

УДК 004.8

В.В. Шишкин, Д.И. Стенюшкин, М.Г. Брон

МАТЕМАТИЧЕСКИЕ МОДЕЛИ И МЕТОДЫ ДЛЯ РАСШИФРОВКИ УЛЬТРАЗВУКОВЫХ ДЕФЕКТОГРАММ ЖЕЛЕЗНОДОРОЖНЫХ РЕЛЬСОВ В РЕАЛЬНОМ ВРЕМЕНИ

Шишкин Вадим Викторинович, кандидат технических наук, доцент, окончил радиотехнический факультет Ульяновского политехнического института. Профессор кафедры «Измерительно-вычислительные комплексы» Ульяновского государственного технического университета, декан факультета информационных систем и технологий УлГТУ. Имеет статьи в области интеллектуального анализа данных. [e-mail: shvv@ulstu.ru].

Стенюшкин Денис Игоревич, окончил факультет информационных систем и технологий УлГТУ. Аспирант кафедры «Измерительно-вычислительные комплексы» УлГТУ. Имеет статьи в области интеллектуального анализа данных. [e-mail: denisstenyushkin@yandex.ru].

Брон Михаил Генрихович, окончил радиотехнический факультет УлГТУ, заместитель директора по НИОКР компании ScanMaster Systems, Ltd. (Израиль). Имеет работы в области ультразвукового контроля в промышленности. [e-mail: misha@scanmaster-irt.com].

Аннотация

В статье представлена система моделей и методов, предназначенных для расшифровки ультразвуковых дефектограмм железнодорожных рельсов в реальном времени в процессе сканирования. Система включает модели и методы для предварительной обработки ультразвуковых данных, включая выборку данных, приведение в диапазон и комбинирование данных отдельных каналов, а также для поиска и классификации дефектов. Предварительная обработка данных основана на выборке ультразвуковых данных с помощью очереди сигналов и их алгебраических преобразованиях для приведения к виду, пригодному для дальнейшей обработки. Поиск и классификация дефектов основаны на применении параллельно функционирующих специализированных классификаторов, представляющих собой искусственные нейронные сети архитектуры Simplified Fuzzy ARTMAP, модифицированные для работы с элементами входных векторов в широком диапазоне значений. Для разрешения возникающих конфликтов предложен метод, основанный на дереве решений. Предложенные модели и методы могут быть эффективно реализованы с применением современных подходов к организации параллельных вычислений. Испытания показали точность распознавания дефектов не ниже 85%.

Ключевые слова: расшифровка дефектограмм, выявление дефектов рельсов, нейронные сети.

MATHEMATICAL MODELS AND METHODS FOR REAL-TIME ANALYSIS OF RAILWAY RAILS ULTRASONIC DEFECTOGRAMS

Vadim Viktorinovich Shishkin, Candidate of Engineering, Associate Professor; graduated from the Faculty of Radio-Engineering at Ulyanovsk Polytechnical Institute; Professor at the Measuring-Computing Complexes Department of Ulyanovsk State Technical University, Dean of the Faculty of Information Systems and Technologies at UlSTU,

an author of articles in the field of automated design of industrial products and intellectual data analysis. e-mail: shvv@ulstu.ru..

Denis Igorevich Stenyushkin, graduated from the Faculty of Information Systems and Technologies at Ulyanovsk State Technical University; Post-Graduate Student at the Measuring-Computing Complexes Department of Ulyanovsk State Technical University, an author of articles in the field of automated design of industrial products and intellectual data analysis. e-mail: denisstenyushkin@yandex.ru.

Michael Genrikhovich Bron, graduated from the Faculty of Radio-Engineering at Ulyanovsk State Technical University; Vice President of R&D in ScanMaster Systems (IRT) Ltd. (Israel); an author of articles in the field of ultrasonic inspection in industry. e-mail: misha@scanmaster-irt.com.

Abstract

The article describes a system of mathematical models and methods devoted to a real-time analysis of the ultrasonic defectograms of railway rails during a testing process. The system includes models and methods for a preliminary ultrasonic data processing including a data reading, a range adjusting and a data combining for separate channels and also for a defect search and classification. The preliminary data processing is based on the ultrasonic data reading with a signal queue and their further algebraic modifications aiming to make them suitable for a further processing. The defect search and classification is based on an artificial neural network of Simplified Fuzzy ARTMAP architecture that is modified in order to deal with the input array elements with a wide value range. A decision making method based on a decision tree is introduced in order to solve the occurring conflicts. The introduced models and methods can be effectively implemented basing on modern parallel computing approaches. The tests showed out that the defect recognition rate is not less than 85%.

Key words: defectogram analysis, rails defects detection, neural networks

ВВЕДЕНИЕ

Ультразвуковой неразрушающий контроль является одним из основных подходов, применяемых в процессах контроля качества железнодорожных рельсов. Методы ультразвукового контроля позволяют выявлять дефекты контролируемого объекта с необходимой точностью и надежностью.

Для визуальной расшифровки дефектограмм, получаемых в ходе ультразвукового контроля, привлекаются эксперты. В этом случае основными недостатками являются:

1. Влияние на получаемые результаты субъективных факторов, связанных с расшифровщиком, таких как квалификация, психоэмоциональное состояние, воздействие отвлекающих факторов, общее самочувствие и т. д.;
2. Низкая производительность труда при ручной расшифровке дефектограмм;
3. Сложность поддержания заданной скорости проведения контроля.

Указанные недостатки могут быть нивелированы средствами автоматизации расшифровки дефектограмм.

Для расшифровки ультразвуковых дефектограмм железнодорожных рельсов разработаны и применяются системы двух типов. Системы первого типа [1] проводят фильтрацию сигналов на основе параметров, задаваемых оператором (пороговое значение амплитуды сигнала, пороговый размер кластера эхо-импульсов и т. д.). В качестве результата оператор получает перечень областей на дефектограмме, в которых вероятно наличие признаков дефектов. Такая фильтрация позволяет сократить объем обрабатываемых оператором данных, однако получаемые результаты все также подвержены влиянию субъективных факторов.

Системы второго типа, выполняющие полностью автоматическую расшифровку дефектограмм [2, 3], позволяют не только определить области на дефектограмме, в которых есть признаки дефектов, но и классифицировать обнаруженные объекты, а также определить некоторые их характеристики. Такие системы имеют следующие особенности:

1. Нацеленность на выявление строго определенных типов дефектов, перечень которых не покрывает весь спектр возможных дефектов рельсов;
2. Неспособность проводить анализ в режиме реального времени при высоких скоростях движения.

Указанные особенности приводят к необходимости применения дополнительных средств для обнаружения дефектов, не выявляемых автоматическим анализом. Отсутствие возможности проводить расшифровку данных в темпе их поступления на высоких скоростях движения датчиков приводит к затруднению локализации дефекта (при расшифровке в условиях лаборатории отсутствует возможность промаркировать рельс) или же снижению эффективности контроля из-за снижения скорости движения дефектоскопа.

Таким образом, применяемые в настоящее время подходы и методы не позволяют в полной мере решить задачу автоматизированной расшифровки ультразвуковых дефектограмм железнодорожных рельсов в реальном времени. Разработка системы математических моделей и методов, решающих эту задачу, и ее реализация в специализированной информационной системе позволят повысить эффективность контроля рельсов, а также надежность и точность получаемых результатов за счет минимизации влияния субъективных факторов.

1 ТРЕБОВАНИЯ К РАЗРАБАТЫВАЕМОЙ СИСТЕМЕ МОДЕЛЕЙ

Для достижения поставленных целей система моделей и методов должна отвечать следующим требованиям:

1. Возможность работы как с одноканальными, так и с многоканальными системами ультразвукового контроля;
2. Учет особенностей применения дополнительных средств настройки процесса контроля, таких, как гейт (gate, [4]);
3. Возможность выявления и классификации всех типов дефектов в предметной области;
4. Вычислительная сложность применяемых алгоритмов должна обеспечивать получение результата в реальном времени при реализации на современных аппаратных платформах (в т. ч. параллельных) при скорости движения датчиков до 80 км/ч;
5. Система должна ориентироваться на представление дефектограммы в виде кортежа амплитуд отраженного сигнала в каждой точке контроля:

$$D = (A_1, A_2, \dots, A_N), \quad (1)$$

где A_i – кортеж амплитуд отраженного сигнала в i -й точке контроля;

N – число таких точек;

и

$$A_i = (a_1, \dots, a_M), \quad (2)$$

где a_j – амплитуда отраженного сигнала на j -м уровне глубины;

M – количество уровней глубины, различаемых ультразвуковой системой.

2 ПРОЦЕСС РАСШИФРОВКИ ДЕФЕКТОГРАММЫ

Предлагаемая общая схема процесса расшифровки дефектограммы показана на рисунке 1. Ее основные этапы – это этап предварительной обработки ультразвуковых данных, включающий выборку данных с датчиков ультразвуковой системы, приведение значений амплитуд в диапазон и комбинирование данных, а также этап поиска дефектов и принятия решения.

Очередь сигналов применяется для выборки исходных данных. Данные каждого канала заносятся последовательно в кортежи одного и того же размера. Каждый сегмент данных затем обрабатывается отдельно.

На следующем шаге данные отдельных каналов, входящие в выборку, комбинируются в единую структуру, которую возможно использовать для поиска признаков дефектов. Поиск дефектов осуществляется параллельно функционирующими специализированными классификаторами.

Решения специализированных классификаторов передаются на вход модуля принятия решений, который разрешает возникшие конфликты в решениях специализированных классификаторов. Принятое окончательное решение является результатом расшифровки данных текущего сегмента. После этого обработка текущей выборки данных завершается, и начинается обработка следующего сегмента.

3 МОДЕЛИ ПРЕДВАРИТЕЛЬНОЙ ОБРАБОТКИ ДАННЫХ

Целью предварительной обработки данных является приведение исходных данных к виду, пригодному для дальнейшей обработки. В рамках предложенной схемы расшифровки дефектограмм для этих целей применяются приведение в диапазон и комбинирование данных датчиков.

Информация о канале ультразвуковой системы, по которому поступает эхо-сигнал, является важной для определения обнаружения и классификации дефекта, т. к. сходные последовательности эхо-сигналов, поступающие с разных датчиков, соответствуют дефектам разных классов. Номер канала кодируется в значении амплитуды эхо-сигнала с помощью приведения в диапазон. Новое значение амплитуды сигнала вычисляется следующим образом:

$$a_n = a_0 + N \cdot M, \quad (3)$$

где a_n – новое значение амплитуды;

a_0 – старое значение амплитуды;

N – условный номер канала;

M – количество возможных значений амплитуды (в большинстве ультразвуковых систем – 256).

При проведении контроля многоканальными ультразвуковыми системами эхо-импульсы от большинства дефектов поступают сразу по нескольким каналам. Для обеспечения надежного обнаружения и корректной классификации дефектов в этом случае необходимо совмест-

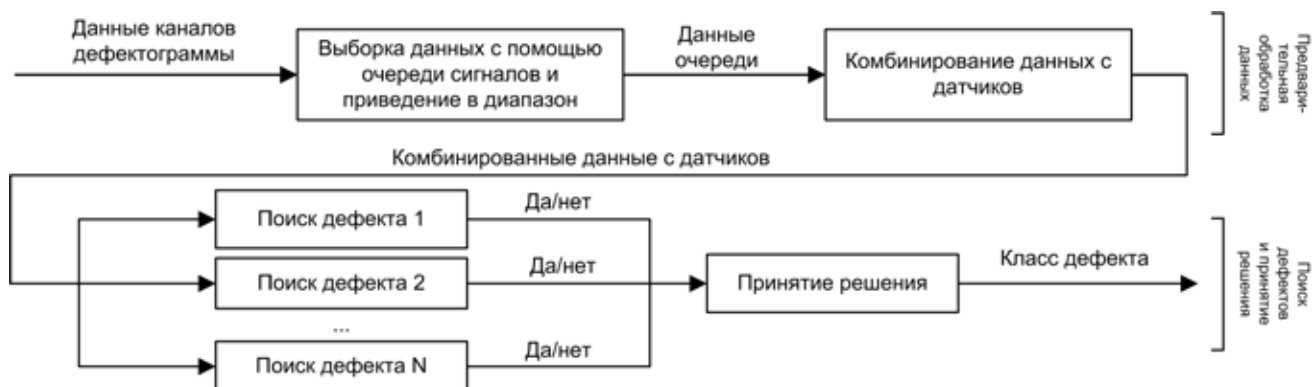


Рис. 1. Схема процесса расшифровки дефектограмм

но обрабатывать данные, поступающие с разных каналов, что обеспечивается с помощью комбинирования данных. Комбинирование данных каналов производится следующим образом:

1. Каждый элемент кортежа данных канала (массив амплитуд) комбинируется с элементами, стоящими в тех же позициях в других каналах;

2. Каждый элемент массива амплитуд (амплитуда) комбинируется с элементами, стоящими в тех же позициях в других массивах амплитуд следующим образом:

а. Если все элементы равны 0, результат равен 0;

б. Если один из элементов не равен 0, результат равен значению ненулевого элемента;

с. Если два и более элемента ненулевые, результат равен

$$a_r = a_1 + a_2 + \dots + a_n + th, \quad (4)$$

где a_r – результирующая амплитуда;

a_1, \dots, a_n – значения амплитуд исходных элементов;

th – некоторое пороговое значение, подбираемое таким образом, чтобы оно было больше максимально возможного значения амплитуды с учетом приведения в диапазон.

Такое кодирование позволяет получить из набора исходных данных один кортеж массивов амплитуд. При этом:

1. Нулевые амплитуды остаются нулевыми;

2. Для ненулевых амплитуд сохраняется их значение, если они не совпадают по позиции с другими амплитудами. Информация об исходном канале также сохраняется;

3. Для совпадающих по позиции амплитуд фиксируется факт совпадения, а также информация о сумме исходных амплитуд.

Полученный кортеж массивов амплитуд должен быть преобразован в одномерный массив амплитуд. Новый индекс элемента в массиве вычисляется следующим образом:

$$i = w + i_0 \cdot W, \quad (5)$$

где i_0 – индекс элемента в исходном массиве;

w – номер массива амплитуд в кортеже;

W – общее число массивов амплитуд в кортеже.

С учетом того, что алгоритмы комбинирования данных и преобразования кортежа в массив оперируют отдельными элементами массивов, они могут быть эффективно распараллелены.

Перечни комбинируемых каналов и количество комбинаций являются свободно настраиваемыми параметрами. Значения этих параметров определяются набором датчиков, присутствующих в системе, а также особенностями дефектов и выявляющих их датчиков.

В результате выполнения описанных преобразований из исходного набора кортежей массивов амплитуд будет получено множество одномерных массивов амплитуд, которые могут быть использованы в дальнейшей обработке специализированными классификаторами.

4 ПОИСК И КЛАССИФИКАЦИЯ ДЕФЕКТОВ

Решение задачи поиска и классификации дефектов железнодорожных рельсов предполагает построение сложной поверхности раздела в пространстве кортежей ультразвуковых данных. Для упрощения решения этой задачи вместо одного сложного классификатора используется набор параллельно функционирующих специализированных классификаторов, направленных на выявление дефектов отдельных классов. Применение такого подхода позволяет строить сложную поверхность раздела из отдельных более простых поверхностей, что повышает точность классификации и снижает вычислительную сложность классификаторов.

При решении задач, связанных с обнаружением и классификацией объектов как в области технической диагностики, так и в медицине и других отраслях, часто применяются искусственные нейронные сети [5–7]. В настоящей работе используются сети архитектуры Simplified Fuzzy ARTMAP (SFAM) [8], что обусловлено следующими фактами:

1. Искусственные нейронные сети позволяют эффективно распараллеливать вычисления, что облегчает организацию обработки данных в режиме реального времени;

2. Сети SFAM работают с входными векторами, элементы которых могут принимать вещественные значения, что делает возможным работу со значениями амплитуды ультразвукового сигнала;

3. Сети SFAM решают дилемму стабильности-пластичности на архитектурном уровне, что облегчает проектирование и обучение сети для работы с входными векторами высокой размерности;

4. Для сети SFAM веса входов нейронов могут быть интерпретированы как интенсивность выраженности соответствующего признака, что облегчает контроль правильности формирования внутренних категорий в процессе обучения сети.

Тем не менее, сеть Simplified Fuzzy ARTMAP не может в исходном виде быть использована для обработки данных массивов амплитуд, т. к. амплитуды представлены целыми числами, выходящими за пределы диапазона [0, 1]. Данное ограничение может быть преодолено двумя способами. Первый способ – нормирование значений амплитуд с целью приведения их в необходимый диапазон. Однако такой подход требует выполнения операции деления для каждого элемента каждого массива. Т. к. операция деления в вычислительных системах является затратной, нормирование внесет дополнительные значительные вычислительные затраты.

Второй способ заключается в модификации нейронной сети таким образом, чтобы она смогла работать с элементами входных векторов в требуемом диапазоне. Такая модификация затронет некоторые уравнения, используемые в работе сети, однако общая архитектура останется без изменений.

Изменение диапазона можно рассматривать как умножение всех элементов входного вектора на масштабный коэффициент R :

$$a = Ra_0, \quad (6)$$

где a и a_0 – значения из нового и старого диапазонов соответственно.

При такой замене функция комплементарного кодирования входного вектора примет вид:

$$R(1 - a_0) = R - Ra_0 = R - a. \quad (7)$$

Таким образом, при комплементарном кодировании свободный коэффициент заменяется на новое значение верхней границы диапазона.

Для функции активации нейрона, учитывая, что в качестве нормы вектора используется сумма его элементов, а в качестве операции конъюнкции – минимум, имеем:

$$T = R \frac{|I \wedge W|}{\alpha + |W|} = \frac{|I' \wedge W'|}{\alpha' + |W'|}, \quad (8)$$

где I и I' – входной вектор (комплементарно кодированный), имеющий элементы, соответственно, в старом и новом диапазоне;

W и W' – вектор входных весов нейрона.

Как видно, вид функции не изменился, а параметр α изменил значение пропорционально масштабному коэффициенту.

Для функции соответствия имеем следующее выражение:

$$M = R \frac{|I \wedge W|}{|I|} = \frac{|I' \wedge W'|}{|I'|}. \quad (9)$$

Как видно, функция не претерпела изменений.

К аналогичному выводу приходим, рассматривая выражение для подстройки входных весов нейрона в процессе обучения:

$$W^{n'} = RW^n = R\beta(I \wedge W) + R(1 - \beta)W = \beta(I' \wedge W') + (1 - \beta)W', \quad (10)$$

где индексом n обозначен новый вектор весов.

Учитывая комплементарное кодирование входного вектора, при использовании старого диапазона значений его элементов для нормы вектора имеем:

$$|I| = N, \quad (11)$$

где N – количество его элементов (без учета комплементарного кодирования).

Исходя из этого, при переходе к новому диапазону значений элементов входного вектора для его нормы получаем:

$$|I| = RN. \quad (12)$$

Сеть должна обучаться таким образом, чтобы при наличии во входном векторе признаков дефекта соответствующего типа давать на выходе значение класса «1», во всех других случаях выходное значение должно быть равно «-1».

Как видно из уравнений работы сети, вычисление функции активации нейрона и функции соответствия предполагает выполнение операций деления, являющихся затратными с точки зрения вычислительных ресурсов. Эти затраты можно уменьшить, воспользовавшись тем фактом, что норма входного вектора, как было показано

выше, является постоянной при заданном размере и диапазоне значений его элементов, а норма вектора весов является постоянной по завершении процесса обучения сети, т. к. в процессе работы сеть не обучается. Таким образом, константы

$$\omega = \frac{1}{\alpha' + |W|} \quad (13)$$

и

$$\iota = \frac{1}{|I|} \quad (14)$$

(для каждого нейрона) могут быть вычислены единожды по завершении процесса обучения сети и затем быть использованы в процессе функционирования сети. Тогда операция деления будет заменена умножением, и уравнения примут следующий вид:

$$T = \omega |I' \wedge W'| \quad (15)$$

для функции активации нейрона и

$$M = \iota |I' \wedge W'| \quad (16)$$

для функции соответствия.

Таким образом, подав на вход каждого из специализированных классификаторов соответствующие комбинированные массивы амплитуд, на выходе мы получим набор решений классификаторов по наличию или отсутствию в векторах признаков дефектов.

5 ПРИНЯТИЕ РЕШЕНИЯ

При использовании более чем одного классификатора возможна ситуация, в которой два и более из них дают на выходе решение «да». Подобные конфликты могут возникать при схожести индикаций разных типов дефектов, при некоторых особенностях комбинирования данных датчиков, когда одна комбинация полностью включает другую, и при других обстоятельствах.

Разрешение подобных конфликтов является целью процесса принятия решения. Принятие решения может основываться на системе приоритетов, которые могут быть организованы в виде дерева принятия решений. Тогда разрешение конфликта может быть представлено в виде прохода по дереву решений, в ходе которого составленные приоритеты будут учтены. С учетом структуры дерева, проход по нему, по крайней мере, на нижних уровнях может осуществляться параллельно по нескольким ветвям.

Точный вид дерева решений может быть установлен при реализации модели в конкретной программно-аппаратной среде с учетом особенностей используемой ультразвуковой системы и контролируемого объекта.

В результате такого прохода будет получено окончательное решение о наличии или отсутствии признаков того или иного дефекта во входных данных в текущем сегменте данных. Полученное решение может быть сохранено или иным образом обработано, после чего обработка данных сегмента завершится.

6 ПОДБОР ПАРАМЕТРОВ КЛАССИФИКАТОРОВ

Подбор параметров параллельных классификаторов осуществлялся в автоматическом режиме с помощью САПР нейросетевых классификаторов [9]. Параметры подбирались отдельно для каждого из классификаторов с учетом следующих ограничений:

1. Требуемая точность классификации: 80%;
2. Требуемый уровень ложных срабатываний: 5%;
3. Требуемый уровень пропусков: 0,5%;
4. Требуемое время срабатывания: 5 с;
5. Размерность входных данных: 1600 элементов;
6. Количество выделяемых классов: 2.

Вектор параметров архитектуры классификатора включал в себя следующие параметры:

1. α – параметр функции активации нейрона;
2. β – параметр функции обучения нейрона;
3. ρ – параметр бдительности сети;
4. Количество и веса нейронов двух слоев нейронной сети (подбирались в соответствии с правилами архитектуры Simplified FuzzyARTMAP).

В процессе подбора параметров классификаторов использовались обучающие выборки объемом 150 элементов и тестовые выборки объемом 20 элементов.

Среднее количество итераций в процессе подбора параметров для отдельных классификаторов составило 18, минимальное – 15 (для классификатора, определяющего наличие дефекта типа «расщеп»), максимальное – 21 (для классификатора, определяющего наличие дефекта типа «трещина болтового отверстия»).

В результате процесса подбора значений параметров были найдены следующие значения свободных параметров классификаторов, удовлетворяющие установленным ограничениям:

1. α – параметр функции активации нейрона: 0,001;
2. β – параметр функции обучения нейрона: 1;
3. ρ – параметр бдительности сети: 0,0965.

Кроме того, были получены значения для весов нейронов каждой нейронной сети.

7 ПРОВЕРКА ПРЕДЛОЖЕННЫХ МОДЕЛЕЙ

Предложенная система моделей была проверена на дефектограммах, полученных в результате ультразвукового контроля железнодорожных рельсов. Исходные данные включали семь каналов, распознавалось пять типов дефектов.

Моделирование производилось в среде Matlab. Исползованные значения настраиваемых параметров приведены в таблице 1.

Данные о комбинировании данных датчиков приведены в таблице 2.

Данные о классификации дефектов приведены в таблице 3. Видно, что точность распознавания составила более 85%. Наихудший результат получен для трещин болтового отверстия, что связано с большим сходством индикаций, характерных для этого дефекта, и индикаций,

Таблица 1

Значения настраиваемых параметров моделей

№ п/п	Обозначение параметра	Описание параметра	Значение параметра
1	F_h	Количество элементов в очереди сигналов	20
2	F_v	Количество элементов в кортеже амплитуд отраженного сигнала в точке сканирования	80
3	R	Масштабирующий множитель	5883

Таблица 2

Комбинирование данных каналов ультразвуковой системы

№ п/п	Углы ввода ультразвуковых импульсов	Распознаваемые дефекты
1	0°	Продольные трещины
2	0°, ±35°	Наклонные трещины
3	0°, ±35°, ±75°	Трещины болтовых отверстий
4	±75°	Поперечные трещины
5	±55°	Расщепы

Таблица 3

Результаты классификации дефектов

№ п/п	Тип дефекта	Доля правильно классифицированных дефектов
1	Продольная трещина	95%
2	Поперечная трещина	97,5%
3	Наклонная трещина	94%
4	Трещина болтового отверстия	85%
5	Расщеп	99%

характерных для «чистого» болтового отверстия. Наилучший результат получен для расщепов, что связано со значительными отличиями индикаций этого типа дефектов от индикаций других дефектов.

ЗАКЛЮЧЕНИЕ

Разработка систем, обеспечивающих расшифровку ультразвуковых дефектограмм железнодорожных рельсов в автоматическом режиме на высоких скоростях сканирования, является важной задачей. При этом модели, применяемые для решения этой задачи в настоящее время, обладают рядом ограничений, не позволяющих решить ее полностью.

В настоящей работе предложена система моделей, позволяющая преодолеть выявленные ограничения и проводить автоматическую расшифровку дефектограмм в процессе проведения контроля на высоких скоростях. Предложенная система моделей основана на применении модифицированной нейронной сети архитектуры Simplified Fuzzy ARTMAP и широком применении параллельных вычислений.

Применение предложенной системы моделей при разработке автоматизированной системы расшифровки ультразвуковых дефектограмм позволит повысить эффективность процесса контроля рельсов, надежность получаемых результатов и безопасность железнодорожных перевозок.

СПИСОК ЛИТЕРАТУРЫ

1. Тарабрин В.Ф., Зверев А.В., Горбунов О.Е. Комплекс «Астра» для регистрации расшифровки результатов диагностики рельсового пути // Комплекс «АСТРА» для регистрации расшифровки результатов диагностики рельсового пути / ЗАО «Фирма Твема». – URL: <http://www.tvema.ru/404>.
2. Шилов М.Н. Методическое, алгоритмическое и программное обеспечение регистрации и анализа дефектограмм при ультразвуковом контроле рельсов : автореф. дис... канд. техн. наук. – СПб. : ОАО «Радиоавионика», 2007. – 23 с.
3. Armbruster R., Heckel T., Fenger S. Die gläserne Schiene Fortgeschrittene Ultraschall-Schienenprüfung // NDT.net. – URL: <http://www.ndt.net/article/dgzfp/pdf/zfp121-Armburster.pdf>.
4. Glossary // NDT-Ed.org. – URL: <http://www.ndt-ed.org/GeneralResources/Glossary/letter/g.htm>.
5. Бархатов В.А. Распознавание дефектов с помощью искусственной нейронной сети специального типа // Дефектоскопия. – 2006. – № 2. – С. 28–39.
6. Долинина О.Н., Кузьмин А.К. Отладка нейросетевой экспертной системы для офтальмологии // Вестник СГТУ. – 2011. – № 4 (62), вып. 4. – С. 248–253.
7. Jiann-Der L. Object recognition using a neural network with optimal feature extraction // Mathematical and Computer Modelling, Vol. 25, Is. 12, June 1997, pp. 105–117.
8. Kasuba T. Simplified fuzzy ARTMAP // AI Expert, Nov. 1993, pp. 18–25.
9. Шишкин В.В., Стенюшкин Д.И., Михеев А.В. Автоматизация проектирования нейросетевых классификаторов // Автоматизация процессов управления. – 2014. – № 3 (37). – С. 112–119.

REFERENCES

1. Tarabrin V.F., Zverev A.V., and Gorbunov O.E. *Kompleks «Astra» dlya registratsii rasshifrovki rezultatov diagnostiki relsovogo puti* [‘Astra’ Software for the Logging and Analyzing of Railroad Track Inspection Results]. Available at: <http://www.tvema.ru/404>.
2. Shilov M.N. *Metodicheskoe, algoritmicheskoe i programmnoe obespechenie registratsii i analiza defektogramm pri ultrazvukovom kontrole relsov*. Avtoref. dis. kand. tekhn. Nauk [Methodical Ware, Knoware, and Software for Logging and Analysing Defectograms of Railway Rails during Ultrasonic Inspection. Author’s abstract for the degree of Candidate of Engineering], Sankt-Peterburg, Radioavionika OJSC Publ., 2007. 23 p.
3. Armbruster R., Heckel T., and Fenger S. *Die gläserne Schiene Fortgeschrittene Ultraschall-Schienenprüfung*. NDT.net. Available at: <http://www.ndt.net/article/dgzfp/pdf/zfp121-Armburster.pdf>.
4. Glossary. NDT-Ed.org. Available at: <http://www.ndt-ed.org/GeneralResources/Glossary/letter/g.htm>.
5. Barkhatov V.A. *Raspoznavanie defektov s pomoshchyu iskusstvennoy neyronnoy seti spetsialnogo tipa* [Recognizing Imperfections with an Artificial Neural Network of Special Type]. *Defektoskopiya* [Russian Journal of Nondestructive Testing], 2006, no. 2, pp. 28–39.
6. Dolinina O.N. and Kuzmin A.K. *Otladka neyrosetevoy ekspertnoy sistemy dlya oftalmologii* [Neural Network-Based Expert Systems’ Debugging Method Applied to Ophthalmology Systems]. *Vestnik SGTU* [Bulletin of Saratov State Technical University], 2011, no. 4(62), Iss. 4, pp. 248–253.
7. Jiann-Der L. Object Recognition Using a Neural Network with Optimal Feature Extraction. *Mathematical and Computer Modelling*, vol. 25, Iss. 12, June 1997, pp. 105–117.
8. Kasuba T. Simplified fuzzy ARTMAP. *AI Expert*, Nov. 1993, pp. 18–25.
9. Shishkin V.V., Stenyushkin D.I. and Mikheev A.V. *Avtomatizatsiya proektirovaniya neyrosetevykh klassifikatorov* [Automated Design of Artificial Neural Network Based Classifiers]. *Avtomatizatsiya protsessov upravleniya* [Automation of Control Processes], 2014, no. 3, pp. 112–119.