

УДК 620.179.16:004.032.26

DOI: [10.26102/2310-6018/2026.55.4.012](https://doi.org/10.26102/2310-6018/2026.55.4.012)

## Многозадачная гибридная модель с многоветвевым регрессионным блоком для обнаружения и оценки размеров дефектов по данным ультразвукового контроля

Д.А. Иванов<sup>1</sup>✉, Д.В. Кондратов<sup>1,2,3</sup>

<sup>1</sup>Саратовский государственный технический университет имени Гагарина Ю.А.,  
Саратов, Российская Федерация

<sup>2</sup>Институт проблем точной механики и управления РАН, Саратов,  
Российская Федерация

<sup>3</sup>Саратовский национальный исследовательский государственный университет имени  
Н.Г. Чернышевского, Саратов, Российская Федерация

**Резюме.** В статье рассматривается создание многозадачной гибридной нейросетевой модели с многоветвевой структурой регрессионного блока для одновременного обнаружения и количественной оценки размеров дефектов по данным ультразвукового неразрушающего контроля. Основная цель работы – повышение точности определения параметров дефектов за счет параллельной обработки признаков разными функциями активации в рамках единой многозадачной архитектуры. В качестве материалов исследования использованы данные ультразвукового контроля сварного стыка из аустенитной нержавеющей стали с искусственными трещинами. Методология включала расширение ранее разработанной CNN-GRU модели для бинарной классификации до многозадачной, где регрессионный блок реализован как многоветвевая структура с параллельными преобразованиями и последующей интеграцией признаков. Обучение проводилось с балансировкой функций потерь для совместной оптимизации задач классификации и регрессии. Результаты показали высокую эффективность предложенного подхода. Модель продемонстрировала абсолютную точность классификации и низкую ошибку регрессии – средняя абсолютная ошибка составила 0,118 мм (5,3 % от среднего размера дефекта). Сравнение с моделью аналогичной архитектуры без многоветвевой структуры подтвердило, что предложенное решение снижает ошибку более чем в два раза и устраняет систематическое смещение предсказаний. Разработанная архитектура может иметь практическую значимость для систем автоматизированной ультразвуковой диагностики, требующих не только обнаружения, но и точного измерения параметров дефектов.

**Ключевые слова:** ультразвуковой контроль, многозадачное обучение, многоветвевая архитектура, классификация, регрессия, нейронные сети, дефектоскопия.

**Для цитирования:** Иванов Д.А., Кондратов Д.В. Многозадачная гибридная модель с многоветвевым регрессионным блоком для обнаружения и оценки размеров дефектов по данным ультразвукового контроля. *Моделирование, оптимизация и информационные технологии.* 2026;14(4). URL: <https://moitvvt.ru/ru/journal/article?id=2263> DOI: 10.26102/2310-6018/2026.55.4.012

## The multi-task hybrid model with a multi-branch regressor for flaw detection and sizing in ultrasonic testing

D.A. Ivanov<sup>1</sup>✉, D.V. Kondratov<sup>1,2,3</sup>

<sup>1</sup>Yuri Gagarin State Technical University of Saratov, Saratov, the Russian Federation

<sup>2</sup>Institute of Precision Mechanics and Control Problems of the Russian Academy of Sciences,  
Saratov, the Russian Federation

<sup>3</sup>Saratov State University, Saratov, the Russian Federation

**Abstract.** This article discusses the development of a multi-task hybrid neural network model with a multi-branch regression block structure for the simultaneous detection and quantitative assessment of defect sizes based on ultrasonic non-destructive testing data. The primary objective of the study is to improve the accuracy of determining defect geometric parameters through parallel feature processing using different activation functions within a single multi-task architecture. The study utilizes ultrasonic testing data for a welded joint made of austenitic stainless steel with artificial cracks. The methodology included expanding the previously developed CNN-GRU model for binary classification to a multi-task model, where the regression block is implemented as a multi-branch structure with parallel transformations and subsequent feature integration. Training was conducted with balanced loss functions to jointly optimize classification and regression problems. The results demonstrated the high efficiency of the proposed approach. The model demonstrated absolute classification accuracy and a low regression error: the average absolute error was 0.118 mm (5.3 % of the average defect size). A comparison with a model of a similar architecture without a multi-branch structure confirmed that the proposed solution reduces the error by more than twofold and eliminates systematic prediction bias. The developed architecture may have practical implications for automated ultrasound diagnostic systems that require not only detection but also precise measurement of defect parameters.

**Keywords:** ultrasonic testing, multitasking learning, multi-branch architecture, classification, regression, neural networks, flaw detection.

**For citation:** Ivanov D.A., Kondratov D.V. The multi-task hybrid model with a multi-branch regressor for flaw detection and sizing in ultrasonic testing. *Modeling, Optimization and Information Technology*. 2026;14(4). (In Russ.). URL: <https://moitvivr.ru/ru/journal/article?id=2263> DOI: 10.26102/2310-6018/2026.55.4.012

## Введение

Ультразвуковой неразрушающий контроль (УЗК) является одним из наиболее распространенных методов диагностики сварных соединений, трубопроводов и металлоконструкций, широко применяемым в промышленности для обеспечения надежности и безопасности эксплуатации оборудования. Помимо факта обнаружения дефекта, практическая ценность результатов УЗК во многом определяется возможностью количественной оценки его геометрических характеристик, прежде всего характерного размера, поскольку именно этот параметр используется при принятии решений о допустимости эксплуатации, необходимости ремонта или замены элемента конструкции. В связи с этим задачи автоматизированной количественной интерпретации ультразвуковых сигналов приобретают всё большую актуальность.

Развитие автоматизированных методов УЗК идет по пути усложнения решаемых задач: от базового обнаружения и классификации дефектов к точной количественной оценке их параметров, а в перспективе – к комплексной диагностике, объединяющей несколько характеристик в рамках единого подхода. Соответственно, и научные исследования в этой области можно условно разделить на три ключевых направления. Первое и наиболее разработанное направление посвящено задаче классификации дефектов по типам. Второе направление фокусируется на регрессионных моделях для количественной оценки размеров, положения и формы обнаруженных повреждений. Наконец, третье активно развивающееся направление стремится преодолеть ограничения отдельных моделей за счет мультизадачных архитектур, способных решать несколько взаимосвязанных задач одновременно. Для систематизации существующих подходов необходимо рассмотреть основные достижения в рамках этих направлений.

Наиболее исследованным, как отмечалось, является направление классификации дефектов. Большинство работ по автоматизированной обработке ультразвуковых сигналов фокусируется именно на этой задаче. В этой области Shi Y. и соавт. предложили архитектуру сверточной нейронной сети (CNN), обучаемую

непосредственно на временных A-scan сигналах. Авторы показали, что отказ от ручного извлечения частотных и вейвлет-признаков позволяет повысить точность классификации дефектов до 98,2 %, а использование результатов классификации отдельных сигналов для формирования C-scan изображений обеспечивает наглядную визуализацию дефектных зон [1]. Стремясь повысить точность обнаружения дефектов, Barshok K., Choi J.-I. и Lee J. предложили подход к автоматическому обнаружению дефектов в сложных структурах на основе PAUT-данных, где сравнение нескольких архитектур показало, что сверточные сети обеспечивают высокую точность классификации, а усовершенствованная модель с механизмом внимания достигает точности до 99,4 % и превосходит классические CNN по качеству распознавания дефектов [2]. Переходя от одномерных сигналов к анализу изображений, Wang H. и соавт. применили методы машинного обучения для классификации дефектов на снимках, полученных методом полной фокусировки (TFM). Наилучший результат – точность около 93 % – был достигнут при использовании гистограммы ориентированных градиентов в качестве признаков и метода опорных векторов в качестве классификатора [3]. Альтернативный подход к анализу изображений, но уже с использованием волн Лэмба, продемонстрировали Krolík A. и соавт., которые исследовали возможность автоматического обнаружения дефектов в панелях из полиэтилена и полиамида. Авторы анализировали амплитуды волн, возбуждаемых в материалах со статическими дефектами различного размера, и показали, что обученные модели машинного обучения способны отличать нормальные и дефектные участки с высокой точностью (0,9431 при классификации и 0,9721 при предсказании) [4]. Наконец, для более сложных объектов, таких как углепластиковые композиты, Tunuković V. и соавт. сравнили традиционную пороговую обработку амплитуд и статистическое детектирование с современными моделями обнаружения объектов, включая YOLO, Faster R-CNN и RetinaNet. Результаты показали, что Faster R-CNN достигала точности до 99,8 %, а использование синтетически расширенных обучающих выборок дополнительно повышало стабильность и точность моделей, демонстрируя превосходство машинного обучения для надёжного обнаружения дефектов в сложных промышленных условиях [5].

Успехи в классификации создали основу для решения более сложной задачи – точной количественной оценки параметров дефектов, что критически важно для инженерных решений. Такая постановка выходит за рамки бинарного распознавания и требует использования регрессионных моделей, способных предсказывать непрерывные характеристики дефектов на основе ультразвуковых сигналов. В этом направлении Соловьев А.Н. и соавт. использовали методы УЗК совместно с CNN для идентификации дефектов в клине с покрытием. Для параметра толщины дефекта средняя относительная ошибка сети не превышала 5 % при угле раскрытия клина 60° и 10 % при 120°. Исследование влияния угла раскрытия показало, что локализация дефекта и определение его положения относительно вершины клина изменяются незначительно при увеличении угла, а наилучшие результаты достигаются при меньших углах раскрытия [6]. Важной задачей при разработке регрессионных моделей является их переносимость с синтетических данных на реальные измерения. В этом контексте Sheehan P. и соавт. исследовали возможность оценки трещин по TFM-изображениям, сравнив несколько архитектур в среде AutoML. Обученные на синтетических данных, модели тестировались на экспериментальных измерениях, а наилучшую точность показала VGG-16, при этом было установлено, что перекоп датчика вносит больший вклад в снижение точности, чем изменение его положения относительно объекта контроля [7]. Повышение точности измерений требует комплексного подхода, включающего как применение нейросетевых методов, так и совершенствование алгоритмов обработки сигналов. В связи с этим Shi S. и соавт. предложили метод машинного обучения, который

позволяет предсказывать численные параметры дефектов и улучшать разрешение изображений за счет комбинированного подхода выбора информативных признаков. В экспериментах модель предсказывала времена прихода отражённых волн с ошибкой менее 3,7 %, обеспечивала высокое пространственное разрешение  $0,5\lambda$  и позволяла с высокой точностью определять глубину и расстояние между дефектами [8]. Схожую задачу, но применительно к трещинам, решили Pyle R. J. и соавт., предложив метод глубокого обучения на основе CNN для количественной оценки трещин в УЗК, который позволяет автоматически определять длину и наклон дефектов, улучшая точность по сравнению с традиционными подходами. Используя сочетание синтетических и экспериментальных данных, полученная модель предсказывает длину трещин с ошибкой около  $\pm 0,29$  мм и наклон с ошибкой  $\pm 2,9^\circ$  [9]. Дальнейшее улучшение точности, особенно в условиях шума, продемонстрировали Fei Q. и соавт., объединив CNN с алгоритмом подавления шума и выделения областей дефекта. Такой подход позволил не только автоматически выявлять трещины, но и точно измерять их длину и высоту с ошибкой  $\pm 0,065$  и  $\pm 0,061$  мм соответственно, оставаясь устойчивым к сложным условиям шумных сигналов [10].

Логическим развитием идей автоматизации становится стремление к комплексной диагностике, когда одна модель способна решать несколько взаимосвязанных задач – обнаруживать, классифицировать, локализовать и оценивать размеры дефекта. Этому способствует развитие архитектур мультизадачного обучения. Так, в работе Azad M. и соавт. предложен метод на базе сверточной нейросети (1D-CNN), который одновременно выполняет обнаружение, локализацию и оценку степени тяжести повреждений в многослойных композитных пластинах на основе необработанных ультразвуковых сигналов. Модель с общими сверточными слоями и отдельными ветвями для каждой задачи продемонстрировала высокие результаты на тестовой выборке: 100 % точность обнаружения, коэффициент детерминации локализации повреждения  $R^2 \approx 93,8\%$  и  $\approx 87,0\%$  точности оценки тяжести дефекта. Такое совместное обучение нескольких задач в одной архитектуре делает возможным более всесторонний анализ повреждений без необходимости использовать отдельные модели для каждой цели [11]. Альтернативный подход к мультизадачности, не требующий размеченных дефектных данных, предложили Dong X. и соавт., разработавшие многозадачную сверточную нейросеть на основе одноклассового обучения. Объединив автокодировщик и одноклассовый классификатор в единой архитектуре, авторы сделали возможным выявление и локализацию дефектов без необходимости разметки аномалий [12]. Для автоматического обнаружения дефектов сварных швов на основе ультразвуковых сигналов эффективно применяются многоветвевые глубокие сети, объединяющие разные типы признаков. Kim K. и соавт. представили архитектуру, где одномерная сверточная сеть (1D-CNN) изучает локальные закономерности сигналов, а двухмерная сверточная сеть (2D-CNN) выделяет пространственные признаки, затем выходы обеих ветвей объединяются для классификации дефектов. Модель показала точность 92,2 %, что подтверждает эффективность многоветвевоего объединения признаков для анализа ультразвуковых данных [13]. Развивая идею параллельной обработки, но уже для точного измерения параметров, Wang L. и соавт. предложили метод с использованием параллельной многоветвевой CNN для одновременного и точного определения глубины, длины и ориентации субмиллиметровых трещин. Авторы использовали слои межзадачной изоляции, что позволило эффективно разграничить перекрывающиеся ультразвуковые сигналы и достичь точности более 90 % в условиях шума. Данный подход демонстрирует эффективность многоветвевой обработки в рамках однозадачной сверточной архитектуры [14]. Наконец, Cao W. и соавт. предложили модель многомодального слияния признаков для улучшения обнаружения дефектов при

фазированном ультразвуковом контроле толстостенных сварных соединений. Комбинируя ResNet и GRU, авторы представили метод, который позволяет одновременно обрабатывать сигналы и изображения, полученные с А-сканирования и S-сканирования. На основе обучения на трех сверхтолстых образцах модель показала точность 98,07 %, что на 8 % выше, чем у одномодальных моделей, обеспечив при этом 100 % точность обнаружения истинных и псевдодефектов [15].

Проведенный анализ исследований свидетельствует о том, что современные подходы к автоматизации УЗК развиваются по пути создания комплексных систем. Уже существуют как модели, решающие отдельные задачи классификации или регрессии, так и более сложные мультизадачные и многоветвевые архитектуры. Последние обычно используют ветви либо для объединения разных типов данных, либо для распараллеливания решения независимых инженерных задач (например, когда одна ветвь локализует дефект, а другая классифицирует его тип). Напротив, применение многоветвевой структуры внутри гибридной мультизадачной модели (сочетающей свёрточные и рекуррентные слои) для совместной работы нескольких ветвей над одной и той же задачей – в частности, для повышения точности регрессии размеров – остаётся малоизученным. Настоящее исследование сосредоточено на разработке и валидации именно такого подхода, где несколько параллельных ветвей с разными функциями активации объединяются для решения единой задачи регрессии в рамках единой гибридной архитектуры, которая одновременно выполняет и классификацию дефектов.

Цель исследования – разработка и валидация гибридной CNN-GRU модели с многоветвевой структурой регрессионного блока, предназначенной для одновременного определения наличия и оценки размера дефекта на основе данных ультразвукового контроля. Для достижения поставленной цели в работе решаются следующие задачи: подготовка данных ультразвукового контроля для формирования выборок с двумя типами целевых переменных (классы и размеры дефектов); разработка архитектуры многозадачной гибридной модели на основе CNN-GRU с многоветвевым регрессионным блоком и параллельными функциями активации (ReLU, tanh, линейная) для совместного решения задач классификации и регрессии; экспериментальное определение гиперпараметров, обеспечивающих сбалансированное обучение классификационной и регрессионной ветвей; анализ стабильности процесса обучения и оценка обобщающей способности модели по динамике ошибок на обучающей и валидационной выборках; проведение сравнительного анализа предложенной архитектуры с базовой моделью для оценки влияния многоветвевой структуры на точность регрессии и наличие систематических смещений; итоговая оценка качества модели на независимой тестовой выборке по метрикам точности классификации, средней абсолютной ошибки регрессии (MAE) и  $R^2$ .

### Материалы и методы

Методологическая основа данного исследования базируется на гибридной архитектуре CNN-GRU, которая была ранее описана и применена для бинарной классификации дефектов в ультразвуковом контроле [16, 17]. Этот подход показал свою эффективность за счет сочетания свёрточных сетей для извлечения локальных признаков и рекуррентных блоков GRU для анализа временных зависимостей. Настоящее исследование продолжает и развивает этот подход путем расширения архитектуры модели до многозадачной, предусматривающей одновременное решение задач классификации и регрессии параметров дефектов. Реализация такого подхода потребовала модификации структуры модели, включая введение регрессионного блока,

а также разработки специализированной схемы обучения с балансировкой функций потерь.

Общая схема исследования включает три ключевых этапа: подготовку данных, построение многозадачной модели и ее обучение. На первом этапе осуществляется предобработка ультразвуковых сигналов. В отличие от предыдущей работы, здесь используются два типа целевых переменных: бинарные классы и непрерывные размеры дефектов. Качество этой подготовки напрямую влияет на сходимость обучения и итоговую точность модели в обеих задачах.

Для обеспечения сопоставимости результатов и оценки новых архитектурных решений использовался тот же набор данных, что и в работе с бинарной классификацией [17], основанный на исследовании Virkkunen I. и соавт. [18]. Набор включает ультразвуковые сигналы, полученные при контроле сварного стыка из аустенитной нержавеющей стали с искусственными трещинами, дополненными методом виртуальных дефектов. Статистический анализ набора данных, результаты которого представлены на Рисунке 1, показал сбалансированность классов (60,7 % дефектов, 39,3 % без дефектов).

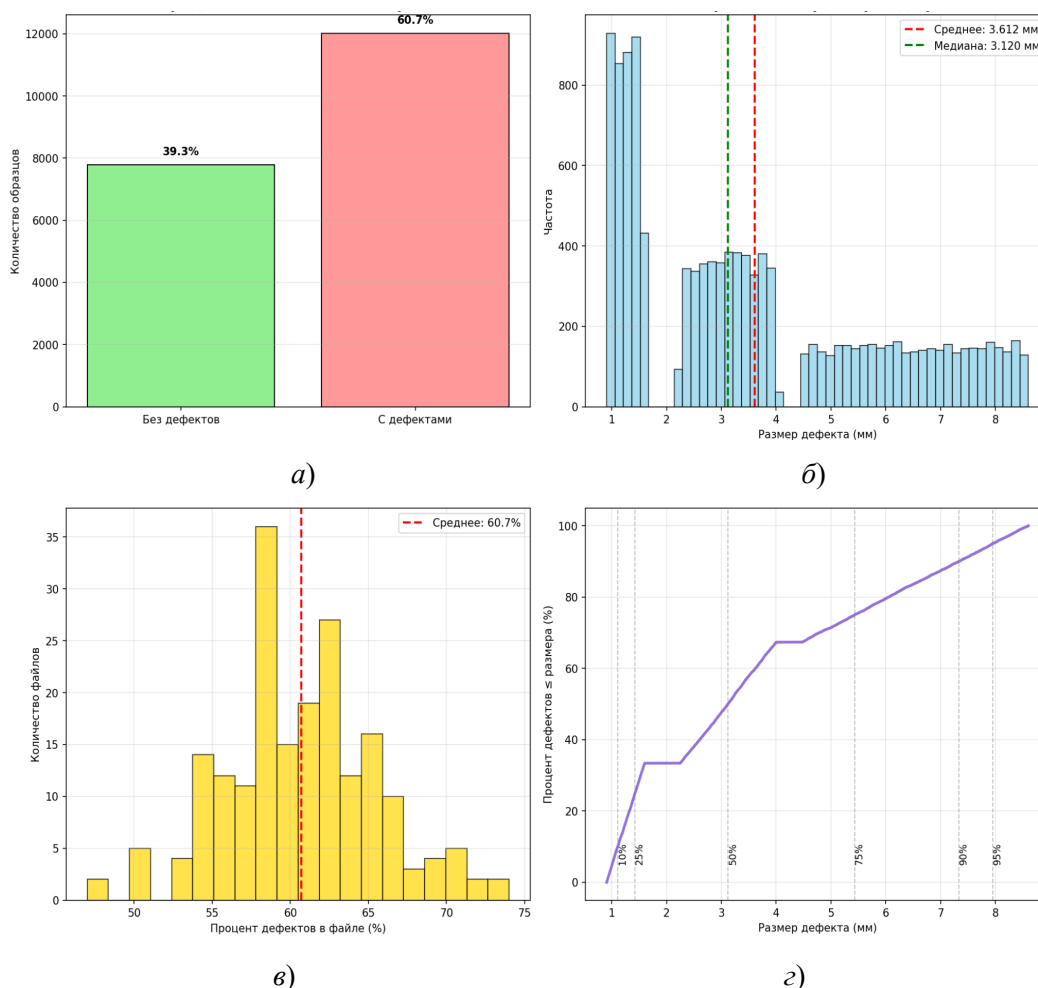


Рисунок 1 – Анализ набора данных УЗК: *а* – распределение классов в наборе данных; *б* – распределение размеров дефектов; *в* – распределение процента дефектов по файлам; *г* – кумулятивное распределение размеров дефектов

Figure 1 – Analysis of the ultrasonic testing dataset: *a* – class distribution in the dataset; *b* – distribution of flaw sizes; *c* – distribution of the percentage of flaws across files; *d* – cumulative distribution of flaw sizes

Архитектура предложенной модели, как уже отмечалось ранее, является развитием гибридной схемы CNN-GRU для классификации дефектов. Сохранены базовые блоки для извлечения пространственно-временных признаков: два последовательных сверточных блока с уменьшающейся размерностью (с 64 до 32 и с 32 до 16 фильтров соответственно). Такое снижение размерности, по сравнению с предыдущей реализацией, было принято для балансировки вычислительной сложности модели, поскольку в нее были введены новые, ресурсоемкие компоненты: многозадачный выход и многоветвевая регрессионная структура. Каждый блок включает активацию ReLU и операцию макс-пулинга. За ними следует двухслойный GRU-блок (с 32 до 16 нейронов) со слоем исключения (Dropout), где вероятность отключения нейрона составляла 0,1. Ключевые модификации внесены в завершающую часть для реализации многозадачности и, в соответствии с целью исследования, направлены на структурное усиление регрессионного блока. Вместо единого выхода реализован асимметричный блок с двумя специализированными ветвями. Классификационная ветвь состоит из полносвязного слоя на 8 нейронов с функцией активации ReLU, слоя Dropout с коэффициентом 0,05 и выходного слоя с сигмоидной активацией. Регрессионная ветвь, в свою очередь, реализована как многоветвевая структура, в которой несколько независимых преобразований параллельно обрабатывают одни и те же входные признаки. Это позволяет модели одновременно изучать разные аспекты данных: первая ветвь с активацией ReLU выделяет положительные активации и линейные зависимости, вторая с активацией tanh работает с насыщающимися сигналами и может улавливать периодические компоненты, а третья с линейной активацией, в свою очередь, сохраняет исходные масштабы значений. Разнообразие активаций повышает вероятность, что хотя бы одна ветвь эффективно выделит паттерны, важные для регрессии.

После параллельной обработки выходы всех ветвей объединяются, создавая признаковое пространство, где представлены разные типы зависимостей. Это пространство затем последовательно сужается через каскад полносвязных слоев (с 64 до 8 нейронов), что позволяет модели интегрировать разнородные признаки и выделить наиболее важные для предсказания размера. Учитывая сложность архитектуры и высокую вариативность целевых значений, для стабилизации обучения на каждом этапе применялся слой пакетной нормализации (Batch Normalization), который стабилизирует распределение активаций в каждой ветви, предотвращая исчезающие или взрывающиеся градиенты, что особенно важно при высокой вариативности целевой переменной, а также выступает как слабый регуляризатор, добавляющий шум в процессе обучения, что улучшает обобщающую способность. Таким образом, решение направлено на увеличение емкости и разнообразия регрессионной ветви – вместо одного линейного преобразования модель использует несколько разнотипных преобразований с последующим объединением, что дает ей больше возможностей для выявления зависимости между ультразвуковыми сигналами и физическим размером дефекта. Итоговая архитектура модели изображена на Рисунке 2.

Модель компилировалась оптимизатором Adam со скоростью обучения 0,001 и ограничением нормы градиентов величиной 1,0. Использовалась составная функция потерь с весами 0,15 для классификации и 10 для регрессии, где для классификации применялась бинарная кросс-энтропия, а для регрессии – среднеквадратичная ошибка. Данное соотношение весов было определено эмпирически в ходе серии экспериментов, направленных на преодоление устойчивого недообучения регрессионной ветви. В качестве отправной точки были взяты равные веса (1:1). В ходе итеративного процесса вес регрессии последовательно увеличивался, а вес классификации – уменьшался, до достижения сбалансированного снижения обеих ошибок на валидационной выборке. Такое резкое асимметричное взвешивание потребовалось для компенсации существенно

большей сложности задачи регрессии (прогнозирование непрерывной величины с высокой дисперсией) по сравнению с уже хорошо решаемой задачей бинарной классификации.

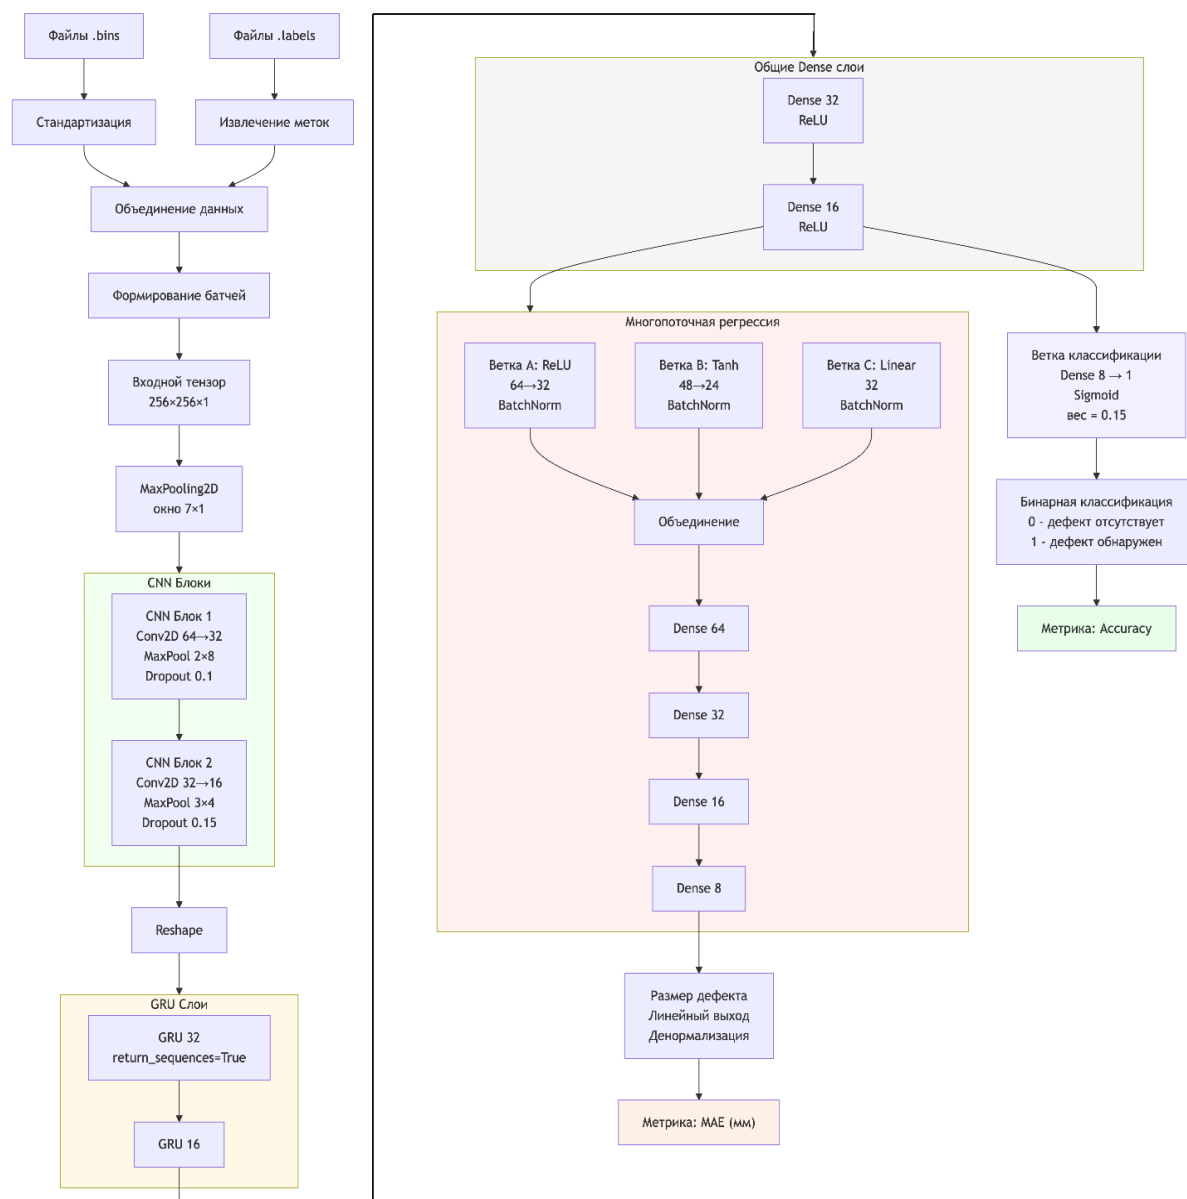


Рисунок 2 – Архитектура многозадачной CNN-GRU модели для классификации и регрессии  
 Figure 2 – Architecture of the multi-task CNN-GRU model for classification and regression

Обучение проводилось в течение 120 эпох на процессоре с архитектурой ARM и 18 ГБ RAM. Для управления процессом применялись callback-функции: ReduceLROnPlateau для адаптивного снижения скорости обучения при стагнации валидационных потерь, ModelCheckpoint для сохранения весов модели с минимальной ошибкой регрессии на валидации и пользовательский TrainingMonitor, реализованный для отслеживания процесса многозадачного обучения, который регистрировал соотношение ошибок на обучающей и валидационной выборках и автоматически пересчитывал метрики регрессии в миллиметры, что давало возможность своевременно обнаруживать дисбаланс в обучении ветвей модели.

## Результаты

В ходе исследования была реализована и обучена многозадачная CNN-GRU модель, способная одновременно определять наличие дефекта и оценивать его линейный размер по данным ультразвукового неразрушающего контроля. Целью экспериментальной части являлась не только оценка итоговой точности модели, но и анализ динамики обучения, стабильности процесса и обобщающей способности на независимых данных.

Обучение модели проводилось в течение 120 эпох. Как видно из графика на Рисунке 3, процесс характеризуется устойчивой сходимостью по обеим целевым задачам.




Рисунок 3 – Динамика обучения многозадачной CNN-GRU модели: *a* – динамика ошибки регрессии; *b* – динамика точности классификации

Figure 3 – Training dynamics of the multi-task CNN-GRU model: *a* – regression error dynamics; *b* – classification accuracy dynamics

В отличие от исследования, посвященного бинарной классификации, в данном эксперименте не использовался механизм ранней остановки (EarlyStopping), несмотря на достижение локального минимума ошибки регрессии. Это решение было мотивировано целью не только зафиксировать наилучший результат, но и провести полный анализ устойчивости и поведения модели в ходе продолжительного обучения, включая этапы возможного роста ошибки на валидации.

Средняя абсолютная ошибка регрессии на валидационной выборке, которую можно наблюдать на Рисунке 3а, достигла своего минимума (0,091 мм, или 4,1 % от

среднего размера дефекта) на 60-й эпохе. После этого наблюдался некоторый рост ошибки вплоть до значений 0,12–0,14 мм с одновременным уменьшением скорости обучения оптимизатором (ReduceLROnPlateau). Такое поведение указывает на то, что модель достигла области локального минимума, а последующее увеличение ошибки может быть связано с адаптацией к более тонким, но менее обобщаемым особенностям обучающей выборки. Механизм ModelCheckpoint обеспечил сохранение весов модели именно с эпохи минимальной валидационной ошибки. Проведение всех 120 эпох позволило убедиться в отсутствии последующего схода к более глубокому минимуму и подтвердить, что наблюдаемый пик качества не был случайным.

Точность классификации, изображённая на Рисунке 3б, на валидационной выборке стабилизировалась на уровне 1,0 уже к 20 эпохе, что подтверждает высокую эффективность базовой CNN-GRU архитектуры для задачи бинарного определения наличия дефектов.

Динамика изменчивости ошибки MAE между эпохами (стандартное отклонение по скользящему окну) для обучающей и валидационной выборок показана на Рисунке 4а. Для обеих выборок начальные значения изменчивости быстро снижаются уже в первые эпохи. После начального периода показатели стабилизируются на низком уровне и продолжают уменьшаться к концу обучения, достигая значений порядка тысячных долей миллиметра. Это указывает на быстрый выход в режим устойчивой оптимизации с минимальными колебаниями между эпохами для обеих выборок.

Баланс между обучением и валидацией, представленный на Рисунке 4б, является важным индикатором степени обобщения модели. Он определяется как отношение обучающей ошибки регрессии к валидационной.




Рисунок 4 – Анализ стабильности и баланса процесса обучения: *а* – изменчивость ошибки между эпохами; *б* – Баланс между обучающей и валидационной ошибками  
 Figure 4 – Analysis of training stability and balance: *a* – error variability between epochs; *b* – balance between training and validation errors

В идеальном сценарии данное отношение стремится к 1. В текущем эксперименте на лучшей 60-й эпохе отношение составило 0,9, что свидетельствует о высоком качестве обобщения и отсутствии переобучения. В дальнейшем (эпохи 61–120) отношение снижалось до 0,45–0,65, что является признаком умеренного переобучения регрессионной ветви: модель продолжает улучшать метрики на тренировочном наборе, но её способность к обобщению на новых данных ухудшается. Этот факт подтверждает корректность решения о раннем сохранении модели и обосновывает отказ от автоматического EarlyStopping в пользу обучения с контролем по валидационной метрике. Однако важно отметить, что абсолютные значения ошибок на обеих выборках в этой фазе оставались крайне низкими. Обучающая MAE снизилась до 0,06–0,07 мм, а

валидационная колебалась в диапазоне 0,10–0,14 мм. Это свидетельствует о том, что наблюдаемое переобучение не является критичным с практической точки зрения: модель не теряет базовой способности к обобщению, а лишь демонстрирует некоторый дисбаланс в точности между обучающей и валидационной выборками, при этом сохраняя высокий абсолютный уровень точности прогноза. Такое поведение, возможно, отражает переход от изучения общих закономерностей к подстройке под менее устойчивые, специфичные для обучающего набора особенности.

Для проверки обобщающей способности обученная модель была протестирована на тестовом наборе данных, состоящем из 200 образцов (111 с дефектами, 89 без дефектов), которые не использовались ни на этапе обучения, ни на этапе валидации. Результаты представлены на Рисунке 5.

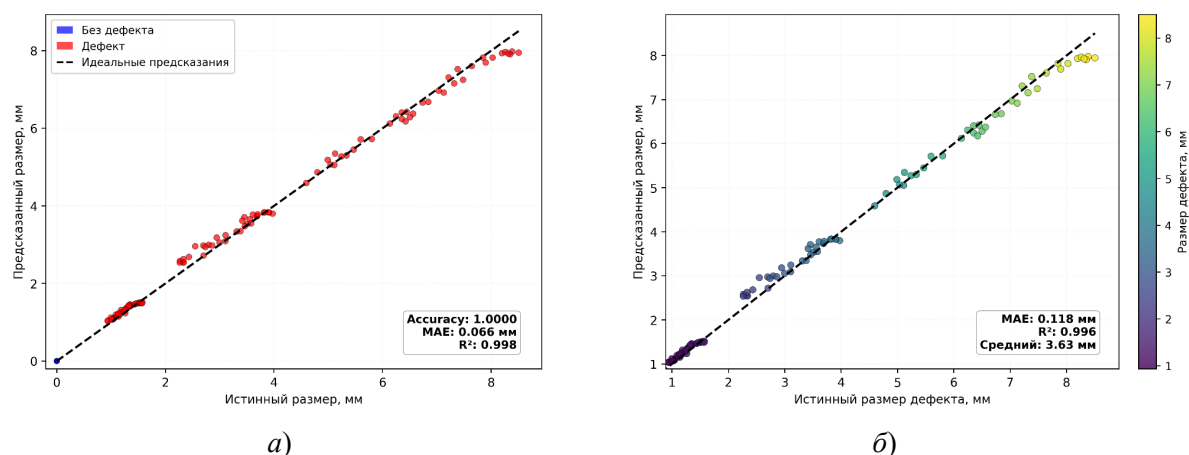


Рисунок 5 – Анализ предсказаний модели на тестовом наборе данных: *а* – все данные (200 примеров); *б* – только дефекты (111 примеров)  
 Figure 5 – Analysis of model predictions on the test dataset: *a* – all data (200 samples); *b* – only flaws (111 samples)

Модель показала абсолютную точность классификации, корректно идентифицировав все образцы. В задаче регрессии средняя абсолютная ошибка составила 0,066 мм для всех образцов и 0,118 мм для дефектных образцов, что соответствует 5,3 % от среднего размера дефекта в обучающей выборке.

Как видно из графика на Рисунке 5*а*, образцы без дефектов группируются вблизи начала координат. Дефектные образцы демонстрируют линейную зависимость между предсказанными и истинными размерами с некоторым разбросом. Анализ дефектных образцов на Рисунке 5*б* показывает распределение точек вблизи линии идеального соответствия. Для большинства дефектов предсказанные значения находятся в пределах  $\pm 0,2$  мм от истинных размеров. Наблюдается несколько выбросов с более значительной ошибкой предсказания, преимущественно в области размеров  $\pm 0,5$  мм.

Значение MAE на тестовом наборе (0,118 мм) превышает минимальную валидационную ошибку (0,091 мм). Такое расхождение характерно для переноса модели на независимые данные и может быть обусловлено как естественной вариативностью ультразвуковых сигналов, так и отличиями в распределении характеристик дефектов между выборками. В контексте ультразвукового контроля различие в 0,027 мм сопоставимо с погрешностью метода и разрешающей способностью оборудования, что делает данное расхождение допустимым.

Для оценки влияния многоветвевой структуры на качество регрессии было проведено сравнение с моделью, имеющей аналогичную архитектуру, но без

многоветвевой организации регрессионного блока. В остальном модели идентичны: используется тот же CNN-GRU энкодер, та же классификационная ветвь и те же параметры обучения. Сравнительные результаты приведены в Таблице 1.

Таблица 1 – Сравнение многоветвевой и базовой CNN-GRU моделей  
Table 1 – Comparison of the multi-branch and baseline CNN-GRU models

Метрика / Модель	Многоветвевая модель	Базовая модель
Точность классификации	1,000	1,000
MAE, все образцы, мм	0,066	0,274
MAE, только дефекты, мм	0,118	0,241
MAE, % от среднего размера	5,3	20,8
Коэффициент R <sup>2</sup>	0,994	0,982

Как видно из таблицы, исключение многоветвевой структуры приводит к росту ошибки регрессии более чем в два раза. Кроме того, в предсказаниях модели без многоветвевой структуры обнаруживается систематическое смещение, отсутствующее у предложенной архитектуры. Полученные результаты позволяют сделать вывод, что именно многоветвевая организация регрессионного блока обеспечивает повышение точности количественной оценки размеров дефектов.

### Заключение

Разработанная гибридная CNN-GRU модель с многоветвевой структурой регрессионного блока продемонстрировала высокую эффективность для одновременного обнаружения и количественной оценки размеров дефектов по данным ультразвукового контроля. Модель обеспечивает абсолютную точность классификации (100 %) и низкую ошибку регрессии – 0,118 мм (5,3 % от среднего размера дефекта) на тестовой выборке. Сравнение с моделью аналогичной архитектуры без многоветвевой структуры подтвердило, что параллельная обработка признаков разными функциями активации существенно снижает ошибку и устраняет систематическое смещение предсказаний. Полученные результаты свидетельствуют о потенциале использования предложенного подхода для задач автоматизированной ультразвуковой диагностики, требующих не только обнаружения, но и точного измерения параметров дефектов.

Перспективы дальнейших исследований заключаются в расширении архитектуры для оценки степени критичности дефекта, апробацию модели на других типах материалов и сварных соединений, а также на исследование возможностей переноса обучения с синтетических данных на полностью реальные производственные измерения.

### СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Shi Y., Xu W., Zhang J., Li X. Automated Classification of Ultrasonic Signal via a Convolutional Neural Network. *Applied Sciences*. 2022;12(9). <https://doi.org/10.3390/app12094179>
2. Barshok K., Choi J.-I., Lee J. Deep Learning-Based Approach for Automatic Defect Detection in Complex Structures Using PAUT Data. *Sensors*. 2025;25(19). <https://doi.org/10.3390/s25196128>
3. Wang H., Fan Zh., Chen X., et al. Automated Classification of Pipeline Defects from Ultrasonic Phased Array Total Focusing Method Imaging. *Energies*. 2022;15(21). <https://doi.org/10.3390/en15218272>
4. Krolik A., Drelich R., Pakuła M., Mikołajewski D., Rojek I. Detection of Defects in Polyethylene and Polyamide Flat Panels Using Airborne Ultrasound-Traditional and

- Machine Learning Approach. *Applied Sciences*. 2024;14(22). <https://doi.org/10.3390/app142210638>
5. Tunukovic V., McKnight Sh., Mohseni E., et al. A study of machine learning object detection performance for phased array ultrasonic testing of carbon fibre reinforced plastics. *NDT & E International*. 2024;144. <https://doi.org/10.1016/j.ndteint.2024.103094>
  6. Соловьев А.Н., Соболев Б.В., Васильев П.В., Сеничев А.В., Новикова А.И. Идентификация дефектов в клине с покрытием на основе методов ультразвукового неразрушающего контроля и сверточных нейронных сетей. *Вестник Пермского национального исследовательского политехнического университета. Механика*. 2023;(1):111–124. <https://doi.org/10.15593/perm.mech/2023.1.11>  
Soloviev A.N., Sobol B.V., Vasiliev P.V., Senichev A.V., Novikova A.I. Identification of defects in a coating wedge based on ultrasonic non-destructive testing methods and convolutional neural networks. *PNRPU Mechanics Bulletin*. 2023;(1):111–124. (In Russ.). <https://doi.org/10.15593/perm.mech/2023.1.11>
  7. Sheehan P.S., Miorelli R., Robert S., Chapuis B., Chatillon S. Investigation of a Deep Learning Methodology for Automatic Detection and Characterization of Crack-Type Defects in Ultrasonic Non-Destructive Testing. In: *2025 ICU PADERBORN – 9<sup>th</sup> International Congress on Ultrasonics, 21–25 September 2025, Paderborn, Germany*. 2025. P. 295–298. <https://doi.org/10.5162/Ultrasonic2025/E4-a3>
  8. Shi S., Jin Sh., Zhang D., et al. Improving ultrasonic testing by using machine learning framework based on model interpretation strategy. *Chinese Journal of Mechanical Engineering*. 2023;36(1). <https://doi.org/10.1186/s10033-023-00960-z>
  9. Pyle R.J., Bevan R.L.T., Hughes R.R., et al. Deep Learning for Ultrasonic Crack Characterization in NDE. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*. 2021;68(5):1854–1865. <https://doi.org/10.1109/TUFFC.2020.3045847>
  10. Fei Q., Cao J., Xu W., et al. A Deep Learning-Based Ultrasonic Diffraction Data Analysis Method for Accurate Automatic Crack Sizing. *Applied Sciences*. 2024;14(11). <https://doi.org/10.3390/app14114619>
  11. Azad M.M., Jung J., Kim H.S., et al. An integrated multi-task transfer learning for damage detection, localization, and severity assessment of laminated composite plate. *Composite Structures*. 2025;371. <https://doi.org/10.1016/j.compstruct.2025.119478>
  12. Dong X., Taylor Ch.J., Cootes T.F. Defect Classification and Detection Using a Multitask Deep One-Class CNN. *IEEE Transactions on Automation Science and Engineering*. 2022;19(3):1719–1730. <https://doi.org/10.1109/TASE.2021.3109353>
  13. Kim K., Kim K.S., Park H.-J. Multi-branch deep fusion network-based automatic detection of weld defects using non-destructive ultrasonic test. *IEEE Access*. 2023;11:114489–114496. <https://doi.org/10.1109/ACCESS.2023.3324717>
  14. Wang L., Qi Zh., Ding X., et al. Accurate detection and characterization of sub-millimeter cracks using nonlinear ultrasonics-informed parallel multi-branch convolutional neural network. *Engineering Applications of Artificial Intelligence*. 2026;166. <https://doi.org/10.1016/j.engappai.2025.113638>
  15. Cao W., Sun X., Liu Zh., et al. The detection of PAUT pseudo defects in ultra-thick stainless-steel welds with a multimodal deep learning model. *Measurement*. 2025;241. <https://doi.org/10.1016/j.measurement.2024.115662>
  16. Иванов Д.А. Обзор подхода к обработке данных ультразвукового неразрушающего контроля с помощью машинного обучения. *Научно-технический вестник Поволжья*. 2025;(6):29–33.

- Ivanov D.A. Review of an approach to processing ultrasonic non-destructive testing data using machine learning. *Scientific and Technical Volga Region Bulletin*. 2025;(6):29–33. (In Russ.).
17. Иванов Д.А., Кондратов Д.В. Гибридная модель для пространственно-временной обработки данных ультразвукового неразрушающего контроля. *Современные наукоемкие технологии*. 2025;(12):69–77. <https://doi.org/10.17513/snt.40606>  
Ivanov D.A., Kondratov D.V. The hybrid model for spatio-temporal processing of ultrasonic non-destructive testing data. *Modern High Technologies*. 2025;(12):69–77. (In Russ.). <https://doi.org/10.17513/snt.40606>
18. Virkkunen I., Koskinen T., Jessen-Juhler O., Rinta-aho J. Augmented Ultrasonic Data for Machine Learning. *Journal of Nondestructive Evaluation*. 2021;40(1). <https://doi.org/10.1007/s10921-020-00739-5>

### ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Иванов Дмитрий Александрович**, аспирант, Саратовский государственный технический университет имени Гагарина Ю.А., Саратов, Российская Федерация.

*e-mail*: [d.ivanov.sstu@yandex.ru](mailto:d.ivanov.sstu@yandex.ru)

ORCID: [0009-0009-4379-9872](https://orcid.org/0009-0009-4379-9872)

**Dmitry A. Ivanov**, Postgraduate, Yuri Gagarin State Technical University of Saratov, Saratov, the Russian Federation.

**Кондратов Дмитрий Вячеславович**, доктор физико-математических наук, доцент, заведующий кафедрой «Информационная безопасность автоматизированных систем», Саратовский государственный технический университет имени Гагарина Ю.А., профессор кафедры математического и компьютерного моделирования, Саратовский национальный исследовательский государственный университет имени Н.Г. Чернышевского, Саратов, Российская Федерация.

*e-mail*: [kondratovdv@yandex.ru](mailto:kondratovdv@yandex.ru)

ORCID: [0000-0003-4266-2718](https://orcid.org/0000-0003-4266-2718)

**Dmitry V. Kondratov**, Doctor of Physical and Mathematical Sciences, Associate Professor, Head of the Department of Information Security of Automated Systems, Yuri Gagarin State Technical University of Saratov, Professor at the Department of Mathematical and Computer Modeling, Saratov State University, Saratov, the Russian Federation.

*Статья поступила в редакцию 02.03.2026; одобрена после рецензирования 14.04.2026; принята к публикации 22.04.2026.*

*The article was submitted 02.03.2026; approved after reviewing 14.04.2026; accepted for publication 22.04.2026.*