

# МЕХАНИКА MECHANICS



УДК 004.85

<https://doi.org/10.23947/2687-1653-2021-21-2-143-153>

## Визуализация внутренних дефектов с применением глубокой генеративной нейросетевой модели и ультразвукового неразрушающего контроля



П. В. Васильев<sup>1</sup>, А. В. Сеничев<sup>1</sup>, И. Джорджо<sup>2</sup>

<sup>1</sup>ФГБОУ ВО «Донской государственный технический университет» (г. Ростов-на-Дону, Российская Федерация)

<sup>2</sup>Университет Л'Акуилы, (г. Л'Акуила, Италия)

**Введение.** Развитие методов машинного обучения дало новый толчок в области решения обратных задач механики. Многие работы показывают, что наряду с хорошо зарекомендовавшими себя техниками ультразвукового, магнитного, теплового неразрушающего контроля, применяются новейшие методы, в том числе на основе нейросетевых моделей. В данной работе продемонстрирован потенциал применения методов машинного обучения в задаче двумерной ультразвуковой визуализации.

**Материалы и методы.** Авторами построена тестовая модель акустического ультразвукового неразрушающего контроля, в которой происходит зондирование исследуемого объекта с последующей фиксацией сигналов-откликов. Распространение ультразвуковой волны моделируется методом конечных разностей во временной области. На вход сверточной нейронной сети подается ультразвуковой сигнал, полученный во внутренних точках объекта контроля. На выходе генерируется изображение, визуализирующее внутренний дефект.

**Результаты исследования.** В ходе проведенного комплекса численных экспериментов был создан набор данных, предназначенный для обучения сверточной нейронной сети. Представлена сверточная нейросетевая модель, разработанная для решения задачи визуализации внутренних дефектов на основе методов ультразвукового неразрушающего контроля. Данная модель имеет небольшой размер, который составляет 3,8 миллиона параметров. Её простота и универсальность обеспечивают высокую скорость обучения и широкие возможности применения в классе смежных задач. Представленные результаты показывают высокую степень информативности ультразвукового отклика и его соответствия реальной форме внутреннего дефекта, находящегося внутри объекта контроля. Исследовано влияние геометрических параметров дефектов на точность работы нейросетевой модели.

**Обсуждение и заключение.** На основе полученных результатов выявлено, что предлагаемая модель показывает высокую точность работы ( $F1 > 0,95$ ) в случаях, когда длина волны зондирующего импульса в десятки раз меньше размера дефекта. Авторы полагают, что комбинация предложенных методов в данном подходе может послужить хорошей отправной точкой для будущих исследований в области решения задач дефектоскопии и обратных задач в целом.

**Ключевые слова:** ультразвуковой неразрушающий контроль, дефект, ультразвуковой отклик, сверточные нейронные сети.

**Для цитирования:** Васильев, П. В. Визуализация внутренних дефектов с применением глубокой генеративной нейросетевой модели и ультразвукового неразрушающего контроля / П. В. Васильев, А. В. Сеничев, И. Джорджо // Advanced Engineering Research. — 2021. — Т. 21, № 2. — С. 143–153. <https://doi.org/10.23947/2687-1653-2021-21-2-143-153>

**Финансирование:** Работа выполнена при финансовой поддержке РФФИ в рамках проектов №19-08-00074А и №20-31-90026

© Васильев П. В., Сеничев А. В., Джорджо И., 2021



## Visualization of internal defects using a deep generative neural network model and ultrasonic nondestructive testing

P. V. Vasiliev<sup>1</sup>, A. V. Senichev<sup>1</sup>, I. Giorgio<sup>2</sup>

<sup>1</sup> Don State Technical University (Rostov-on-Don, Russian Federation)

<sup>2</sup> Università degli Studi dell'Aquila (L'Aquila, Italy)

**Introduction.** The development of machine learning methods has given a new impulse to solving inverse problems in mechanics. Many studies show that along with well-behaved techniques of ultrasonic, magnetic, and thermal nondestructive testing, the latest methods are used, including those based on neural network models. In this paper, we demonstrate the potential application of machine learning methods in the problem of two-dimensional ultrasound imaging.

**Materials and Methods.** We have developed an experimental model of acoustic ultrasonic non-destructive testing, in which the probing of the object under study takes place, followed by the recording of the response signals. The propagation of an ultrasonic wave is modeled by the finite difference method in the time domain. An ultrasonic signal received at the internal points of the control object is applied to the input of the convolutional neural network. At the output, an image that visualizes the internal defect is generated.

**Results.** In the course of the performed complex of numerical experiments, a data set was generated for training a convolutional neural network. A convolutional neural network model, which is developed to solve the problem of visualizing internal defects based on methods of ultrasonic nondestructive testing, is presented. This model has a small size, which is 3.8 million parameters. Its simplicity and versatility provide high-speed learning and a wide range of applications in the class of related problems. The presented results show a high degree of information content of the ultrasonic response and its correspondence to the real form of an internal defect located inside the test object. The effect of geometric parameters of defects on the accuracy of the neural network model is investigated.

**Discussion and Conclusion.** The results obtained have established that the proposed model shows a high operating accuracy ( $F1 > 0.95$ ) in cases when the wavelength of the probe pulse is tens of times less than the size of the defect. We believe that the combination of the proposed methods in this approach can serve as a good starting point for future research in solving flaw detection problems and inverse problems in general.

**Keywords:** ultrasonic nondestructive testing, defect, ultrasonic response, convolutional neural networks.

**Funding information:** the research is done with the financial support from RFFI within the framework of projects nos. 19-08-00074A and 20-31-90026.

**For citation:** P. V. Vasiliev, A. V. Senichev, I. Giorgio. Visualization of internal defects using a deep generative neural network model and ultrasonic nondestructive testing. Advanced Engineering Research, 2021, vol. 21, no. 2, pp. 143–153. <https://doi.org/10.23947/2687-1653-2021-21-2-143-153>

**Введение.** В данной работе авторы исследуют возможности применения нейросетевых технологий в решении обратных задач механики, в частности, в задаче двумерной визуализации внутренних дефектов. Данные методы получили широкое распространение в медицине, гражданской инженерии, неразрушающем контроле и других областях.

Так в работе [1] была разработана система для обнаружения трещин в стальных конструкциях и оценки их глубины на основе двумерных изображений. Цель работы заключается в том, чтобы разработать доступную и удобную для пользователя систему контроля взамен дорогостоящих измерительных устройств. Была предложена стратегия обучения и несколько нейросетевых структур. В процессе обучения средняя интенсивность профилей двумерных стальных трещин подавалась в нейронную сеть вместе с максимальной глубиной стальных трещин, измеренной с помощью лазерного микроскопа. Средняя ошибка работы нейронной сети составляет 18 % на тестовой выборке, что лучше, в сравнении с предыдущими работами авторов. Улучшение качества определения глубины дефектов достигается за счет применения новой стратегии обучения и инструмента оценки глубины трещин.

В работе [2] были предложены некоторые методы глубокого обучения для выявления дефектов в изображениях, полученных с помощью неразрушающего контроля. Для применения таких подходов нужны размеченные данные изображений с дефектами. Авторы предлагают модель обучения с глубоким переносом для извлечения признаков внутренних дефектов на рентгеновских изображениях композитных материалов авиационной отрасли. Исследовали метод автоматического обнаружения дефектов включения на рентгеновских изображениях, используя предложенную модель. Экспериментальные результаты показывают, что модель

может достичь точности классификации 96 % (по метрике F1) с удовлетворительными результатами обнаружения.

В работе [3] предлагается метод реконструкции и визуализации внутренних дефектов в виде трехмерного изображения с использованием экономичной и быстрой технологии импульсной термографии. Представлен новый метод быстрой оценки глубины и толщины дефекта одновременно на основе одной односторонней проверки. Осуществимость и эффективность предложенного решения демонстрируется путем осмотра композитного и стального образцов с полужакрытыми воздушными зазорами. Для композитного образца этот метод может обеспечить сравнительно низкую, в пределах 10%, среднюю относительную ошибку оцененного общего объема 3D-дефектов.

В работе [4] рассматриваются основные причины отказов двигателей твердотопливных ракет. Отслаивания на границе раздела пропеллент/гильза/изоляция являются критическим моментом для целостности двигателей. Современные решения обычно ограничиваются методами оценки целостности конструкции ракетных двигателей и визуального контроля их компонентов.

В данной статье представлен улучшенный алгоритм обнаружения дефектов поверхности гильзы, которые могут нарушить связь между твердым ракетным топливом и изоляцией. Использование локальных двоичных шаблонов (LBP) обеспечивает структурный и статистический подход к анализу текстуры образцов изображений двигателя. Нейронная сеть анализирует образцы изображений двигателя и классифицирует каждый пиксель на один из трех классов: исправный, посторонний объект и дефект. Было проведено несколько тестов с варьированием различных параметров для того, чтобы найти оптимальную конфигурацию нейронной сети. В результате для соответствующих классов была достигнута лучшая точность классификации: 99,08 %, 90,66 % и 99,48 %.

В работе [5] представлен краткий обзор алгоритмов искусственного интеллекта, применимых к неразрушающему контролю. Он ориентирован на два метода: искусственные нейронные сети и нечеткую логику. Приведены избранные примеры применения этих методов в цифровой рентгенографии и вихретоковом методе.

В работе [6] автор исследует потенциал методов глубокого обучения для электромагнитной инверсии. Этот подход не требует расчета градиента и сразу после обучения сети дает результаты. Глубокие нейронные сети, основанные на полностью сверточной архитектуре, обучаются на больших наборах синтетических данных, полученных с помощью полного трехмерного моделирования. Эффективность метода демонстрируется на моделях, имеющих большое практическое значение, представляющих сценарий мониторинга электромагнитного поля скопления углекислого газа под землей с контролируемым источником на поверхности.

Ранее авторами были исследованы некоторые задачи, объединяющие современные методы глубокого машинного обучения и хорошо зарекомендовавшие себя классические подходы идентификации дефектов [7–9].

В этой работе в качестве пилотного исследования рассматривается нейросетевая модель, на основе которой проводится двумерная акустическая визуализация внутренних дефектов. Построена пробная модель неразрушающего ультразвукового контроля, на основе которой проводится комплекс численных экспериментов. Результаты этих экспериментов служат основой для обучения нейронной сети и её валидации.

**Материалы и методы.** Предлагается метод идентификации и визуализации внутренних дефектов, основанный на ультразвуковом неразрушающем контроле и генеративной нейросетевой модели. На вход сверточной нейронной сети подается ультразвуковой сигнал, полученный во внутренних точках объекта контроля. На выходе генерируется изображение, визуализирующее внутренний дефект. В качестве объекта для демонстрации возможности и перспектив развития данного метода исследования была выбрана внутренняя часть стальной пластины. Внутри полосы может находиться дефект, обозначенный отсутствием материала. Форма, размер и ориентация дефекта могут быть различными. Подход заключается в проведении ряда численных экспериментов, на основе которых возможно обучить глубокую нейросетевую модель. Путем варьирования геометрических параметров дефекта и моделирования распространения акустической ультразвуковой волны для каждого случая создается обучающий набор. На основе собранных данных возможно построить оптимальную структуру нейросетевой модели и обучить её.

**Метод конечных разностей во временной области.** Данный метод был предложен Кейном Йи [10] и относится к классу сеточных методов решения дифференциальных уравнений. В настоящий момент данный метод нашел широкое применение — от задач геофизики до решения задач в оптическом диапазоне, а также в ряде задач моделирования сред как с дисперсными, так и нелинейными свойствами. Метод конечных разностей во временной области в акустической постановке применяется для проведения моделирования распространения звука в текучих средах, таких как воздух или жидкости. Однако в некоторых случаях для упрощения решения

задач этот метод возможно применять и в упругих средах. В рамках данного метода скорость и акустическое давление частиц моделируемого объекта располагаются поочередно в узлах сетки. Затем их значения рассчитываются последовательно, что позволяет в течение времени провести расчет распространения звукового поля.

Основным уравнением данной акустической модели в плоской постановке является следующее:

$$\frac{\partial p}{\partial t} = -k \left( \frac{\partial v_x}{\partial x} + \frac{\partial v_y}{\partial y} \right) \frac{\partial v_x}{\partial t} = -\frac{1}{\rho} \frac{\partial p}{\partial x}, \quad \frac{\partial v_y}{\partial t} = -\frac{1}{\rho} \frac{\partial p}{\partial y},$$

где  $p$  — это давление,  $v$  — скорость,  $k$  — объемный модуль упругости,  $\rho$  — плотность среды.

Величины пространственного  $\Delta x$  и временного  $\Delta t$  разрешений влияют на то, как точно и устойчиво будет рассчитано акустическое поле. Эти величины не могут быть установлены независимо и должны выбираться с учетом друг друга.

Прежде всего, нужно установить значение  $\Delta x$  исходя из соображений точности. При этом точность и устойчивость независимы друг от друга. Моделирование может проходить устойчиво, но с низкой точностью в случае грубой сетки. Точность решения данным методом зависит от многих факторов. В данном случае величины  $\Delta x$  и  $\Delta t$  могут быть установлены как:

$$\Delta x = \frac{\lambda_{\min}}{10} \sim \frac{\lambda_{\min}}{20}, \Delta t \leq \frac{1}{\sqrt{d}} \frac{\Delta x}{c_{\max}},$$

где,  $\lambda_{\min}$  — длина волны, которая распространяется в моделируемом пространстве,  $c_{\max}$  — наибольшее значение скорости звука в моделируемой среде,  $d$  — значение размерности, для плоской задачи  $d = 2$ .

Построена эталонная модель распространения акустической ультразвуковой волны в пакете COMSOL. Соответственно решение осуществляется методом конечных элементов и методом конечных разностей. Ниже на рис. 1 показаны нормированные значения акустического давления, считанные в точке модели. Модель представляет собой квадратную область, выполненную из стали с отверстием внутри. Небольшие отличия в форме сигнала обусловлены способом задания источника ультразвуковых колебаний. В случае FEM — точки на окружности, в случае FDTD — точка в узле сетки.

Сравнение распространения ультразвуковой волны




Рис. 1. Форма прямого и отраженного ультразвукового сигнала. Штриховой линией показаны значения, рассчитанные с помощью метода FDTD, сплошной — с помощью метода конечных элементов

Так как сетка имеет ограниченный размер, нет возможности проводить моделирование распространения акустических волн за пределами этой области, поэтому применяются специальные граничные условия. Применяются поглощающие слои Мура или идеально согласованные слои (Perfect Matched Layers, PML [11]). Данные условия существенно снижают отражающую способность границ области, в которой происходит моделирование и создают эффект прохождения волн за границы этой области.

**Модель неразрушающего контроля.** В качестве пробной модели неразрушающего контроля выбрана внутренняя часть стальной пластины, содержащая дефект. Размер исследуемой области  $20 \times 20$  мм. Дефекты представлены в виде геометрических фигур: эллипса, треугольника, квадрата, прямоугольника. Физические параметры дефектов варьируются относительно моделируемой области в следующих пределах: положение

дефекта — от 0,3 до 0,7; размер дефекта — от 0,1 до 0,35; угол наклона дефекта — от  $0^\circ$  до  $360^\circ$ . Входной сигнал состоит из фиксированного количества дискретных значений, заданных временем эксперимента. Время эксперимента выбрано таким образом, чтобы зондирующий импульс, отразившись от дефекта, смог преодолеть расстояние и вернуться в точку инициирующего сигнала. Частота зондирующего импульса составляет 10 МГц.

На рис. 2 показана схема проводимого численного эксперимента. Дефект расположен в центре зондируемой области с заданным смещением. Источник ультразвукового сигнала показан красной меткой. Точки считывания сигнала показаны зелеными метками. Прерывистой линией показаны границы дефекта.




Рис. 2. Схема одного из проведенных численных экспериментов

Модель позволяет оценить возможность применения предлагаемого метода и дальнейшие перспективы его использования. Ультразвуковой сигнал задается во внутренней точке объекта контроля. Точки, имитирующие датчики, считывающие проходящий и отраженный сигналы, расположены по разные стороны от предполагаемого места локации дефекта. Такая виртуальная модель позволяет оценить влияние некоторых параметров эксперимента на качество работы нейронной сети. На основе реализованного подхода возможно построение моделей, отражающих реальные технические задачи. На рис. 3 показано распространение и отражение ультразвуковой волны от дефекта внутри исследуемой области.

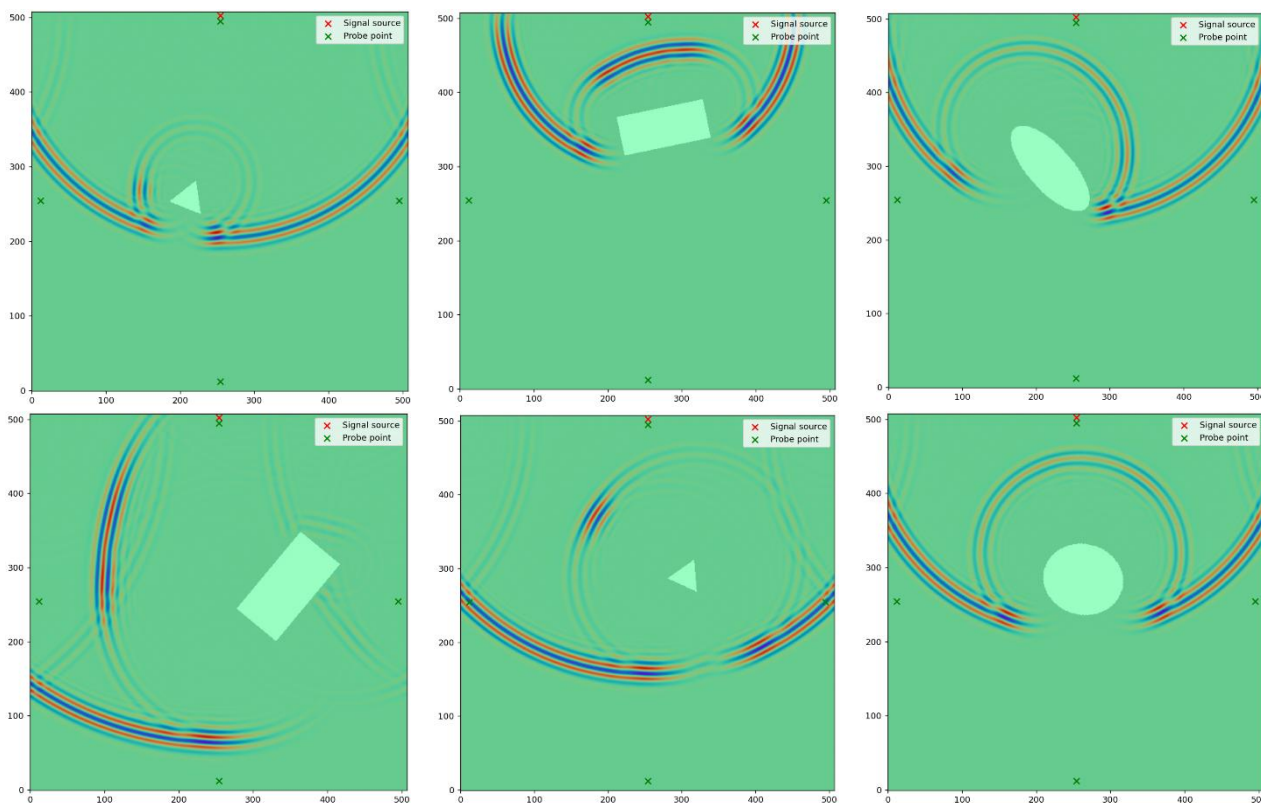


Рис. 3. Распространение ультразвуковой волны и её отражение от различных дефектов



**Нейросетевая модель.** Сверточные нейронные сети (СНН) — это особый нейросетевой инструмент для обработки данных, имеющих сеточную структуру (двумерные изображения, одномерные сигналы) [12]. На данный момент это один из самых бурно развивающихся и перспективных инструментов глубокого обучения [13–15].

Они также оказались чрезвычайно успешными в других практических применениях, включая видеоанализ и обработку данных временных рядов (последнюю можно рассматривать как одномерную сетку, обрабатывающую образцы через фиксированные промежутки времени). СНН — это ключевой пример успешного применения идей, полученных при изучении мозга (в некоторой степени вдохновленных структурой зрительной системы млекопитающих). Как видно из названия, сверточная сеть использует операцию свертки, то есть фильтрацию с помощью карты признаков или ядра, вместо общего умножения матриц в полносвязных сетях (фактически, свертка соответствует произведению на разреженную матрицу).

Для решения задачи визуализации дефектов авторы предлагают использовать сверточную нейросетевую модель. На вход модели подается ультразвуковой сигнал, полученный во внутренних точках объекта контроля. На выходе генерируется изображение с предполагаемой формой, положением и ориентацией дефекта. Входной сигнал проходит слои одномерной свертки (Conv1D) и субдискретизации (MaxPooling). После чего данные попадают на полносвязный слой. Эта сверточная часть сети служит для выделения признаков из сигнала, на основе которых будет происходить визуализация дефекта. Вторая часть сети генерирует изображения, соответствующие форме, положению и ориентации дефекта. Данные из полносвязного слоя проходят трансформацию и отображаются на двумерный слой. Из этого слоя, пройдя через ряд обучаемых разверточных слоев (Conv2D Transpose), получается финальное изображение, которое визуализирует внутренний дефект. Модель сверточной нейронной сети, используемой в данной работе, представлена на рис. 4. Под каждым слоем показан размер входных данных и количество ядер свертки. Например,  $504 \times 32$  означает, что на этот слой подается 504 значения и к ним применяются 32 различных сверточных фильтра.

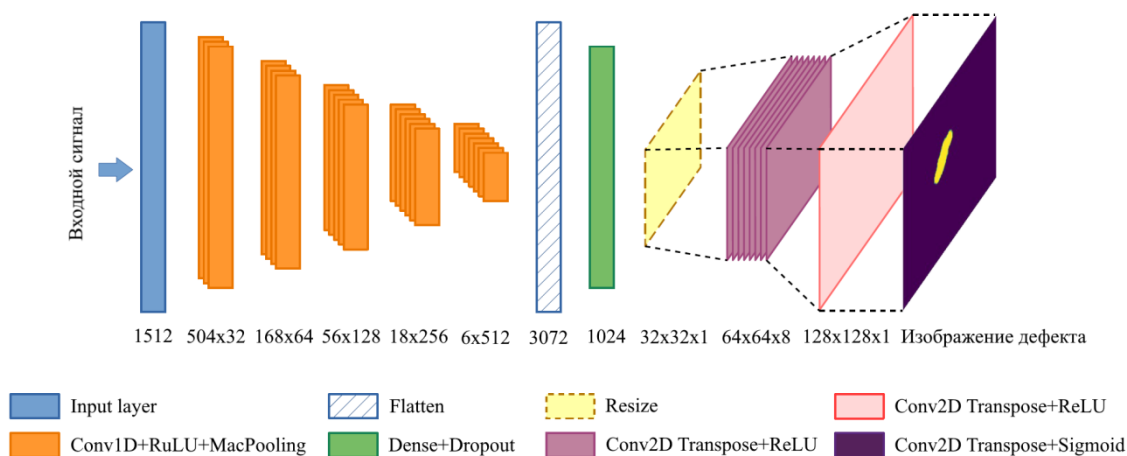


Рис. 4. Схема архитектуры сверточной нейронной сети

**Обучение и валидация модели.** В рамках комплекса численных экспериментов было решено 17 000 задач с различными геометрическими параметрами дефекта. Для обучения использовались 14 000 экземпляров, 2 000 для тестирования и 1 000 для валидации.

При обучении показателем успешности является ошибка обучения. При проверке работы нейросетевой модели на тестовых данных, которые ранее были недоступны для сети, определяется её способность к обобщению. В процессе тестирования вычисляется ошибка тестирования. Таким образом, о производительности модели можно судить по двум ключевым факторам. Первый заключается в достижении наименьшей ошибки обучения. Второй — в уменьшении разницы между ошибкой обучения и тестирования.

В области машинного обучения существует несколько техник регуляризации. При обучении нейронных сетей одной из проблем является переобучение. Оно выражается в потере способности к обобщению в процессе обучения. Одним из наиболее популярных приемов его предотвращения является

применение регуляризации Тихонова (ridge regression или L2), в машинном обучении также называемая weight decay.

Одним из важных этапов обучения нейросетевой модели является начальная инициализация весов. Одним из популярных на данный момент методов инициализации является метод Xavier [16]. Этот метод упрощает прохождение сигнала в случае прямого и обратного распространения ошибки через слои сети. Метод подходит как для линейной, так и для сигмоидной активационных функций (её ненасыщенный участок имеет линейный характер).

Метод батч-нормализации (batch-normalization) предложен Ioffe и Szegedy [17]. Во время распространения сигнала по слоям сети может произойти его искажение как по матожиданию, так и по дисперсии (этот эффект известен как внутренний ковариационный сдвиг). Это может вызвать некоторое несоответствие между градиентами на различных уровнях сети.

Применяются общие подходы регуляризации при обучении нейросетевой модели. Наиболее простыми из них являются ранняя остановка (early stopping) и применение техники dropout. Эти методы обеспечивают более устойчивое обучение модели. В связи с достаточным размером обучающей выборки и сложностью проведения аугментации данных, последняя не выполняется.

В рамках данной работы балансировка набора данных не проводится. Ниже на рис. 5 можно видеть распределение дефектов в зависимости от их размера.




Рис. 5. Количество дефектов в зависимости от их размера в обучающем наборе данных

Обучение нейронной сети — это эквивалент решения задачи оптимизации, в которой происходит поиск минимума функции потерь. Эта функция показывает, насколько хорошо модель выполняет свою задачу. Правильный выбор функции потерь оказывает большое влияние на результат обучения. В данной задаче оптимальным выбором будет применение коэффициента схожести Жаккара (Intersection over Union). Данный показатель часто применяется в задачах компьютерного зрения и определяется как:

$$IoU = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|}$$

Соответственно, функция потерь определяется как  $1 - IoU$  и отражает различие между двумя экземплярами. Также она известна как расстояние Жаккара. Также для оценки качества работы нейросетевой модели применяется метрика  $F1 = \frac{2 \times IoU}{IoU + 1}$ , которая отражает гармоническое среднее между полнотой и точностью.

Для обучения используется один из самых популярных алгоритмов Adam [18]. Авторы применили открытую библиотеку TensorFlow и фреймворк Keras. Данные программные решения содержат большинство современных алгоритмов и моделей. Для достижения приемлемого уровня работы модели потребовалось 200 эпох обучения.

**Результаты исследования.** Применение нейросетевого подхода к решению обратных задач давно зарекомендовало себя [8, 19–20]. С развитием машинного обучения и появлением новых техник становятся доступны новые методы интерпретации данных и появляются новые возможности решения классических задач механики и дефектоскопии.

Авторы представили сверточную нейросетевую модель, разработанную для решения задачи визуализации внутренних дефектов на основе методов ультразвукового неразрушающего контроля. Данная модель имеет небольшой размер, который составляет 3,8 миллиона параметров. Её простота и универсальность обеспечивают высокую скорость обучения и широкие возможности применения в классе смежных задач. Авторы используют FDTD метод симуляции распространения ультразвуковых волн и приводят сравнение его результатов с результатами конечноэлементного метода. Выбор данного метода позволил многократно повысить скорость расчета моделей, по сравнению с задачами, решаемыми ранее [21].

Точность визуализации дефектов




Рис. 6. Количество идентифицируемых дефектов с определенной точностью

После обучения нейросетевой модели происходит валидация её работы на соответствующем наборе данных. Для общей оценки производительности модели применяется метрика F1, описанная выше. В целом точность работы предложенного метода находится на высоком уровне. Среднее значение показателя F1 для всей валидационной выборки составляет 91 %. На рис. 6 видно, что часть дефектов не была идентифицирована нейросетевой моделью.

На рис. 7 можно видеть, как точно нейросетевая модель проводит визуализацию дефектов различного размера. Визуализация проводилась на валидационном наборе данных.



Влияние размера дефекта на точность визуализации




Рис. 7. Зависимость точности визуализации от размера дефекта

Ниже на рис. 8 продемонстрированы результаты работы нейросетевой модели. На приведенных изображениях видны положение, границы и форма предполагаемого дефекта.




Рис. 8. Результат визуализации дефекта нейронной сетью: *а* — оригинальный дефект, *б* — визуализация дефекта на основе ультразвукового отклика, *в* — различие между оригинальным и восстановленным образцами

**Обсуждения и заключение.** В данной работе продемонстрирован потенциал применения методов машинного обучения в задаче ультразвуковой визуализации. Авторы построили тестовую модель неразрушающего контроля. На основе этой модели подготавливается набор данных, предназначенный для обучения нейронной сети. Предложена модель сверточной нейронной сети, позволяющая предугадать форму, положение и ориентацию дефектов внутри твердого тела. Представленные результаты показывают высокую степень информативности ультразвукового отклика и его соответствия реальной форме внутреннего дефекта.

На основе полученных результатов выявлено, что предлагаемая модель показывает высокую точность работы ( $F1 > 0,95$ ) в случаях, когда длина волны зондирующего импульса в десятки раз меньше размера дефекта.

Авторы полагают, что комбинация предложенных методов в данном подходе может послужить хорошей отправной точкой для будущих исследований в области решения задач дефектоскопии и обратных задач в целом.

### Библиографический список

1. Steel crack depth estimation based on 2D images using artificial neural networks / Yasser S. Mohamed, Hesham M. Shehata, Mohamed Abdellatif [et al.] // Alexandria Engineering Journal. — 2019. — Vol. 58 (4). — P. 1167—1174. <https://doi.org/10.1016/j.aej.2019.10.001>
2. A deep transfer learning model for inclusion defect detection of aeronautics composite materials / Yanfeng Gong, Hongliang Shao, Jun Luo, Zhixue Li // Composite Structures. — 2020. — Vol. 252. — 112681. <https://doi.org/10.1016/j.compstruct.2020.112681>
3. Three-dimensional subsurface defect shape reconstruction and visualisation by pulsed thermography / Adisorn Sirikham, Yifan Zhao, Haochen Liu [et al.] // Infrared Physics & Technology. — 2020. — Vol. 104. — 103151. <https://doi.org/10.1016/j.infrared.2019.103151>
4. Luiz Felipe Simões Hoffmann. Detection of liner surface defects in solid rocket motors using multilayer perceptron neural networks / Luiz Felipe Simões Hoffmann, Francisco Carlos Parquet Bizarria, José Walter Parquet Bizarria // Polymer Testing. — 2020. — Vol. 88. — 106559. <https://doi.org/10.1016/j.polymertesting.2020.106559>
5. Artificial Neural Networks and Fuzzy Logic in Nondestructive Evaluation / Ryszard Sikora, Piotr Baniukiewicz, Tomasz Chady [et al.] // Studies in Applied Electromagnetics and Mechanics. — 2014. — Vol. 38. — P. 137–151. <https://doi.org/10.3233/978-1-61499-354-4-137>
6. Puzyrev, V. Deep learning electromagnetic inversion with convolutional neural networks / Vladimir Puzyrev // Geophysical Journal International. — 2019. — Vol. 218 (2). — P. 817–832. <https://doi.org/10.1093/gji/ggz204>
7. Soloviev, A. N. Ultrasonic and Magnetic Flow Inspection Methods of Identification of Cracks in the Pipe Coupled with Artificial Neural Networks / A.N. Soloviev, B.V. Sobol, P. V. Vasiliev // Advanced Materials. Springer Proceedings in Physics. — 2017. — Vol. 193. — P. 381–395.
8. Generative Artificial Neural Network Model for Visualization of Internal Defects of Structural Elements / A. Soloviev, B. Sobol, P. Vasiliev, A. Senichev // Advanced Materials. Springer Proceedings in Materials. — 2020. — Vol. 6. — P. 587–595. [https://doi.org/10.1007/978-3-030-45120-2\\_48](https://doi.org/10.1007/978-3-030-45120-2_48)
9. Identification of crack-like defect and investigation of stress concentration in coated bar / B.V. Sobol, A.N. Soloviev, E. V. Rashidova P. V. Vasiliev // PNRPU Mechanics Bulletin. — 2019. — No. 4. — P. 165–174. <https://doi.org/10.15593/perm.mech/2019.4.16>
10. Yee, K. Numerical solution of initial boundary value problems involving Maxwell's equations in isotropic media / Kane Yee // IEEE Transactions on Antennas and Propagation. — 1966. — Vol. 14 (3). — P. 302–307. <https://doi.org/10.1109/TAP.1966.1138693>
11. Berenger, J.-P. A perfectly matched layer for the absorption of electromagnetic waves / Jean-Pierre Berenger // Journal of Computational Physics. — 1994. — Vol. 114 (2). — P. 185–200.
12. Backpropagation applied to handwritten zip code recognition / Y. LeCun, B. Boser, J.S. Denker [et al.] // Neural Computation. — 1989. — Vol. 1 (4). — P. 541–551. <https://doi.org/10.1162/neco.1989.1.4.541>
13. Goodfellow, I. Deep learning. Vol. 1. /Ian. Goodfellow, Yoshua Bengio, Aaron Courville // MIT Press, Cambridge, 2016. — 800 p.
14. Krizhevsky, A. ImageNet classification with deep convolutional neural networks / A. Krizhevsky, I. Sutskever, G. E. Hinton // Advances in Neural Information Processing Systems. — 2012. — Vol. 25. — P. 1097–1105.
15. Deep residual learning for image recognition / Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. — 2016. — P. 770–778. <https://doi.org/10.1109/CVPR.2016.90>

16. Glorot, X. Understanding the difficulty of training deep feedforward neural networks / Xavier Glorot, Yoshua Bengio // JMLR Proceedings. — 2010. — Vol. 9. — P. 249–256.
17. Ioffe, S. Batch normalization: accelerating deep network training by reducing internal covariate shift. / S. Ioffe, Ch. Szegedy // Proceedings of the 32nd International Conference on International Conference on Machine Learning. — 2015. — Vol. 37. — P. 448–456.
18. Kingma, D. P. Adam: A method for stochastic optimization / D. P. Kingma, J. Ba // In: Proc. 3rd International Conference for Learning Representations. — 2014. arXiv preprint arXiv:1412.6980
19. Puzyrev, V. Deep learning electromagnetic inversion with convolutional neural networks / Vladimir Puzyrev // Geophysical Journal International. — 2019. — Vol. 218 (2). — P. 817–832. <https://doi.org/10.1093/gji/ggz204>
20. Two-dimensional Ultrasound Imaging Technique based on Neural Network using Acoustic Simulation / Y. Nagatani, S. Okumura, S. Wu, T. Matsuda // Medical Physics. — 2020. arXiv:2004.08775v1
21. Solov'ev, A. N. Ultrasonic Location of Inner Crack Defects in a Compound Elastic Cylinder Using an Artificial Neural-Network Apparatus / A. N. Solov'ev, B. V. Sobol', P. V. Vasil'ev // Russian Journal of Nondestructive Testing. — 2016. — Vol. 52 (3). — P. 119–124.

Поступила в редакцию 13.03.2021

Поступила после рецензирования 02.04.2021

Принята к публикации 06.04.2021

*Об авторах:*

**Васильев Павел Владимирович**, старший преподаватель кафедры «Информационные технологии», ФГБОУ ВО «Донской государственный технический университет» (344003, РФ, г. Ростов-на-Дону, пл. Гагарина, 1), Researcher ID: [P-8366-2017](https://orcid.org/0000-0003-4112-7449), Scopus ID: [57193327081](https://orcid.org/0000-0003-4112-7449), ORCID: <https://orcid.org/0000-0003-4112-7449>, [lyftzeigen@mail.ru](mailto:lyftzeigen@mail.ru)

**Сеничев Александр Вадимович**, аспирант кафедры «Информационные технологии», ФГБОУ ВО «Донской государственный технический университет» (344003, РФ, г. Ростов-на-Дону, пл. Гагарина, 1), ORCID: <https://orcid.org/0000-0003-2001-8235>, [alexandr.senichev@gmail.com](mailto:alexandr.senichev@gmail.com)

**Джорджо Иван**, профессор кафедры «Гражданское, строительно-архитектурное и экологическое проектирование» Л'Аквила, Италия; исследователь в Международном исследовательском центре математики и механики сложных систем (Via Camponeschi, 19 Piazza Santa Margherita, 2 Palazzo Camponeschi, 67100 L'Aquila AQ, Italy), кандидат наук, Researcher ID: [E-9341-2010](https://orcid.org/0000-0002-0044-9188), Scopus ID: [24757867200](https://orcid.org/0000-0002-0044-9188), ORCID: <https://orcid.org/0000-0002-0044-9188>, [ivan.giorgio78@gmail.com](mailto:ivan.giorgio78@gmail.com)

*Заявленный вклад соавторов:*

П. В. Васильев — формирование основной концепции, цели и задачи исследования; А. В. Сеничев — проведение расчетов, подготовка текста, формирование выводов; И. Джорджо — доработка текста, корректировка выводов.

*Все авторы прочитали и одобрили окончательный вариант рукописи.*