

ПРИМЕНЕНИЕ НЕЙРОСЕТЕЙ ДЛЯ АВТОМАТИЗИРОВАННОГО АНАЛИЗА ДАННЫХ УЛЬТРАЗВУКОВОГО КОНТРОЛЯ С ФАЗИРОВАННЫМИ РЕШЕТКАМИ



**ХАЙРУЛЛИН
Артур
Айдарович**

Главный научный сотрудник ООО «Новотекс системс», Москва
Специалист III уровня по UT, PAUT+TOFD, MT, PT, LT, VT, ET



**ИСМАГИЛОВ
Марсель
Мунирович**

Главный научный сотрудник ООО «Новотекс системс», Москва
Специалист III уровня по UT, RT, VT, MT



**КОСТАНИЯЦ
Вячеслав
Альбертович**

Технический специалист «Новотекс системс», Москва
Специалист II уровня по UT, MT, ET

Ультразвуковой неразрушающий контроль с фазированными решетками (Phased Array Ultrasonic Testing, PAUT) позволяет получать большой объем данных за короткое время за счет электронного сканирования диаграммы направленности и фокусировки в различных точках объекта контроля. Данная технология обеспечивает более полное покрытие зоны контроля и высокое разрешение изображений дефектов по сравнению с традиционным ультразвуковым контролем. Однако анализ и интерпретация больших массивов данных PAUT вручную представляет значительную сложность и требует высокой квалификации оператора. Обработка результатов контроля приборов с фазированными решетками является трудоемкой, в ней возможны ошибки вследствие усталости и субъективности оператора. По дан-

ным исследований, расхождения в выводах разных дефектоскопистов при анализе одних и тех же данных могут достигать заметных величин [1, 2]. Таким образом, существует потребность в автоматизации анализа данных ультразвукового контроля, чтобы повысить эффективность и воспроизводимость результатов.

Ранние подходы к автоматизации анализа ультразвуковых данных основывались на алгоритмах обработки сигналов и изображений, а также на жестко заданных правилах и пороговых критериях. Например, разработанное программное обеспечение (ПО) от Olympus для автоматического обзора PAUT-сканов способно выделять подозрительные зоны, основываясь на превышении амплитуды сигнала над заданным уровнем. Тем не менее классические алгоритмы имеют ограничения,

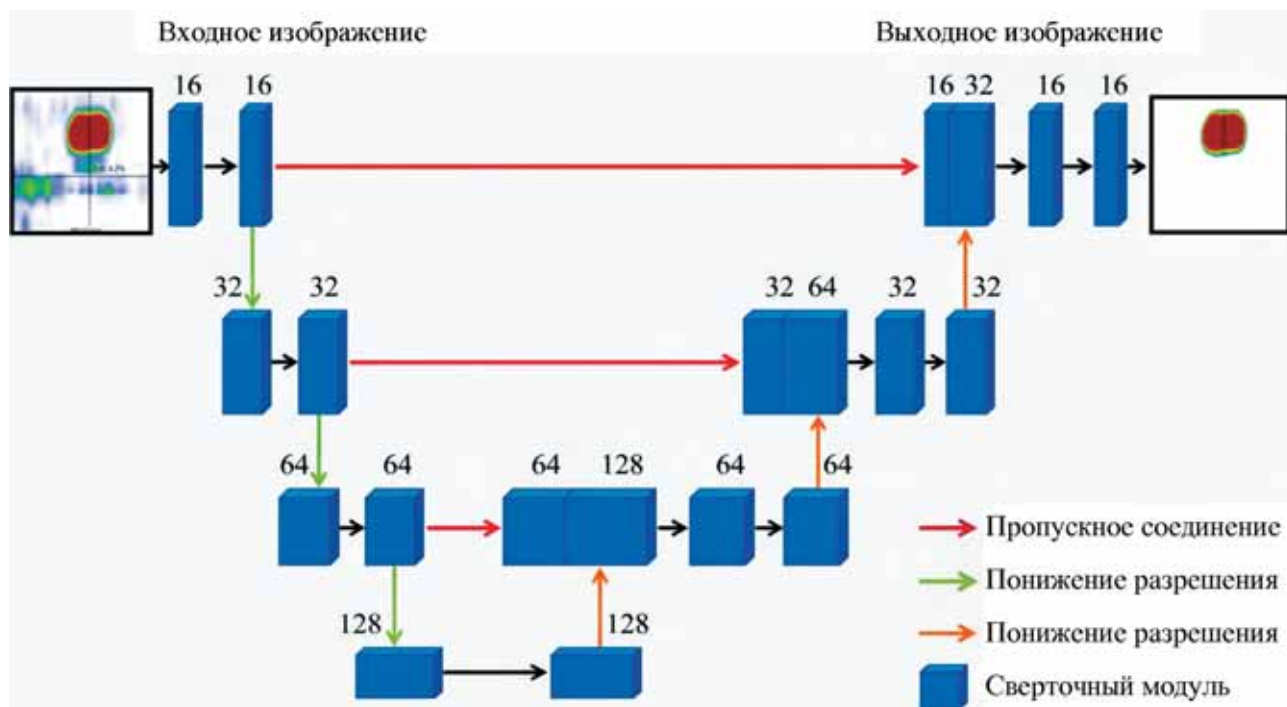


Рис. 1. Архитектура нейросети U-Net:

сеть состоит из симметричной структуры кодера (слева) и декодера (справа), соединенных пропускными связями (красные стрелки), что позволяет точно локализовать признаки в изображении. Каждый блок (синий прямоугольник) представляет собой сверточный модуль, количество фильтров указано над блоками. Зеленые стрелки обозначают понижение разрешения (Downsampling), оранжевые — повышение (Upsampling). Такая архитектура эффективно применяется для сегментации изображений, включая задачи распознавания дефектов на ультразвуковых сканах

связанные с недостаточной гибкостью, — заранее заданные критерии могут не учитывать всего многообразия дефектов. Дополнительно в программных комплексах применялись полуавтоматические инструменты разметки: оператор задавал границы индикации (выделение области), после чего система автоматически вычисляла численные параметры (амплитуда, координаты, условные размеры, протяженность по уровню -6 дБ) и формировала таблицу дефектов [3].

Критерии оценки регламентированы нормативной документацией, а принятие решения по каждому дефекту и сварному соединению в целом, как правило, осуществляется оператором на основе «ручной» интерпретации данных. Основное ограничение такого класса решений — жесткость правил при изменении геометрии, уровня структурного шума, настроек, схем прозвучивания или качества акустического контакта, устойчивость пороговой логики снижается, а часть пограничных случаев требует дополнительной интерпретации.

В настоящей работе приведены примеры применения методов машинного обучения (в том числе искусственного интеллекта) при обработке данных ультразвукового контроля с фазированными решетками, а также пример промышленной реализации,

в которой автоматизированный анализ доведен до уровня протоколирования дефектов и оценки качества сварного соединения в соответствии с требованиями выбранных нормативно-технических документов.

Современный этап развития методов автоматизации НК связан с использованием искусственных нейронных сетей и методов глубокого обучения. Нейросети способны самостоятельно выявлять сложные закономерности в больших массивах данных и принимать решения на основе обобщенных признаков, что делает их привлекательными для задач дефектоскопии.

В последние годы появилось много работ, демонстрирующих эффективность глубоких нейросетей в этой области. Так, сверточные нейронные сети (convolutional neural network CNN) уже показали способность обнаруживать дефекты на ультразвуковых данных с точностью на уровне квалифицированного эксперта [1]. Автоматизация на базе нейросетей позволяет уменьшить влияние человеческого фактора и обрабатывать большие объемы многоканальных данных значительно быстрее человека [2, 4].

Одним из специализированных типов CNN является архитектура U-Net, схема которой приведена на рис. 1.

Обнаружение и классификация дефектов

Одной из первых целей применения технологий машинного обучения в ультразвуковом контроле стало **обнаружение наличия дефекта и классификация его типа** по данным, полученным с фазированных решеток. Традиционно оператор просматривает сканы В, С, D, TOP/END VIEW в поисках дефектов.

Простейшая постановка задачи — бинарная классификация: имеется дефект в данном участке данных или нет. Для ее решения используются сверточные нейронные сети, которые анализируют либо непосредственно А-сканы, либо другие виды сканов, сформированные на их основе. Например, в работе Siljama O. с соавторами [1] показано, что современная CNN может обнаруживать трещины в многоканальных PAUT-данных сварных швов, достигая чувствительности и специфичности, сопоставимых с интерпретацией данных высококвалифицированного специалиста.

Дальнейшее развитие получило решение задачи многоклассовой классификации, когда нейросеть не только выявляет наличие дефекта, но и определяет его тип (например, трещина, непровар, скопление пор и т.д.). Для этого архитектуры CNN дополняются выходным слоем на несколько классов либо используются более сложные модели. Так, Pyle M. с соавторами [5] обучили глубокую сеть на базе сверточной архитектуры распознавать тип трещин в сварных швах по данным PAUT. В исследовании Vai X. с соавторами [6] сравнивается эффективность классических байесовских подходов и методов машинного обучения при оценке характеристик рассеяния ультразвукового сигнала; результаты показали, что нейросеть способна надежно идентифицировать и характеризовать дефекты. Эти работы




Рис. 2. Выбор алгоритмов оценки

демонстрируют, что глубинное обучение справляется не только с задачей обнаружения наличия дефекта, но и может извлекать информацию о его природе.

Важно отметить, что после 2021 г. акцент смещается от простой фиксации наличия дефекта к автоматизированному выделению дефектной области на S-скане, оценке геометрических параметров и последующему принятию решения о допустимости по установленным критериям.

Поэтому все чаще применяются модели сегментации, которые выделяют область дефекта на секторных изображениях и тем самым создают основу для последующего вычисления размеров и устойчивого отделения дефектов от ложных индикаций [7, 8]. Параллельно развивается направление многозадачных моделей, где в едином алгоритмическом контуре решаются сразу несколько задач: обнаружение, классификация, измерение и оценка качества. Обзорные публикации подчеркивают, что именно такие многоканальные и многозадачные архитектуры являются наиболее перспективными для промышленного внедрения, поскольку они

позволяют приблизить автоматическую обработку данных к логике точной расшифровки и снизить разброс результатов при контроле больших объемов данных [2, 4].

При этом ключевым ограничением большинства академических решений остается то, что они часто завершаются на уровне метрик распознавания, тогда как практическая задача включает еще один, наиболее ответственный шаг — приведение результата к формату протоколирования: присвоение шифров дефектов, расчет нормируемых параметров и формирование итогового заключения в соответствии с принятыми критериями. Именно этот переход от распознавания к формализованной оценке определяет прикладную ценность системы и ее применимость в производственном контуре [9].

Промышленной реализацией такого подхода является нейросеть SIGNAL AI.

Нейросеть SIGNAL AI

Компания ООО «Новотекс Системс» разработала собственную многоходовую сверточную нейросеть SIGNAL AI, предназначенную для автоматической

интерпретации ультразвуковых данных по требованиям ПАО «Транснефть». В ее основе лежат алгоритмы глубокого обучения, обеспечивающие исключение из анализа эхосигналов от геометрии, выявление, интерпретацию и присвоение шифра индикациям с последующей оценкой их соответствия требованиям выбранного нормативно-технического документа (рис. 2).

На рис. 3 представлены результаты автоматической интерпретации дефектов сварного шва диаметром 219 мм согласно РД-25.160.10-КТН-0016-23 «Не разрушающий контроль сварных соединений при строительстве и ремонте магистральных трубопроводов». Каждому дефекту присваивается шифр, рассчитываются условные протяженности допустимых по амплитуде сигналов и на основании совокупной оценки формируется заключение о годности сварного соединения.

В режиме оценки по РД-19.100.00-КТН-0330-21 «Техническое диагностирование резервуаров. Ультразвуковой контроль сварных соединений стенки резервуаров» нейросеть SIGNAL AI выполняет оценку всего спектра классификационных признаков, предусмотренных данным нормативно-техническим документом. Для каждого эхосигнала система сопоставляет амплитудные, пространственные и геометрические параметры с регламентированными критериями, включая оценку отношения амплитуды к структурному шуму и оценку отношения амплитуд на противоположных датчиках.

Автоматически рассчитываются суммарные протяженности и эквивалентные площади дефектов на каждом оценочном участке, а также сравнивается суммарная площадь всех дефектов с поперечным сечением сварного шва (рис. 4).

В ходе опытной эксплуатации продолжительностью шесть

№ группы	Тип	Амплитуда	Амплитуда	Координаты начала	Глубина
1	G-1	CC	Ан	201.86%	63.00
2	G-2	CC	Ан	127.94%	64.00
3	G-2	SH	Ад	59.06%	104.00
4	G-2	CC	Ад	76.99%	162.00

Рис. 3. Результат автоматической оценки

Оценочный участок	Максимальная длина	Количество дефектов	Эквивалентная площадь	Площадь поперечного
184.00~209.00	21.00	1	21.61	500.00
185.00~210.00	20.00	1	20.38	500.00
186.00~211.00	19.00	1	19.14	500.00
187.00~212.00	18.00	1	17.90	500.00
188.00~213.00	17.00	1	16.66	500.00
189.00~214.00	16.00	1	15.43	500.00
190.00~215.00	15.00	1	14.19	500.00
191.00~216.00	14.00	1	12.95	500.00
192.00~217.00	13.00	1	10.69	500.00
193.00~218.00	5.00	2	8.43	500.00
194.00~219.00	5.00	2	7.40	500.00
195.00~220.00	5.00	2	6.37	500.00

Рис. 4. Список оценочных участков

месяцев обработана выборка объемом более 1500 ультразвуковых сканов, полученных при контроле сварных швов магистральных нефтепроводов и резервуаров. Результаты автоматизированной обработки сопоставлялись с данными ручной расшифровки.

По итогам сопоставления установлено, что точность присвоения шифров дефектов составила 97,8%. Получено, что среднее время автоматизированного анализа набора данных для одного контрольного участка протяженностью 500 мм не превышает 2 с, тогда как ручная интерпре-

тация занимает, как правило, 5–10 мин в зависимости от количества дефектов. Тем самым обеспечивается существенное сокращение времени на этапе расшифровки и формирования протокола результатов контроля.

Отмечено, что при наличии отражений, обусловленных геометрическими особенностями контролируемого соединения (обратный валик, разнотолщинные соединения и др.), система сохраняет корректность выделения и классификации индикаций за счет анализа совокупности амплитудных, пространственных и геометрических признаков.

Предусмотрен механизм обратной отрицательной связи: корректировки оператора (включая исключение ложных индикаций и уточнение параметров) используются для пополнения данных и последующей адаптации модели.

Применение нейросетей существенно расширяет возможности автоматизированного анализа данных УЗК с фазированными решетками. Уже продемонстрировано успешное обнаружение, классификация и сегментация дефектов на уровне, сравнимом с человеческим, при значительно большей скорости обработки данных. Дальнейшие исследования направлены на повышение надежности и объяснимости этих методов. Можно ожидать, что по мере решения текущих проблем нейросетевые алгоритмы станут неотъемлемой частью средств неразрушающего контроля, повышая объективность и эффективность диагностики во многих отраслях — от энергетики до авиационно-космической промышленности.

Библиографический список

1. **Siljama O., Koskinen T., Jessen-Juhler O., Virkkunen I.** Automated Flaw Detection in Multi-channel Phased Array Ultrasonic Data Using Machine Learning // *Journal of Nondestructive Evaluation*. 2021. Vol. 40, No. 3. DOI: 10.1007/s10921-021-00796-4
2. **Cantero-Chinchilla S., Wilcox P. D., Croxford A. J.** Deep learning in automated ultrasonic NDE — Developments, axioms and opportunities // *NDT & E International*. 2022. Article 102703. DOI: 10.1016/j.ndteint.2022.102703
3. **Olympus** Introduces TomoView 2.9 — The Newest Software to Enhance UT Inspection (электронный ресурс) // *NDT.net*. URL: <https://www.ndt.net/search/docs.php?id=8371> (дата обращения: 23.12.2025).
4. **Na Y., He Y., Deng B., et al.** Advances of Machine Learning in Phased Array Ultrasonic Non-Destructive Testing: A Review // *AI*. 2025. Vol. 6, No. 6. Article 124. DOI: 10.3390/ai6060124
5. **Pyle M., 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. 99. DOI: 10.1109/TUFFC.2020.30458472
6. **Bai X., Bourdais F. L., Miorelli R., et al.** Ultrasonic defect characterisation using Bayesian inversion and machine learning // *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*. 2021. 99. DOI: 10.1109/TUFFC.2021.3084798
7. **Zhang S., Zhang Y.** Automated weld defect segmentation from phased array ultrasonic data based on U-net architecture // *NDT & E International*. 2024. Vol. 146, No. 10. P. 103165.
8. **Chen Y., He S., He D., et al.** Welding defect detection based on phased array images and two-stage segmentation strategy // *Advanced Engineering Informatics*. 2024. Vol. 62. P. 102879. DOI: 10.1016/j.aei.2024.102879
9. **Lee S.-E., Park J., Yeom Y.-T., et al.** Sizing-Based Flaw Acceptability in Weldments Using Phased Array Ultrasonic Testing and Neural Networks // *Applied Sciences*. 2023. Vol. 13, No. 5. P. 3204. DOI: 10.3390/app13053204