осевой жесткости, а неповрежденная и поврежденная конфигурации стержня предполагаются симметричными. Метод основан на многократном определении квазиизоспектральных операторов стержня. Процедура реконструкции является явной, она реализована численно и протестирована для идентификации одиночных и множественных локализованных повреждений. Оценивается и обсуждается чувствительность метода к количеству используемых частот, форме, интенсивности и расположению повреждений, а также к наличию шума в данных.

Реакции метаматериалов обычно моделируются обобщенными теориями на основе сплошной среды. Присущая им структура приводит к необходимости теорий более высокого порядка, и, особенно в механике повреждений, такое обобщение трудно получить. В работе [28] авторы берут за основу механику Лагранжа для получения основных уравнений обобщенной механики повреждений для метаматериалов. Кроме того, благодаря использованию вспомогательных переменных, вариационная формулировка наделяется первой

скоростью переменной повреждения, которая отсутствует в стандартных подходах. Представленный формализм действий со вспомогательными переменными приводит непосредственно к слабой форме. Авторы реализуют подход на основе метода конечных элементов с использованием вычислительной платформы с открытым исходным кодом FEniCS и решают эту слабую форму, чтобы численно получить деформацию и определить повреждение.

В работе [29] рассматривается стальная труба, ослабленная несквозной поверхностной трещиной полуэллиптической формы. Трещина имеет продольную ориентацию и располагается на наружной поверхности трубы. Труба испытывает действие внутреннего давления. При помощи CAE-системы ANSYS решается задача механики разрушения. Для точек вдоль фронта дефекта исследуется распределение значений коэффициента интенсивности напряжений, вычисленных при помощи инвариантного J-интеграла. Расчет значений J-интеграла выполняется методом интегрирования по области. Проводится сравнение полученных в работе результатов с данными других авторов, полученных для труб и цилиндрических сосудов давления, ослабленных несквозными трещинами. Результаты численного моделирования хорошо согласуются с известными решениями. Применение регулярной сетки с большим числом конечных элементов вдоль фронта дефекта существенно повышает точность решения задачи механики разрушения. Исследование распределения параметров механики разрушения позволило выявить наличие краевого эффекта вблизи выхода фронта трещины на поверхность трубы.

В [30] предложен приближенный метод оценки влияния дефектов на статическую прочность композитных фланцев для высоконагруженных корпусных деталей и узлов авиационной техники из полимерных композитов, основанный на современных методах численного моделирования. Определены основные виды дефектов в слоистых композитах, проведен обзор основных работ, посвященных исследованию вопросов прочности слоистых конструкций с дефектами. С помощью двумерной осесимметричной модели в среде конечно-элементного анализа ANSYS проведено численное моделирование механического поведения фланца из стеклопластика с основными типами дефектов при силовом нагружении. Оценка прочности конструкции с дефектом проводилась с запасом прочности. Запас статической прочности рассматриваемого фланца оценивался по компонентам напряжений с использованием критерия максимального напряжения. Модель позволяет анализировать как нормальные напряжения в плоскости слоя, так и межслойные растягивающие и сдвиговые напряжения.

В настоящей работе авторы проводят решение задачи идентификации трещиноподобного дефекта в клине, усиленного покрытием на основе ультразвукового неразрушающего контроля. Построена конечно-элемент-

ная модель распространения ультразвуковой волны внутри клина. На основе построенной модели реализован теневой метод ультразвукового сканирования. Проведен ряд численных экспериментов для различных комбинаций геометрических параметров клина и дефекта. На основе полученных данных построена нейросетевая модель, способная идентифицировать дефект и определять его характеристики.

1. Постановка задачи

В прямой задаче рассматриваются вынужденные колебания упругого тела, которые описываются следующей краевой задачей:

$$\sigma_{ij,j} = \rho \ddot{u}_i; \sigma_{ij} = c_{ijkl} u_{k,l}, i = 1, 2, 3; \quad (1)$$

$$u_i |_{S_u} = u_i^{(0)}, \sigma_{ij} n_j |_{S_i} = p_i, \sigma_{ij} n_j |_{S_d} = q_i, \quad (2)$$

где u_i – искомые компоненты вектора смещений, $u_i^{(0)}$ и p_i, q_i – известные компоненты вектора смещений и поверхностных нагрузок, σ_{ij} и c_{ijkl} – компоненты тензоров напряжения и упругих постоянных; ρ – плотность; S_u, S_i – поверхности тела, на которых задан вектор смещений и напряжений соответственно, S_d – внутренние поверхности туннельной трещины в направлении оси Ox_3 .

В задачах идентификации дефектов (трещин, включений, полостей) требуется определить их конфигурацию, поэтому поверхности S_d являются неизвестными, что относит рассматриваемые проблемы к обратным геометрическим задачам теории упругости [6]. Далее будем считать, что берега трещины не взаимодействуют и свободны от напряжений $q_i = 0$. Для решения обратных задач реконструкции поверхности S_d необходима некоторая дополнительная информация кроме той, что содержится в краевых условиях (2). Такой дополнительной информацией может быть амплитудно-временная характеристика (ABX) волнового поля смещений \bar{U} , измеренного на свободной поверхности:

$$X: u_i = U_i(\bar{x}_k, t),$$

$$\text{при } t \in [0, T] \text{ и } k = 1, 2, \dots, n, \bar{x}_k \in S_i, \quad (3)$$

где T – характерное время отражения сигнала; n – количество точек измерения.

Таким образом, получаем набор входной информации X , который может быть использован в методе реконструкции геометрических параметров трещины.

2. Предлагаемый метод

Авторы предлагают подход идентификации дефекта с последующим определением его геометрических параметров.

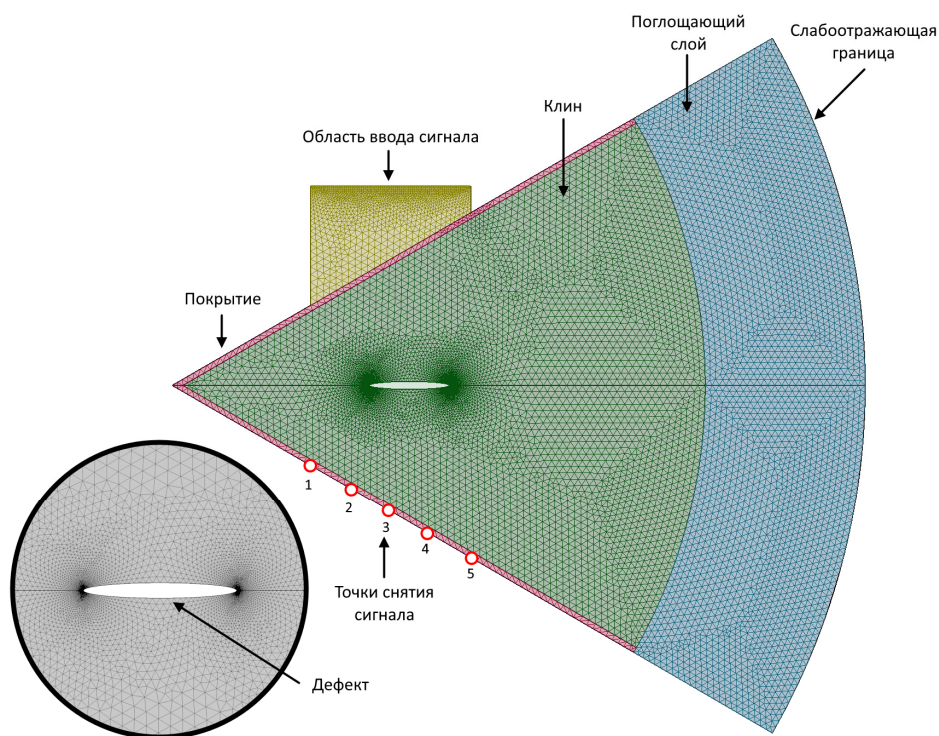


Рис. 1. Исследуемая клиновидная композитная структура

Fig. 1. Investigated wedge-shaped composite structure

Подход основан на теновом методе ультразвукового неразрушающего контроля [7; 8] в сочетании с технологиями глубокого машинного обучения. Инспектируется клиновидная область на наличие внутреннего дефекта. На одной грани клина расположен источник ультразвуковых колебаний, на противоположной грани – приемник. Проходя через покрытие и тело клина, часть сигнала отражается от неоднородностей и дефектов, которые могут присутствовать в нем. Сигнал, достигший противоположной грани клина, считывается приемником. Полученные данные обрабатываются нейросетевой моделью, которая прогнозирует наличие или отсутствие внутреннего дефекта, и в случае его наличия определяет геометрические параметры, такие как размер и положение. Обучение нейросетевой модели производится на предварительно подготовленных данных, полученных в результате проведения серии численных экспериментов. С помощью конечно-элементной системы автоматизированных расчетов формируется обучающий объем данных. При этом решается большое число задач с различными геометрическими параметрами, такими как положение источника и приемника сигнала, положение и размеры внутреннего дефекта. После чего происходит необходимая обработка и подготовка данных с дальнейшим обучением нейросетевой модели и её тонкой настройкой.

В данной работе рассмотрены случаи, когда источник и приемник сигнала синхронно перемещались вдоль граней клина. При каждом перемещении происходит инициирование ультразвукового импульса, с од-

ной стороны, и его считывание – с другой. На рис. 1 показана клиновидная область с покрытием и внутренним дефектом, актюатор и область считывания сигнала

3. Конечно-элементное моделирование

В качестве среды моделирования применяется COMSOL Multiphysics 5.5. Моделирование проводится с помощью интерфейса ElasticWaves, TimeExplicit. Интерфейс ElasticWaves предназначен для решения нестационарных линейных задач распространения упругих волн в больших областях, размер которых значительно превосходит длину моделируемой волны. Он подходит для проведения моделирования с произвольными источниками и полями, зависящими от времени. Данный интерфейс может быть применен для моделирования процессов неразрушающего контроля или, например, для моделирования распространения сейсмических волн в грунте и породе. Специальные поглощающие слои используются для создания эффективных неотражающих граничных условий.

Интерфейс основан на разрывном методе Галеркина (dG-FEM) и использует явный решатель [9]. Этот метод очень эффективен в использовании памяти и может решать проблемы со многими миллионами степеней свободы. Этот метод также хорошо подходит для распределенных вычислений на кластерах.

Интерфейс решает уравнения линейной упругости в формулировке скорость – деформация. Зависимыми переменными являются структурная скорость v и де-

формация E . Структурное демпфирование может быть введено с использованием модели демпфирования Рэлея.

Модель решает основные уравнения для общего линейного упругого материала в формулировке скорости – деформации

$$\rho \frac{\partial v}{\partial t} - \nabla \cdot S = F_v,$$

$$\frac{\partial E}{\partial t} - \frac{1}{2} [\nabla v + (\nabla v)^T] = 0,$$

$$S = C : E,$$

где v это скорость, ρ – плотность, S – тензор напряжений, E – тензор деформаций, C – тензор упругости (или тензор жесткости), F_v – это объемная сила. Уравнения действительны как для изотропных, так и для анизотропных материалов. Диссипативные свойства могут быть добавлены к модели в виде демпфирования Рэлея. Это добавляет дополнительные левые члены к уравнению движения (первое уравнение) относительно массы и жесткости.

На основе параметров материала (модуля Юнга и коэффициента Пуассона) могут быть рассчитаны скорости волн:

$$c_p = \sqrt{\frac{\tilde{E}(1-\nu)}{\rho(1+\nu)(1-2\nu)}}, c_s = \sqrt{\frac{\tilde{E}}{2\rho(1+\nu)}},$$

где c_p – скорость продольной волны, c_s – скорость поперечной (сдвиговой) волны и ρ – плотность, \tilde{E} – модуль Юнга, ν – коэффициент Пуассона.

Поскольку применяется разрывный метод Галеркина, необходимо определить внутреннее условие на границе соединения покрытия и основного материала клина. Эти условия учитывают скачек свойств материалов. Условия обеспечивают непрерывность скорости и нормальных напряжений на внутренней границе

$$v_{down} - v_{up} = 0,$$

$$(S_{down} - S_{up})n = 0,$$

индексы «up» и «down» в уравнении относятся к верхним и нижним сторонам внутренней границы относительно нормали n .

Задается поглощающий слой (Absorbing Layer) (рис. 1) который работает, комбинируя три метода: систему масштабирования, фильтрацию и простые неотражающие условия. Слой добавляет специальную систему, где масштабирование эффективно замедляет распространяющиеся волны. Фильтрация ослабляет и отфильтровывает высокочастотные составляющие волны. Согласно геометрии рассматриваемой клинообразной структуры, тип геометрии слоя установлен как ци-

линдрический, так как он расположен симметрично относительно вершины клина.

На правой границе клиновидной структуры (см. рис. 1) задано условие, которое позволяет выходить распространяющимся волнам за пределы клина с минимальными отражениями. Это условие пытается создать идеальное согласование импеданса для продольных и поперечных волн на основе параметров материала домена, к которому оно применено.

$$Sn = -d_{im} \frac{\partial v}{\partial t},$$

$$d_{im} = d_{im}(\rho c_s c_p).$$

Данное условие применяется совместно с поглощающим слоем, чтобы создать эффективные условия поглощения, которые будут работать для большинства углов падения распространяющихся волн.

При решении задач распространения волн в упругих телах следует учитывать, что множество различных волн могут распространяться внутри упругой среды и на ее поверхности. Внутри среды распространяются продольные и поперечные волны. При наличии свободной поверхности или границы раздела сред могут распространяться поверхностные (например, волны Рэлея) или интерфейсные волны.

Разные волны распространяются с разными скоростями и имеют разные длины волн. Быстрой волне со скоростью c_{max} соответствует длина волны λ_{max} . Это и определяет размер сетки конечных элементов. Как и для всех явных методов, для решения задач с помощью данного интерфейса (Elastic Waves) порядок дискретизации равен четырем (quartic-shaped functions). Что задает максимальный размер элемента сетки

$$h_{max} = \frac{\lambda_{max}}{1,5} = \frac{c_{max}}{1,5 \cdot f_{max}},$$

где f_{max} это максимальная частотная составляющая, которая должна быть определена в распространяющемся сигнале.

Сетка должна адекватно отражать детали геометрии и изогнутые поверхности, в данном случае дефект, заданный эллипсообразным вырезом в теле клина. На рис. 1 (внизу слева) показана детализация сетки конечных элементов в вершинах дефекта. В рамках данной модели применяются значения коэффициента кривизны 0,3–0,4, что дает хорошую детализацию с учетом метода решения.

Как было упомянуто выше, описанный здесь метод использует явную временную схему. Это устанавливает строгий предел для внутреннего временного шага. Шаг по времени контролируется наименьшим значением, определяемым как соотношение между локальным размером сетки и самой быстрой волной, распространяющейся со скоростью c_{max} . Это означает, что один ма-

ленький элемент сетки в модели будет контролировать глобальный временной шаг, с которым будет работать решатель. Допуская, что в большинстве случаев продольные волны распространяются с большей скоростью, чем остальные типы волн, устанавливается $c_{max} = c_p$. Это особенно важно, когда проводится моделирование распространения волн в телах с комплексной структурой, такой, как в данной задаче (покрытие – тело клина). Для каждой области задается соответствующий размер сетки элементов, зависящий от скорости распространения волны в этом материале.

Исходя из этого, при построении сетки конечных элементов уделяется особое внимание детализации в области дефекта и области ввода ультразвукового сигнала. Руководствуясь изложенным выше, частота зондирующего импульса была выбрана равной 0,5 МГц. Синусоидальный сигнал в сочетании с функцией Хеннинга формирует зондирующий импульс, который задается граничными условиями:

$$Sn = F_A(t), F_A = -p(t)n.$$

Выбранные параметры позволяют наиболее рационально использовать вычислительные мощности и провести необходимое количество численных экспериментов за ограниченное время.

Параметры конечно-элементной модели, показанной на рис. 1, приведены в таблице ниже. В качестве материала покрытия выступает карбид вольфрама, в качестве основного материала клина – конструкционная сталь.

На рис. 2 показаны результаты моделирования распространения ультразвуковой волны в клине с покрытием и дефектом. Слева продемонстрирован случай, когда источник ультразвукового сигнала находится над

дефектом, часть сигнала отражается от дефекта, другая часть проходит к противоположной грани клина. Справа показан случай, когда сигнал проходит мимо дефекта и достигает противоположной грани клина без существенных отражений.

Таблица 1

Основные параметры конечно-элементной модели

Table 1

Basic parameters of the finite element model

Параметр	Значение
Угол раскрытия клина (α)	60°
Толщина покрытия (h), мм	1
Размер клина (l), мм	100
Длина трещины ($crack_{length}$), мм	15
Толщина трещины ($crack_{width}$), мм	1,5
Удаленность трещины от вершины клина ($crack_{position}$), мм	35
Удаленность актюатора и приемника от вершины клина ($actuator_{position}$), мм	30
Скорость распространения продольной волны в покрытии ($c_{tungsten}$), м/с	7166
Скорость распространения продольной волны в теле клина (c_{steel}), м/с	5856
Плотность покрытия ($\rho_{tungsten}$), г/см ³	15,66
Плотность тела клина (ρ_{steel}), г/см ³	7,85
Модуль Юнга покрытия ($\tilde{E}_{tungsten}$), ГПа	721
Модуль Юнга тела клина (\tilde{E}_{steel}), ГПа	200
Коэффициент Пуассона покрытия ($\nu_{tungsten}$)	0,2
Коэффициент Пуассона тела клина (ν_{steel})	0,3
Частота ультразвукового сигнала ($signal_{freq}$), МГц	0,5




Рис. 2. Распространение ультразвуковой волны в клине с покрытием: $a - actuator_{position} = 30,34$ мм, $time = 1,94 \cdot 10^{-5}$ с ;

$$b - actuator_{position} = 60$$
 мм, $time = 2,8 \cdot 10^{-5}$ с

Fig. 2. Propagation of an ultrasonic wave in a coated wedge: $a - actuator_{position} = 30,34$ mm, $time = 1.94 \cdot 10^{-5}$ sec ;

$$b - actuator_{position} = 60$$
 mm, $time = 2.8 \cdot 10^{-5}$ sec

4. Создание обучающего набора данных

Для создания объема данных, необходимого для обучения нейросетевой модели, проводится ряд численных экспериментов на базе COMSOL Multiphysics. Исходя из опыта предыдущих работ авторов [10; 11], строится сбалансированный набор, в котором присутствуют результаты расчетов с различными геометрическими параметрами модели. Параметр $crack_{length}$ – в пределах от 5 до 20 мм (всего 15 значений), параметр $crack_{width}$ – в пределах от 0,5 до 2 мм (всего 15 значений), параметр $crack_{position}$ – в пределах от 5 до 50 мм (всего 15 значений), параметр $actuator_{position}$ – в пределах от 0 до 60 мм (всего 15 значений). Доля результатов расчетов, в модели которых отсутствует дефект, составляет 5 %. В качестве одной обучающей единицы выступает спектрограмма, полученная после обработки данных алгоритмом быстрого преобразования Фурье. Так как сигналы считываются одновременно в 5 точках (см. рис. 1), то результирующий объем данных состоит из 16 875 векторов с наличием дефекта и 840 векторов без дефекта. В связи со спецификой решаемой задачи проводить дополнительную аугментацию данных невозможно. Соотношение обучающей и тестовой выборок составляет 85 к 15 %.

5. Обработка данных и применение нейросетевых технологий

Результатом решения ряда задач с различными параметрами конечно-элементной модели служит большой объем данных, который может быть обработан

нейросетевой моделью. В качестве входной информации выступают спектрограммы, полученные после обработки принятых сигналов алгоритмом БПФ. Они позволяют провести предварительную оценку информативности аккумулируемых данных. На рис. 3, а, показаны формы принятых ультразвуковых сигналов в различных точках, на рис. 3, б, соответственно показаны их амплитудно-частотные характеристики. В качестве выходной информации выступают геометрические параметры идентифицируемого дефекта и информация о его наличии или отсутствии. На основе этих данных строятся обучающие вектора для нейросетевой модели.

Из-за наличия покрытия в исследуемой модели при переходе волны из одного материала (карбид вольфрама) в другой (конструкционная сталь) происходят многократные отражения сигнала. Лидирующие позиции среди решений по обработке больших объемов данных с высокой степенью вариативности и зашумленности на данный момент занимают модели глубокого обучения на основе сверточных нейронных сетей [2; 12; 13].

На рис. 4 продемонстрированы спектрограммы сигналов, принятых в различных точках на поверхности клина. При этом источник и приемник сигнала синхронно перемещались вдоль граней клина. По этому рисунку можно визуально оценить информативность принятых сигналов. В точках 3–5 отчетливо наблюдается акустическая тень, созданная наличием дефекта внутри клина. На основе подобной информации будет проходить обучение нейросетевой модели.

Сверточные нейронные сети (СНН) [14] представляют собой особый тип нейронных сетей, которые обычно состоят из следующих слоев: входного, сверточного, субдискретизации, полносвязного.




Рис. 3. Амплитудно-временная характеристика принятых сигналов в точках 1 и 5 (а), амплитудно-частотная характеристика этих же сигналов (б)

Fig. 3. The amplitude-time characteristic of the received signals at points 1 and 5 (a), the amplitude-frequency characteristic of the same signals (b)




Рис. 4. Спектрограммы сигнала, принятого в пяти различных точках на поверхности клина

Fig. 4. Spectrograms of the signal received at 5 different points on the surface of the wedge

На входной слой подается информация, которая будет обработана нейросетевой моделью, обычно это изображения, но размерность данных этого слоя может быть произвольной.

Сверточный слой использует фильтры, которые выполняют операции свертки данных, полученных на входном слое. Его гиперпараметры включают размер фильтра и шаг, с которым окно фильтра будет перемещаться по входному массиву данных. Полученный результат свертки называется картой объектов, или картой активации.

Слой субдискретизации выполняет операцию понижающей дискретизации, которая обычно применяется после слоя свертки. Он выполняет некоторую пространственную инвариантность. Обычно может применяться среднее или максимальное объединение данных.

Полносвязный слой принимает на вход одномерные данные, где каждый вход связан со всеми нейронами слоя. Обычно полносвязные слои присутствуют в сверточных нейросетевых моделях, которые решают задачи регрессии, например таких, как оценка принадлежности к классу и определение значений параметров. Добавление полносвязного слоя является (как правило) простым способом изучения нелинейных комбинаций высокоуровневых объектов, представленных на выходе сверточного слоя. Полностью связанный слой изучает возможную нелинейность в этом пространстве. Сверточный слой и объединяющий слой (субдискретизации) могут быть точно настроены с учетом гиперпараметров.

Разработана модель (рис. 5) сверточной нейронной сети-классификатора, состоящая из следующих слоев: входной, представляющий двумерное изображение размером 60×120 пикселей. Каскад сверточных и субдискретизационных слоев с количеством фильтров 64, 32, 16 соответственно, активационная функция сверточных слоев ReLU. Выходной размер изображений после суб-

дискретизации показан на рисунке. Слой, меняющий размерность данных для связи со следующим одномерным полносвязным слоем.

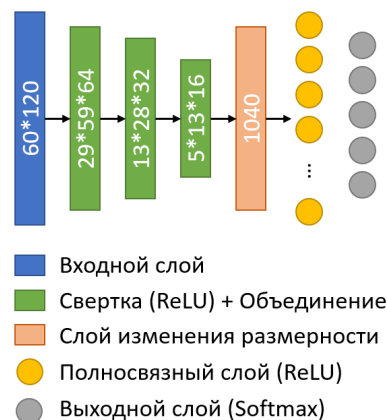


Рис. 5. Модель сверточной нейронной сети, применяемой для идентификации дефекта внутри клина

Fig. 5. A model of a convolutional neural network used to identify a defect inside a wedge

Полносвязный слой с активационной функцией ReLU, состоящий из 512 нейронов. Выходной слой с активационной функцией Softmax, содержащий 5 выходных нейронов. Два выходных нейрона показывают наличие или отсутствие дефекта в inspected области, один нейрон соответствует значению длины дефекта, другой нейрон соответствует значению ширины трещины и последний нейрон соответствует значению положения дефекта, относительно вершины клина. Построенная модель имеет 559 285 обучаемых параметров. В качестве функции потерь применяется функция среднеквадратичной ошибки.

Приемлемое качество работы нейронной сети достигается после 30 эпох обучения. Стабильность процесса обучения осуществляется посредством балансировки обучающего набора данных и применения специальных слоев Batchnormalization [15].

6. Результаты

Обученная нейросетевая модель была протестирована на тестовой выборке, состоящей из 2500 экземпляров, подготовленных на этапе формирования обучающего набора данных. На вход нейронной сети подавались данные спектрального сканирования, полученные в результате моделирования ультразвукового неразрушающего контроля. На выходе нейронной сети считывались значения, прогнозирующие наличие или отсутствие дефекта и его геометрические параметры.

Исследована точность определения параметра толщины дефекта нейросетевой моделью (рис. 6). При увеличении значений параметра $crack_{width}$ точность работы сети возрастает и стабилизируется на второй половине исследуемого диапазона. Средняя относительная ошибка определения этого параметра, на исследуемом

интервале, не превышает 5 % для угла раскрытия клина $\alpha = 60^\circ$ и 10 % для $\alpha = 120^\circ$. Предположительно, для более точной идентификации этого параметра необходимо рассмотреть модели ультразвукового контроля с более высокими частотами зондирующего сигнала и другой конфигурацией расположения иницирующих и принимающих датчиков.

Исследованы ошибки работы нейронной сети в зависимости от угла раскрытия клина (рис. 7). На рис. 7 приведены средние значения ошибки определения каждого параметра. Изменение параметра α в меньшей степени оказывает влияние на точность локализации дефекта и на точность определения его положения относительно вершины клина, по сравнению с другими параметрами дефекта. Наилучшее качество работы нейросетевой модели наблюдается при меньшем угле раскрытия клина α .




Рис. 6. Ошибка определения толщины дефекта при $\alpha = 60^\circ$ и $\alpha = 120^\circ$

Fig. 6. Error in determining the thickness of the defect at $\alpha = 60^\circ$ and $\alpha = 120^\circ$




Рис. 7. Средняя ошибка локализации и определения геометрических параметров дефекта в зависимости от угла раскрытия клина α

Fig. 7. Average error of localization and determination of the geometric parameters of the defect depending on the opening angle of the wedge α

Заключение

В данной работе авторами предложен подход идентификации трещиноподобного дефекта в клине с покрытием, в основе которого лежат классические методы ультразвукового неразрушающего контроля. Проведено моделирование распространения ультразвуковой волны в клине, разработана и обучена нейросетевая модель, способная проводить локализацию и определение геометрических параметров дефекта. Продемонстрированные результаты показывают возможность применения глубоких нейросетевых моделей в решении задач дефектоскопии. В отличие от предыдущих работ авторов [16; 17], применена более совершенная нейросетевая технология, позволяющая эффективно обрабатывать данные, полученные в результате моделирования процессов неразрушающего контроля. Уделено особое

внимание процессу моделирования высокочастотных колебаний и обработке их результатов.

Проведенные численные эксперименты показывают, что с увеличением угла раскрытия клина α увеличивается ошибка идентификации дефекта, но на определение положения дефекта относительно вершины клина оказывается незначительное влияние. Для дефектов толщиной более 1 мм достигается качество идентификации в пределах 95 %. Дефект был идентифицирован в 99 % случаев.

Данная работа показывает перспективы применения современных и эффективных методов машинного обучения в задачах дефектоскопии. Предложенный подход может быть задействован в реализации программно-аппаратных решений неразрушающего контроля, а также получить развитие в других областях науки и техники.

Библиографический список

1. Samanta S., Mandal A., Thingujam Jackson Singh. Application of ANN in Identifying Defects in Impacted Composite // *Procedia Materials Science*. – 2014. – Vol. 6. – P. 926–930.
2. van Sloun R.J.G., Cohen R., Eldar Y.C. Deep Learning in Ultrasound Imaging // *Proceedings of the IEEE*. – 2020. – Vol. 108, no. 1. – P. 11–29. DOI: 10.1109/JPROC.2019.2932116
3. Черпаков А.В., Акопьян В.А., Соловьев А.Н. Алгоритм многопараметрической идентификации дефектов стержневых конструкций [Электронный ресурс] // *Техническая акустика: электронный журнал*. – URL: <http://www.ejta.org>. – 2013. – № 1.
4. Bar H.N., Bhat M.R., Murthy C.R.L. Identification of failure modes in GFRP using PVDF sensors: ANN approach // *Composite Structures*. – 2004. – Vol. 65, iss. 2. – P. 231–237.
5. Use of an improved ANN model to predict collapse depth of thin and extremely thin layered rock strata during tunneling / Dong-Fang Chen, Xia-Ting Feng, Ding-Ping Xu, Quan Jiang, Cheng-Xiang Yang, Pin-Pin Yao // *Tunnelling and Underground Space Technology*. – 2016. – Vol. 51. – P. 372–386.
6. Ватульян А.О. Обратные задачи в механике деформируемого твёрдого тела. – М.: Физматлит, 2007. – С. 224.
7. Ermolov I., Aleshin N., Potapov A. Non-destructive testing. Acoustic methods of control. – Moscow: High School, 1991.
8. Willcox M.A. A Brief Description of NDT Techniques. – Toronto: NDT Equipment Limited, 2003. – 54 p.
9. Hesthaven J.S., Warburton T. Nodal Discontinuous Galerkin Methods: Algorithms, Analysis, and Applications. – Springer, 2008.
10. Soloviev A., Sobol B., Vasiliev P. (2019) Identification of Defects in Pavement Images Using Deep Convolutional Neural Networks // Parinov I., Chang S.H., Kim Y.H. (eds) *Advanced Materials*. Springer Proceedings in Physics. – 2009. – Vol 224.
11. Васильев П.В., Сеничев А.В. Применение нейросетевых технологий в задаче контроля поверхностных дефектов // *Известия высших учебных заведений. Северо-Кавказский регион. Технические науки*. – 2020. – № 1ю. – С. 33–40.
12. Cao Vu Dung, Le Duc Anh, Autonomous concrete crack detection using deep fully convolutional neural network // *Automation in Construction*. – 2019. – Vol. 99. – P. 52–58.
13. Deep Learning in Medical Ultrasound Analysis: A Review / Shengfeng Liu, Yi Wang, Xin Yang, Baiying Lei, Li Liu, Shawn Xiang Li, Dong Ni, Tianfu Wang // *Engineering*. – 2019. – Vol. 5, iss. 2. – P. 261–275.
14. Gradient-based learning applied to document recognition / Y. LeCun [et al.] // *Proceedings of the IEEE*. – 1998. – Vol. 86, iss. 11. – P. 2278–2324.
15. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift // *CoRR*. – 2015. – 9 p. – DOI: abs/1502.03167
16. Соловьев А.Н., Соболев Б.В., Васильев П.В. Ультразвуковая локация внутренних трещиноподобных дефектов в составном упругом цилиндре с применением аппарата искусственных нейронных сетей // *Дефектоскопия*. – 2016. – № 3. – С. 3–9.
17. Идентификация трещиноподобного дефекта и исследование концентрации напряжений в полосе с покрытием / Соболев Б.В., Соловьев А.Н., Рашидова Е.В., Васильев П.В. // *Вестник Пермского национального исследовательского политехнического университета. Механика*. – 2019. – № 4. – С. 165–174. DOI: 10.15593/per.mech/2019.4.16
18. Andraeus U., Baragatti P. Cracked beam identification by numerically analysing the nonlinear behaviour of the harmonically forced response // *Journal of Sound and Vibration*. – 2011. – Vol. 330(4). – P. 721–742.
19. Andraeus U., Casini P. Identification of multiple open and fatigue cracks in beam-like structures using wavelets on deflection signals // *Continuum Mechanics and Thermodynamics*. – 2016. – Vol. 28(1–2). – P. 361–378.
20. Placidi L., Misra A., Barchiesi E. Simulation results for damage with evolving microstructure and growing strain gradient moduli // *Continuum Mechanics and Thermodynamics*. – 2019. – Vol. 31(4). – P. 1143–1163.
21. Hemivariational continuum approach for granular solids with damage-induced anisotropy evolution / D. Timofeev, E. Barchiesi, A. Misra, L. Placidi // *Mathematics and Mechanics of Solids*. – 2021. – Vol. 26(5). – P. 738–770.
22. Cuomo M., Contrafatto L., Greco L. A variational model based on isogeometric interpolation for the analysis of cracked bodies // *International Journal of Engineering Science*. – 2014. – Vol. 80. – P. 173–188.
23. A continual model of a damaged medium used for analyzing fatigue life of polycrystalline structural alloys under thermal-

mechanical loading / I.A. Volkov, L.A. Igumnov, F. dell'Isola, S.Y. Litvinchuk, V.A. Eremeyev // *Continuum Mechanics and Thermodynamics*. – 2020. – Vol. 32(1). – P. 229–245.

24. Qualitative pivot damage analysis in aluminum printed pantographic sheets: numerics and experiments / M. Spagnuolo, K. Barcz, A. Pfaff, F. dell'Isola, P. Franciosi // *Mechanics Research Communications*. – 2017. – Vol. 83. – P. 47–52.

25. Berezovski A., Yildizdag M.E., Scerrato D. On the wave dispersion in microstructured solids // *Continuum Mechanics and Thermodynamics*. – 2020. – Vol. 32(3). – P. 569–588.

26. Turco E. Tools for the numerical solution of inverse problems in structural mechanics: review and research perspectives // *European Journal of Environmental and Civil Engineering*. – 2017. – Vol. 21(5). – P. 509–554.

27. Bilotta A., Morassi A., Turco E. Quasi-isospectral Sturm-Liouville operators and applications to system identification // *Procedia engineering*. – 2017. – Vol. 199. – P. 1050–1055.

References

1. S. Samanta, A. Mandal, Thingujam Jackson Singh. Application of ANN in Identifying Defects in Impacted Composite // *Procedia Materials Science*, Volume 6, 2014, pp. 926-930, ISSN 2211-8128.

2. R.J.G. van Sloun, R. Cohen and Y.C. Eldar, "Deep Learning in Ultrasound Imaging," in *Proceedings of the IEEE*, vol. 108, no. 1, pp. 11–29, Jan. 2020, doi: 10.1109/JPROC.2019.2932116.

3. A.V. Cherpakov, V.A. Akop'yan, A.N. Solov'yev. Algoritm mnogoparametricheskoy identifikatsii defektov sterzhnevnykh konstruksiy [Algorithm for multi-parameter identification of defects in bar structures] // *Tekhnicheskaya akustika* <http://www.ejta.org>. – №1, 2013.

4. H.N. Bar, M.R. Bhat, C.R.L. Murthy, Identification of failure modes in GFRP using PVDF sensors: ANN approach // *Composite Structures*, Volume 65, Issue 2, August 2004, Pages 231-237, ISSN 0263-8223.

5. Dong-Fang Chen, Xia-Ting Feng, Ding-Ping Xu, Quan Jiang, Cheng-Xiang Yang, Pin-Pin Yao. Use of an improved ANN model to predict collapse depth of thin and extremely thin layered rock strata during tunneling // *Tunnelling and Underground Space Technology*, Volume 51, January 2016, Pages 372-386, ISSN 0886-7798.

6. Vatul'yan A.O. Obratnye zadachi v mekhanike deformiruemogo tverdogo tela [Inverse problems in solid mechanics]. – M.: Fizmatlit, 2007, P. 224.

7. Ermolov I., Aleshin N., Potapov A. Non-destructive testing. Acoustic methods of control. – Moscow: High School, 1991.

8. Willcox M.A. A Brief Description of NDT Techniques / M.A. Willcox – Toronto: NDT Equipment Limited, 2003. – 54 p.

9. J.S. Hesthaven and T. Warburton, *Nodal Discontinuous Galerkin Methods: Algorithms, Analysis, and Applications*, Springer, 2008.

10. Soloviev A., Sobol B., Vasiliev P. (2019) Identification of Defects in Pavement Images Using Deep Convolutional Neural Networks. In: Parinov I., Chang SH., Kim YH. (eds) *Advanced Materials*. Springer Proceedings in Physics, vol 224. Springer, Cham.

11. Vasil'yev P.V., Senichev A.V. Primenenie neyrosetevykh tekhnologiy v zadache kontrolya poverkhnostnykh defektov [Application of neural network technologies in the problem of surface defects control] // *Scientific-educational and applied journal university news North-Caucasian region. Technical sciences series*. 2020; 1:33–40.

28. A novel phase-field approach to brittle damage mechanics of gradient metamaterials combining action formalism and history variable / B.E. Abali, A. Klunker, E. Barchiesi, L. Placidi // *ZAMM-Zeitschrift für Angewandte Mathematik und Mechanik*. – 2021. – e202000289.

29. Глушков С.В., Скворцов Ю.В., Перов С.Н. Сравнение результатов решения задачи механики разрушения для трубы с несквозной трещиной // *Вестник Пермского национального исследовательского политехнического университета. Механика*. – 2014. – № 3. – С. 36–49. DOI: 10.15593/perm.mech/2014.3.03

30. Моделирование технологических дефектов и оценка их влияния на статическую прочность композитных фланцев / А.Н. Аношкин, В.Ю. Зуйко, В.М. Осокин [и др.] // *Вестник Пермского национального исследовательского политехнического университета. Механика*. – 2016. – № 2. – С. 5–21. DOI: 10.15593/perm.mech/2016.2.01

12. Cao Vu Dung, Le DucAnh, Autonomous concrete crack detection using deep fully convolutional neural network, *Automation in Construction*, Volume 99, 2019, Pages 52-58.

13. Shengfeng Liu, Yi Wang, Xin Yang, Baiying Lei, Li Liu, Shawn Xiang Li, Dong Ni, Tianfu Wang, Deep Learning in Medical Ultrasound Analysis: A Review, *Engineering*, Volume 5, Issue 2, 2019, Pages 261-275.

14. Gradient-based learning applied to document recognition / Y. LeCun [et al.] // *Proceedings of the IEEE*. – 1998. – Vol. 86, iss. 11. – pp. 2278–2324.

15. Ioffe, S. Batch normalization: Accelerating deep network training by reducing internal covariate shift / S. Ioffe, C. Szegedy // *CoRR*. – 2015. – 9 p. – DOI: abs/1502.03167.

16. Solov'yev A.N., Sobol' B.V., Vasil'yev P.V. Ul'trazvukovaya lokatsiya vnutrennikh treshchinopodobnykh defektov v sostavnom uprugom tsilindre s primeneniem apparata iskusstvennykh neyronnykh setey [Ultrasonic location of internal crack-like defects in a composite elastic cylinder using the apparatus of artificial neural networks] // *Russian Journal of Nondestructive Testing*. – 2016. – №3. – pp. 3–9.

17. Sobol' B.V., Solov'yev A.N., Rashidova E.V., Vasil'yev P.V. Identifikatsiya treshchinopodobnogo defekta i issledovanie kontsentratsii napryazheniy v polose s pokrytiem [Identification of a crack-like defect and study of stress concentration in a coated strip] // *PNRPU Mechanics Bulletin*. – 2019. – № 4. – pp. 165–174. DOI: 10.15593/perm.mech/2019.4.16.

18. Andreas, U., & Baragatti, P. (2011). Cracked beam identification by numerically analysing the nonlinear behaviour of the harmonically forced response. *Journal of Sound and Vibration*, 330(4), 721–742.

19. Andreas, U., & Casini, P. (2016). Identification of multiple open and fatigue cracks in beam-like structures using wavelets on deflection signals. *Continuum Mechanics and Thermodynamics*, 28(1–2), 361–378.

20. Placidi, L., Misra, A., & Barchiesi, E. (2019). Simulation results for damage with evolving microstructure and growing strain gradient moduli. *Continuum Mechanics and Thermodynamics*, 31(4), 1143–1163.

21. Timofeev, D., Barchiesi, E., Misra, A., & Placidi, L. (2021). Hemivariational continuum approach for granular solids with damage-induced anisotropy evolution. *Mathematics and Mechanics of Solids*, 26(5), 738–770.

22. Cuomo, M., Contrafatto, L., & Greco, L. (2014). A variational model based on isogeometric interpolation for the analysis of cracked bodies. *International Journal of Engineering Science*, 80, 173–188.
23. Volkov, I.A., Igumnov, L.A., dell'Isola, F., Litvinchuk, S.Y., & Eremeyev, V.A. (2020). A continual model of a damaged medium used for analyzing fatigue life of polycrystalline structural alloys under thermal–mechanical loading. *Continuum Mechanics and Thermodynamics*, 32(1), 229–245.
24. Spagnuolo, M., Barcz, K., Pfaff, A., dell'Isola, F., & Franciosi, P. (2017). Qualitative pivot damage analysis in aluminum printed pantographic sheets: numerics and experiments. *Mechanics Research Communications*, 83, 47–52.
25. Berezovski, A., Yildizdag, M. E., & Scerrato, D. (2020). On the wave dispersion in microstructured solids. *Continuum Mechanics and Thermodynamics*, 32(3), 569–588.
26. Turco, E. (2017). Tools for the numerical solution of inverse problems in structural mechanics: review and research perspectives. *European Journal of Environmental and Civil Engineering*, 21(5), 509–554.
27. Bilotta, A., Morassi, A., & Turco, E. (2017). Quasi-isospectral Sturm-Liouville operators and applications to system identification. *Procedia engineering*, 199, 1050–1055.
28. Abali, B. E., Klunker, A., Barchiesi, E., & Placidi, L. (2021). A novel phase-field approach to brittle damage mechanics of gradient metamaterials combining action formalism and history variable. *ZAMM-Zeitschrift für Angewandte Mathematik und Mechanik*, e202000289.
29. Glushkov S.V., Skvortsov Yu.V., Perov S.N. Sravnenie rezultatov resheniya zadachi mekhaniki razrusheniya dlya trub s neskvoznoy treshchinoy [Comparison of the results of solving the problem of fracture mechanics for a pipe with a non-through crack] // PNRPU Mechanics Bulletin. – 2014. – № 3. – pp. 36–49. doi: 10.15593/perm.mech/2014.3.03.
30. Anoshkin A.N., Zuyko V.Yu., Osokin V.M. Modelirovanie tekhnologicheskikh defektov i otsenka ikh vliyaniya na staticheskuyu prochnost' kompozitnykh flantsev [Modeling of technological defects and evaluation of their influence on the static strength of composite flanges] // PNRPU Mechanics Bulletin. – 2016. – № 2. – pp. 5–21. doi: 10.15593/perm.mech/2016.2.01.

Финансирование. Работа выполнена при финансовой поддержке РФФИ (гранты №20-31-90026, №19-38-90248).

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Вклад авторов равноценен.

Financing. The work was supported by the Russian Foundation for Basic Research (grants no. 20-31-90026, no. 19-38-90248).

Conflict of interest. The authors declare no conflict of interest.

The contribution of the authors is equivalent.