

МЕТОДЫ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ ПАРАМЕТРОВ ДЕФЕКТОВ В СВАРНЫХ ШВАХ ПО УЛЬТРАЗВУКОВЫМ СИГНАЛАМ

© 2020 г. К. Судхира^{1,*}, Н.М. Нандхита^{1,**}, В. Пайнени Бхавагна Венкат Сай^{1,***}, Налламоту Виджай Кумар^{1,****}

¹Институт науки и технологий Сатибама

Джепниаар Нагар, Старая дорога Мамаллапурам, Ченнай 600119

E-mal: *Sudhirasatya@gmail.com; ** nandhi_n_m@yahoo.co.in; ***bhavagn@gmail.com; ****nvk012@gmail.com

Поступила в редакцию 01.05.2020; после доработки 22.06.2020

Принята к публикации 17.07.2020

Описана компьютерная интерпретация ультразвуковых сигналов, отображающих дефекты сварных деталей. В данном исследовании изучается применимость долгой краткосрочной памяти (ДКСП) для определения параметров дефектов. Благодаря преимуществу ДКСП, первый метод включает обучение ДКСП непосредственно на сигналах, используемых в качестве входных данных, и тестирование его способности обнаруживать дефекты по входным сигналам. Большой разброс в длине входных последовательностей приводит к разреженности в других последовательностях, это влияет на общую точность. Следовательно, во втором методе ДКСП обучается также и на характеристиках сигналов, было обнаружено, что общая точность контрольных данных составляет 67,64 %. Эти характеристики являются статистическими параметрами, полученными из коэффициента аппроксимации входных сигналов. Входные сигналы разлагаются по новому вейвлет-шаблону.

Ключевые слова: ультразвуковой контроль, сварные швы, дефекты, ДКСП, точность, чувствительность.

DOI: 10.31857/S013030822010005X

1. ВВЕДЕНИЕ

Технологические достижения в сварочном производстве приводят к массовому производству сварных конструкций. Следовательно, оценка качества сварных деталей является обязательной перед их поставкой потребителям. Ультразвуковой контроль (УЗК) — это наиболее широко используемый метод неразрушающего контроля (НК), используемый для определения характеристик как поверхностных, так и подповерхностных дефектов. УЗК, в целом, представлен 2 методами, а именно: эхоимпульсный (анализ отраженной волны) и дифракционно-временной (ДВ), в котором строится и анализируется прошедшая волна. Если в сварной детали присутствует дефект, высокочастотный ультразвуковой сигнал отражается от его поверхности. Затем этот сигнал строится и анализируется для определения характеристик дефекта.

Определение характеристик дефекта означает определение типа дефекта, его расстояния от поверхности, форму и ориентацию. В данной работе определялась такая характеристика, как тип дефекта. В этой области ведутся обширные исследования. Munira и др. [1] предложили алгоритм классификации таких дефектов, как шлаки, несплавления, непровары, трещины и пористость, с использованием нейронной сети. S Esther Florence и др. [2] разработали искусственную нейронную сеть (ИНС), основанной на методах классификации дефектов с использованием в качестве ключевого параметра амплитуду пика дефекта. Licheng Liu и др. [3] использовали взвешенное совместное разреженное представление (ВСП) вместе со взвешенным одновременным ортогональным сопоставлением, чтобы удалить шум и общую информацию, полученную из того же подпространства изображения. BorMojškerc и др. [4] предложили алгоритм оценки стыков стеклопластика и полиамидного клея по амплитуде отраженного сигнала. K.Sudheera и др. [6] разработали автоматизированный компьютерный инструмент для улучшения обнаружения и сегментации дефекта сварного шва по рентгенограммам. Varun Gupta и др. [7] обнаружили, что анализ главных компонентов (АГК) очень подходит для классификации данных. Wang Xiaokai и др. [8] проанализировали дефекты точечной сварки в 100 образцах. Характеристики были определены, а дефекты классифицированы с помощью машины опорных векторов оптимизации роя частиц.

Из-за сложности выходного сигнала достижение чувствительности порядка 90+ по-прежнему является первоочередной задачей. Эффективность таких методов сильно зависит от методов, используемых для определения признаков, выбора признаков, решений по анализу во временной или спектральной области, необходимости в классификаторе и т.д. Предлагаемая работа направлена на изучение возможности использования долгой краткосрочной памяти (ДКСП) для определения характеристик дефекта. ДКСП обучается с использованием сигналов, используемых в качестве входных данных, и оценивается эффективность. Кроме того, ДКСП обучается на характеристиках

сигналов (с использованием нового вейвлет-шаблона). Эффективность измеряется с точки зрения чувствительности и точности.

Раздел 2 посвящен получению сигналов и представляет собой, в целом, метадаанные. Предлагаемая методика объясняется в разделе 3. Результаты обсуждаются в разделе 4, а в разделе 5 представлено заключение и перспективы дальнейшей работы.

2. БАЗА ДАННЫХ ДЛЯ ИССЛЕДОВАНИЯ

Для проведения исследовательской работы необходимо получить ультразвуковые сигналы от дефектов, а именно несплавления, непровара, пористости, включения шлака и трещины как в углеродистой, так и в нержавеющей стали (табл. 1). Ультразвуковой датчик, используемый для регистрации сигналов, был АМ70-4L с размером пьезоэлемента 8×9, углом ввода 70 град и частотой 4 МГц. Длина, ширина и толщина пластин из углеродистой стали 145, 143 и 20 мм соответственно.

Таблица 1

Количество сигналов от каждого дефекта

№	Дефект	Количество сигналов
1	Трещина	16
2	Несплавление	19
3	Непровар	13
4	Пористость	15
5	Шлак	12

Сигналы (рис. 1—5) показывают изменение пакета сигнала для всех дефектов. Для ручного интерпретатора форма пакета, амплитуда пика пакета, боковые лепестки, амплитуда боковых лепестков, частота импульсов, соотношение амплитуд между пиком и его боковыми лепестками, положение пакета — важные характеристики. Однако вышеупомянутые характеристики не могут быть четко понятны при ручной интерпретации, и поэтому подход к работе давно сдвинулся в сторону компьютерной интерпретации.




Рис. 1. УЗ-сигналы, изображающие трещину в углеродистой стали.

3. ПРЕДЛАГАЕМАЯ МЕТОДИКА

Дискретное вейвлет-преобразование — лучший выбор для анализа нестационарных сигналов (пакетов). Основная проблема заключается в выборе вейвлета, порядка и уровня разложения. Первоначально ультразвуковые сигналы были разложены с помощью различных вейвлетов, которые




Рис. 2. УЗ-сигналы, изображающие несплавление в углеродистой стали.




Рис. 3. УЗ-сигналы, изображающие неспрар в углеродистой стали.




Рис. 4. УЗ-сигналы, изображающие пористость в углеродистой стали.




Рис. 5. УЗ-сигналы, изображающие шлаки в углеродистой стали.

приведены в литературе. Однако удовлетворительных результатов получено не было. Это потому, что сигнал и материнский вейвлет имеют разные формы. Вейвлет-разложение дает хорошие результаты только тогда, когда форма исходного вейвлета и сигнала схожа. Имея это в виду, материнский вейвлет создается заново после разложения сигнала от дефекта несплавления на основе вейвлета biog2.2 . Коэффициент аппроксимации седьмого уровня рассматривается как материнский вейвлет. Разложение исходного сигнала, изображающего несплавление, и детализирующие коэффициенты с использованием материнского вейвлета и материнский вейвлет показаны на рис. 6.

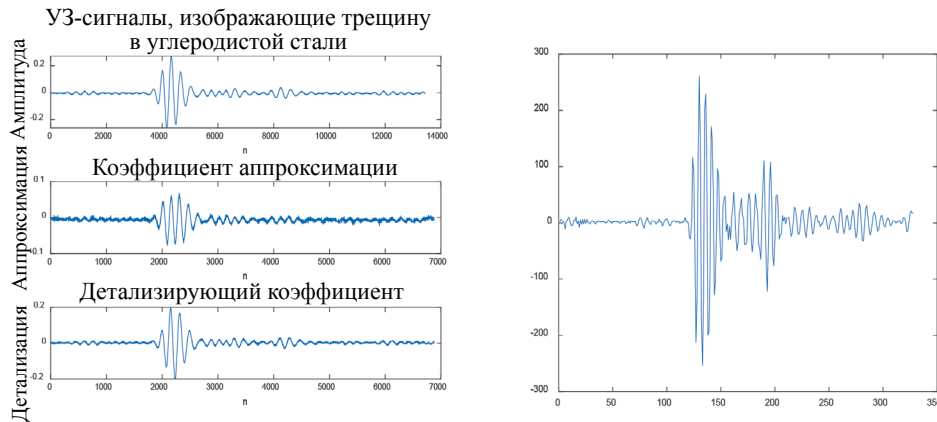


Рис. 6. Исходный сигнал, коэффициенты аппроксимации, детализирующие коэффициенты и вейвлет, используемые для разложения сигнала.

Разложение исходного сигнала, изображающего несплавление, на коэффициенты аппроксимации и детализации показано на рис. 6.

3.1. Целесообразность характеристик

Статистические характеристики получены для коэффициента аппроксимации на 74 сигналах, которые разложены с использованием предложенного вейвлета. Статистические параметры для 74 сигналов показаны на рис. 7.

По оси X от 1 до 15 обозначают сигнал, изображающий трещину, от 16 до 34 — несплавление, от 35 до 47 — непровар, от 48 до 62 — пористость и с 63 до 74 — включение шлака. Из рис. 3 видно, что статистические параметры практически одинаковы для трещин и несплавления, но разные для непровара. Точно так же разные параметры для включений шлака. Для остальных групп к таким выводам прийти нельзя. В двух словах, межклассовая дисперсия высока для статистических параметров трещин и несплавления. Также межклассовая дисперсия для включений шлака высока по сравнению с остальными группами. Затем проводится анализ на основе внутриклассовой дисперсии. В табл. 2 показана внутриклассовая дисперсия статистических параметров для пяти различных дефектов.

Таблица 2

Внутриклассовая дисперсия статистических параметров для пяти различных дефектов

Параметр/Дефект	Трещина	Несплавление	Непровар	Пористость	Шлак
Среднее значение	0,000851	0,003034	0,000789	0,021747	0,033554
Медианное значение	0,003121	0,003179	0,000788	0,022555	0,034138
Минимум	0,036594	0,118854	0,03287	0,488074	0,706949
Максимум	0,045133	0,129633	0,038569	0,493868	0,796905
Диапазон	0,066476	0,248679	0,071324	0,981348	1,50365
Стандартное отклонение	0,006847	0,042401	0,006369	0,135118	0,113071
CAO #1	0,187005	0,028756	0,002346	0,056023	0,069338
L2-норма	2,504558	3,110656	0,652156	22,82371	45,93218
Максимум-норма	0,113993	0,132525	0,222084	0,492637	0,795632

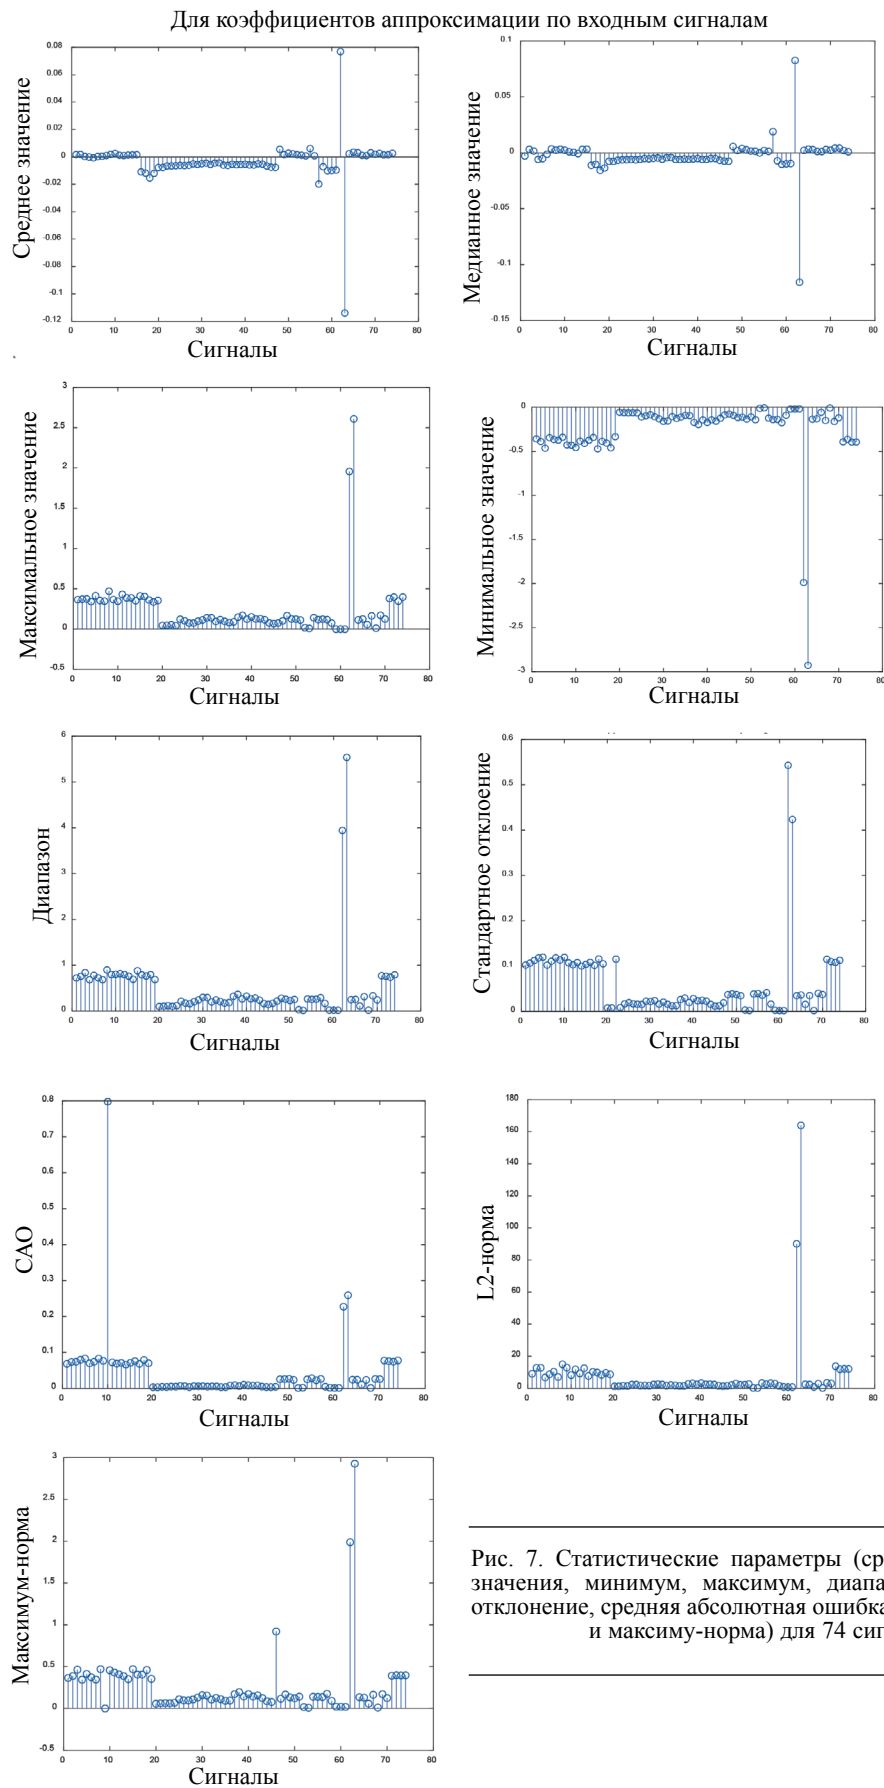


Рис. 7. Статистические параметры (среднее, медианное значения, минимум, максимум, диапазон, стандартное отклонение, средняя абсолютная ошибка (CAO), L2-норма и максимум-норма) для 74 сигналов.

Если иметь порог на уровне 0,05, то внутренний класс меньше порогового значения для среднего и медианного значения. Минимальное значение, максимальное значение и стандартное отклонение также имеют внутриклассовую дисперсию меньше порогового значения. L2-норма не может рассматриваться как значимый статистический параметр, поскольку внутриклассовая дисперсия высока. Следовательно, для дальнейшего анализа L2-норма не рассматривается. Поэтому примеры для обучения нейронной сети обратного распространения (НОР) приведены в табл. 3.

Таблица 3

Примеры для обучения НОР-классификатора

Среднее значение	Медианное значение	Минимум	Максимум	Диапазон	Стандартное отклонение	САО #1	Максимум-норма	О/р
0,0003	0,0015	0,374	-0,4634	0,8374	0,1124	0,07391	0,4634	10
-0,0109	-0,0111	0,4041	-0,3855	0,7896	0,1082	0,07566	0,4041	8
-0,0117	-0,0103	0,3604	-0,4047	0,7651	0,1018	0,06843	0,4047	8
-0,015	-0,0156	0,3354	-0,46	0,7954	0,1158	0,07873	0,46	8
-0,0059	-0,0059	0,081	-0,09172	0,1727	0,01266	0,003309	0,0917	6
-0,0061	-0,0059	0,0882	-0,09448	0,1827	0,01281	0,0035	0,0944	6
-0,0053	-0,0055	0,1484	-0,1718	0,3202	0,02621	0,007513	0,1718	6
0,0055	0,0056	0,1665	-0,1113	0,2778	0,03706	0,02532	0,1665	4
0,0016	0,0020	0,1244	-0,133	0,2574	0,0388	0,02568	0,133	4
0,0027	0,0038	0,122	-0,1086	0,2306	0,03719	0,02635	0,122	4
-0,114	-0,1157	2,609	-2,927	5,536	0,4235	0,2592	2,927	2
0,0023	0,0022	0,1125	-0,1345	0,247	0,03462	0,02414	0,1345	2
0,0034	0,0033	0,1237	-0,1299	0,2535	0,03629	0,02407	0,1299	2

Соотношение между ожидаемыми и реальными значениями для определения характеристик дефекта сварного шва с помощью НОР показано на рис. 8 (1 — трещина, 2 — несплавление, 3 — непровар, 4 — пористость, 5 — шлак). Чувствительность к трещинам, несплавлениям, непроварам, пористости и включению шлака для ряда контрольных тестов посредством НОР составляет 85,74, 50, 33,33, 25 и 0 % соответственно. Общая точность определения дефектов на основе НОР составляет 40,54 %.

Соотношение между ожидаемыми и реальными выходными значениями (тестовые данные) при использовании НОР




Рис. 8. Соотношение между ожидаемыми и реальными значениями для определения характеристик дефекта сварного шва с помощью НОР.

Шлак не может быть идентифицирован посредством НОР, потому что внутриклассовая дисперсия для шлака относительно высока для большинства статистических параметров. Это означает, что сигналы, изображающие шлак, отражают различные характеристики и, следовательно, изменяющиеся статистические параметры. В попытке повысить чувствительность определения характеристик дефектов используются рекуррентные нейронные сети (РНС). Поскольку РНС может принимать только один входной параметр, выбирается статистический признак с меньшей внутриклассовой дисперсией. Из табл. 2 видно, что среднее значение имеет наименьшую внутриклассовую дисперсию и, следовательно, выбирается для обучения РНС для определения характеристик дефектов.

Соотношение между ожидаемыми и реальными значениями при определении параметров дефектов сварного шва с помощью РНС показано на рис. 9 (1 — трещина, 2 — несплавление, 3 — непровар, 4 — пористость, 5 — шлак). Чувствительность к трещине, неплавлению, непровару, пористости и включению шлака для ряда контрольных тестов посредством РНС составляет 100, 50, 50, 37,5 и 0 % соответственно. Общая точность определения дефектов на основе РНС составляет 45,71 %.




Рис. 9. Соотношение между ожидаемыми и реальными значениями для определения характеристик дефекта сварного шва с помощью РНС.

Чувствительность РНС выше, чем у НОР, при определении трещины, неплавления, непровара и пористости. Однако шлак также не удалось идентифицировать с помощью РНС. Это требует использования другой сети, которая успешно бы определяла наличие включений шлака.

3.2. Долгая краткая память. Обзор

Hochreiter [5] выявил следующие недостатки в НОР из-за ошибки, изменяющейся по экспоненте: наличие отрицательных весов означает, что простое увеличение количества скрытых слоев не может способствовать значительному обновлению веса (во время обратного распространения сигналов ошибки) и, следовательно, повышению производительности. Кроме того, конфликтующие ошибки могут возникать как входы в один и тот же нейрон, тем самым подавляя друг друга. Следовательно, это приводит к обновлению веса до нуля.

Поэтому были разработаны сети с долгой краткосрочной памятью (ДКСП) с использованием блоками памяти и вентиляей. Вентили решают, следует ли передавать предыдущий вывод на следующий уровень или нет. Даже если принято решение передать вывод на следующий уровень, вывод преобразуется с использованием функции «tanh», а затем передается. Еще одно преимущество ДКСП заключается в том, что он может запоминать информацию, которая была передана даже на самом раннем этапе, что невозможно в НОР или РНС (Sepp Hochreiter and Jurgen Schmidhuber [5]). Предлагаемая методика представлена на древовидной диаграмме (рис. 10).

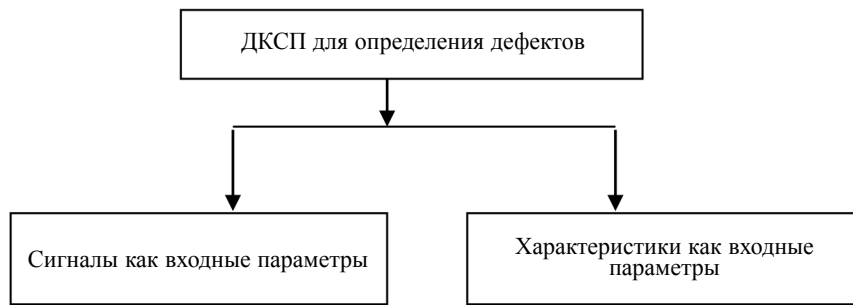


Рис. 10. Древовидная диаграмма, показывающая два типа ДКСИ для определения параметров дефектов.

3.3. ДКСИ для определения дефектов с сигналами на входах

Данные ДКСИ сети могут использоваться при определении параметров дефектов путем подачи либо входных сигналов, либо известных признаков. Из 74 сигналов, связанных с пятью различными типами дефектов, 50 % сигналов используются для обучения, а 50 % — для тестирования. Входные сигналы сохраняются в ячейке памяти, а выходные метки, соответствующие входам, сохраняются в массиве ячеек.

Тип входных данных — «двойной», а тип выходных — «категориальный». Поскольку входной вектор является массивом, могут быть заданы последовательности различной длины. Но отклонение в длине последовательности отрицательно сказывается на производительности сети. Также обнаружено, что сеть хорошо работает на больших величинах, чем числа меньше 1. В данной работе величины умножаются на 10000 (предварительная обработка данных). Кроме того, размер пакета должен быть 30, а длина последовательности должна отражать фактическую длину сигнала. Количество нейронов равно 100. Эффективность определяется с учетом матрицы неточностей, как указано в табл. 4 и 5 для обучающих и тестовых наборов данных соответственно. Из табл. 4 видно, что сеть не тренировалась, хорошо характеризуя включения, непровары и несплавления. Общая точность 78,37 %.

Таблица 4

Матрица неточностей при определении дефектов на сигналах на входах ДКСИ (обучающий набор данных)

Дефекты	Трещина	Несплавление	Непровар	Пористость	Шлак	Чувствительность
Трещина	8	0	0	0	0	100 %
Несплавление	2	7	0	0	0	77,77 %
Непровар	0	0	5	2	0	71,42 %
Пористость	0	0	0	7	0	100 %
Шлак	1	2	0	1	2	33,33 %

Таблица 5

Матрица неточностей при определении дефектов на сигналах на входах ДКСИ (тестовый набор данных)

Дефекты	Трещина	Несплавление	Непровар	Пористость	Шлак	Чувствительность
Трещина	3	0	0	2	2	42,85 %
Несплавление	2	0	0	8	0	0 %
Непровар	2	2	0	1	1	0 %
Пористость	1	4	1	1	1	12,5 %
Шлак	0	1	1	3	1	16,67 %

Из табл. 5 следует, что непровар и несплавление не могут быть идентифицированы. Хотя другие дефекты и были выявлены, чувствительность была очень низкой. Сложность в опреде-

лении параметров дефектов объясняется сложностью сигналов, т.е. сигналы от разных дефектов имеют одинаковый коэффициент во временной области. Для хороших результатов входные характеристики должны иметь меньшую внутриклассовую дисперсию и высокую межклассовую дисперсию. В этом случае амплитуды сигналов (подаваемых в качестве входных) не имеют меньшей внутриклассовой дисперсии или высокой межклассовой дисперсии. Кроме того, количество выбросов больше у непроваров и несплавлений, т.е. характеристики сигналов от несплавления напоминают характеристики пористости и трещины. Аналогичным образом, сигналы от непроваров аналогичны сигналам от несплавления и трещины. В двух словах, представление сигналов во временной области не может охарактеризовать неоднородность, спектральные особенности или всплесковый характер сигналов дефектов. В связи с этим, точность тестового набора данных составляет 13,15 %. Таким образом, необходимо преобразовывать эти сигналы в спектральной области и выделять их особенности.

3.4. ДКСП для определения дефектов с характеристиками на входах

Статистические параметры табл. 2 используются для тренировки нейросети с архитектурой долгой краткосрочной памяти. Эти характеристики также умножаются на 10000 (предварительная обработка данных), чтобы улучшить способность определения параметров посредством ДКСП. Из параметров для 74 сигналов 50 % используется для обучения, а еще 50 % — для тестирования. Эффективность анализируется с помощью матрицы неточностей как для обучающих, так и для тестовых наборов данных, и рассчитывается чувствительность (табл. 6 и 7). Точность тренировки 94,59 % при 100 % чувствительности для пористости, шлаков и трещин. Матрица неточностей для тестового набора данных (который не используется для обучения) приведена в табл. 7.

Таблица 6

Матрица неточностей при определении дефектов на сигналах на входах ДКСП (обучающий набор данных)

Дефекты	Трещина	Несплавление	Непровар	Пористость	Шлак	Чувствительность
Трещина	8	0	0	0	0	100 %
Несплавление	0	8	1	0	0	88,89 %
Непровар	0	1	6	0	0	85,71 %
Пористость	0	0	0	7	0	100 %
Шлак	0	0	0	0	6	100 %

Таблица 7

Матрица неточностей при определении дефектов на сигналах на входах ДКСП (тестовый набор данных)

Дефекты	Трещина	Несплавление	Непровар	Пористость	Шлак	Чувствительность
Трещина	6	0	0	0	1	85,71 %
Несплавление	0	5	5	0	0	50 %
Непровар	0	1	5	0	0	83,33 %
Пористость	3	0	1	4	0	50 %
Шлак	1	0	0	2	3	50 %

4. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Чувствительность при определении трещин и непроваров составляет 85,71 и 83,33 % соответственно. Чувствительность к несплавлению, пористости и шлаку составляет 50 %, а общая точность составляет 67,64 %. Из последних столбцов табл. 2—7 установлено, что чувствительность больше для ДКСП, обученного на особенностях сигналов, чем для ДКСП, обученных на самих сигналах. Что и показано на рис. 11.

Из рис. 11 видно, что способность обученной на параметрах сигналов нейросети ДКСП определять дефекты увеличилась по сравнению со способностью ДКСП, обученной на сигналах. Чув-

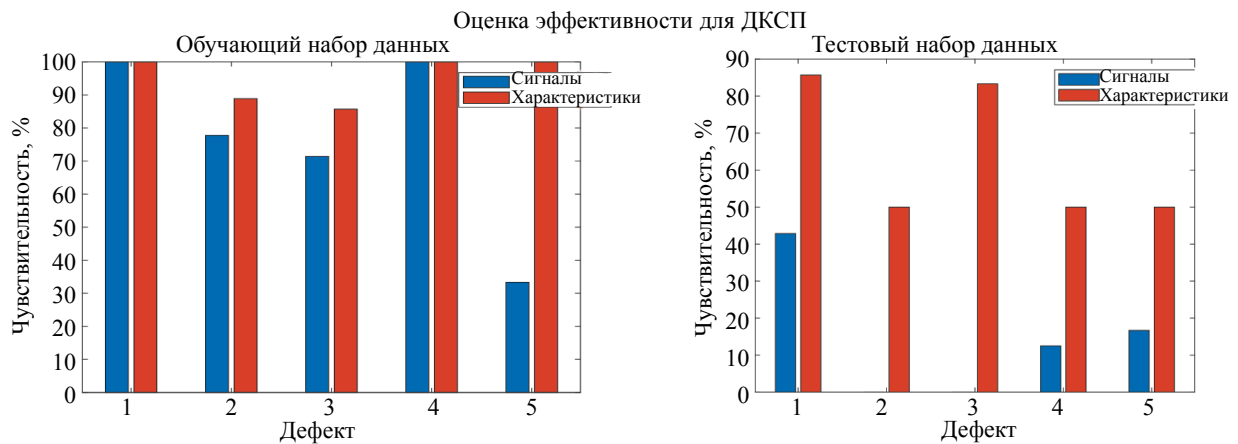


Рис. 11. Анализ чувствительности для ДКСП, обученной на сигналах и их параметрах (обучающий и тестовый набор данных).

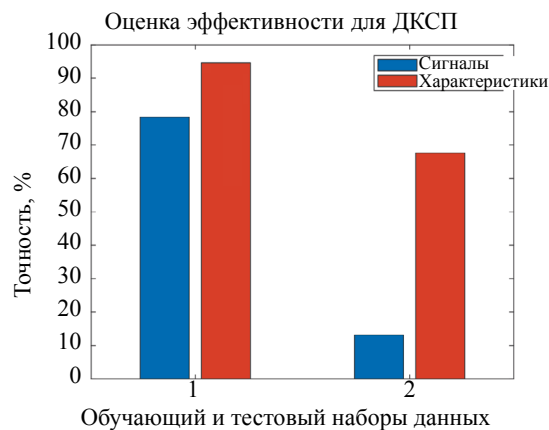


Рис. 12. Сравнение точности для нейросетей ДКСП, обученных на сигналах и их параметрах.

ствительность увеличилась не только для обучающего набора данных, но и для тестового набора. Чем меньше разреженность входного вектора, тем выше точность определения характеристик дефекта (рис. 12).

5. ЗАКЛЮЧЕНИЕ И ПЕРСПЕКТИВЫ ДАЛЬНЕЙШЕЙ РАБОТЫ

В этой работе РНС и ДКСП используются для распознавания дефектов сварки по ультразвуковым сигналам. ДКСП обучается непосредственно с использованием сигналов в качестве входных данных, и изучается ее эффективность. Установлено, что общая точность составляет 78,37 и 13,15 % для обучающих и тестовых наборов данных соответственно. Чтобы повысить точность определения, параметры сети ДКСП изменяются, а затем обучаются на характеристиках, извлеченных из коэффициента аппроксимации. Общая точность увеличилась до 94,59 и 67,64 % для обученных и тестовых наборов данных соответственно. Эффективность сети косвенно связана с разреженностью входного набора данных и отклонением длины последовательности.

Однако точность обученной на особенностях сигналов ДКСП может быть увеличена. Кроме того, разложение сигналов остановилось на самом первом уровне. Можно изучить влияние уровня разложения на внутриклассовую дисперсию и межклассовую дисперсию статистических характеристик. Также в исследовательской базе было всего 74 сигнала. Предлагаемая процедура распознавания дефектов на основе ДКСП может быть расширена за счет большой базы данных. Также можно определить ориентацию, глубину и форму дефекта.

СПИСОК ЛИТЕРАТУРЫ

1. *Munira Nauman, Kima Hak-Joon, Parka Jinhyun, Songa Sung-Jin, Kang Sung-Sik.* Convolutional neural network for ultrasonic weldment flaw classification in noisy conditions. Doi.org/10.1016/j.ultras.2018.12.001 Ultrasonics
2. *Esther Florence S., Vimal Samsingh R., Babu Reddy Vimalaswar.* Artificial intelligence based defect classification for weld joints / 2nd International conference on Advances in Mechanical Engineering (ICAME 2018) IOP Conf. Series: Materials Science and Engineering 402 (2018) 012159 doi:10.1088/1757-899X/402/1/012159
3. *Liu Licheng, Chen Long, Chen C.L. Philip, Tang Yuan Y., Pun Chi Man.* Weighted Joint Sparse Representation for Removing Mixed Noise in Image // IEEE Transactions on cybernetics. 2017. V. 47. No. 3. P. 600—611.
4. *Mojškerc Bor, Kek Tomaž, Grum Janez.* Ultrasonic Disbond Detection in Adhesive Joints // Proc. of the 14th International Conference of the Slovenian Society for Non-Destructive Testing Application of Contemporary Non-Destructive Testing in Engineering. September 4—6, 2017, Bernardin, Slovenia.
5. *Hochreiter Sepp and Schmidhuber Jurgen.* Long Short Term Memory / Neural Computation 9(8): December 1997. P. 1735—80. DOI: 10.1162/neco.1997.9.8.1735
6. *Sudheera K., Nandhitha N.M.* Computer Aided Radiograph Interpretation Tool For Defect Characterization From Weld Plates, June 2019 // Russian Journal of Nondestructive Testing. 2019. V. 55. No. 6. P. 481—488. DOI: 10.1134/S1061830919060081.
7. *Gupta Varun, Singh Ramveer, Singh Gavendra, Singh Rajvir.* An Introduction to Principle Component Analysis and its Importance in Biomedical Applications // 2011 International Conference on Life Science and Technology. Singapore. 2011. V. 3. P. 29—33.
8. *Wang Xiaokai, Guan Shanyue, Hua Lin, Wang Bin, He Ximing.* Classification of spot-welded joint strength using ultrasonic signal time-frequency features and PSO-SVM method // Ultrasonics. January, 2019. V. 91. P. 161—169. doi.org/10.1016/j.ultras.2018.08.0142019