

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В РАДИАЦИОННОМ НЕРАЗРУШАЮЩЕМ КОНТРОЛЕ

© 2019 г. С.Ю. Назаренко^{1,*}, В.А. Удод^{1,2,**}

¹ *Национальный исследовательский Томский политехнический университет, Россия 634050 Томск, пр-т Ленина, 30*

² *Национальный исследовательский Томский государственный университет, Россия 634050 Томск, пр-т Ленина, 36*

*E-mail: *svetanaz@mail.ru; **pr.udod@mail.ru*

Поступила в редакцию 27.12.2018; после доработки 01.03.2019

Принята к публикации 19.04.2019

Представлен обзор современного состояния и опыта практического применения искусственных нейронных сетей в радиационном неразрушающем контроле и приведены некоторые данные об использовании искусственных нейронных сетей в других видах неразрушающего контроля.

Ключевые слова: радиационный неразрушающий контроль, нейронные сети, распознавание дефектов.

DOI: 10.1134/S013030821906006X

ВВЕДЕНИЕ

Целью неразрушающего контроля качества веществ, материалов и изделий является не только обнаружение дефектов, но и их распознавание вследствие различного уровня потенциальной опасности дефектов разного типа [1]. Распознавание выявленных дефектов существенно повышает информативность контроля, что объективно необходимо для оптимизации управления технологическими процессами и качеством продукции. В настоящее время среди различных типов систем неразрушающего контроля одними из наиболее интенсивно развивающихся являются системы радиационного контроля с визуальным отображением результатов измерения излучения [2]. Помимо технической дефектоскопии они широко используются и при досмотре, проводимом в аэропортах, пограничных и железнодорожных станциях, в государственных учреждениях и т. п. с целью обеспечения безопасности перевозок и пресечения попыток нелегального провоза (перемещения) запрещенных предметов [3]. В данных системах распознавание элементов внутренней структуры просвечиваемого объекта традиционно сводится к визуальному распознаванию полутонного изображения, адекватного радиационному изображению объекта, человеком-оператором. Такое распознавание имеет ряд естественных недостатков: субъективизм, малая надежность, зависимость от компетентности оператора и т. д. Вследствие этого применение специализированных методов и алгоритмов автоматического распознавания изображений для систем радиационного контроля и досмотра позволит существенно повысить их эффективность. Одними из таких алгоритмов в настоящее время являются алгоритмы, основанные на использовании искусственных нейронных сетей.

В настоящее время происходит активное внедрение искусственных нейронных сетей в различные области человеческой деятельности. Нейронные сети применяются для решения трудно формализуемых задач, для которых сложно найти точный алгоритм решения [4]. К задачам, решаемым с помощью нейронных сетей, относятся задачи распознавания речи, изображений и рукописного текста, предсказания валютного курса и курса акций, диагностики заболеваний.

Цель настоящей работы заключается в описании современного состояния и опыта практического применения искусственных нейронных сетей в радиационном неразрушающем контроле. Для удобства изложения материала приведем сначала описание биологической нейронной сети.

БИОЛОГИЧЕСКИЕ НЕЙРОННЫЕ СЕТИ

Исследования, проводимые с искусственными нейронными сетями, показали, что способ обработки информации человеческим мозгом существенно отличается от методов, которые применяются обычными цифровыми компьютерами [5]. Человеческий мозг как система обработки информации может быть рассмотрен как очень сложный, нелинейный, быстродействующий компьютер.

Он способен организовывать свои структурные компоненты (нейроны) так, чтобы нейроны могли выполнять такие задачи как распознавание образов, обработка сигналов органов чувств, моторные функции во много раз быстрее, чем это смогли бы самые современные компьютеры [5].

Обычное зрение служит примером такой задачи обработки информации. Человек получает с помощью зрения более 90 % информации [6]. Одной из функций зрительной системы является создание представления об окружающем мире в таком виде, который обеспечивал бы возможность взаимодействия человека с этим миром. При этом мозг последовательно выполняет ряд задач распознавания, например, распознавание знакомого лица в незнакомом окружении. Для выполнения этой задачи мозгу потребуется около 100 – 200 миллисекунд, а решение аналогичных задач даже меньшей сложности на компьютере может занять несколько дней [6].

При разработке сетевых конфигураций и алгоритмов на основе искусственных нейронных сетей исследователи применяют термины организации мозговой деятельности по аналогии с биологическими нейронными сетями. К сожалению, знания о деятельности мозга существенно ограничены, и создателям нейронных сетей приходится выходить за пределы современных биологических знаний в поисках структур, способных выполнять полезные функции.

Таким образом, в своих работах исследователи отказываются от биологических терминов, мозг становится всего лишь метафорой, и создаются сети, существование которых невозможно в живой материи или требующие невероятно больших допущений об анатомии и работе мозга [7].

Тем не менее искусственные нейронные сети в настоящее время продолжают сравнивать с мозгом, хотя их связь с биологией слаба и зачастую малосущественна.

Перейдем теперь к непосредственному описанию биологической нейронной сети.

Биологической нейронной сетью называют совокупность нейронов головного и спинного мозга центральной нервной системы, которые объединены в нервной системе [5]. Каждый нейрон характеризуется многими качествами, общими с другими структурными частями тела, но его исключительной способностью является получение, обработка и передача электрохимических сигналов по нервным связям, которые формируют коммуникационную систему мозга [6]. Строение биологического нейрона показано на рис. 1.

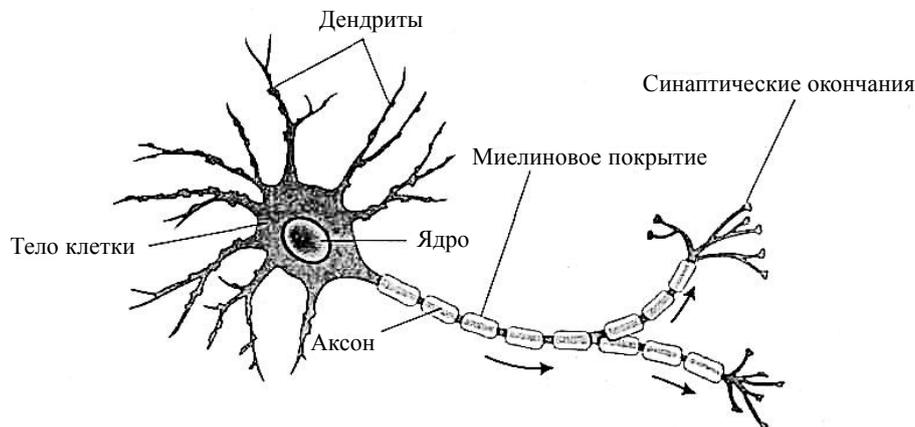


Рис. 1. Биологическое строение нейрона [6].

Биологический нейрон — чрезвычайно сложная система. Во многом это объясняется тем, что нейрон, помимо обработки сигнала (основное его назначение), вынужден еще выполнять много других функций, поддерживающих его жизнь. Более того, сам механизм передачи сигнала от нейрона к нейрону тоже очень сложный с биологической и химической точки зрения [6].

Общеизвестно, что в коре головного мозга человека имеется около 10^{11} нейронов, каждый из которых имеет связи с 10^3 — 10^4 другими нейронами. Биологический нейрон имеет большое количество отростков — дендритов и одно длинное волокно — аксон. По дендритам нервные импульсы поступают в нейрон, а по аксону нервный импульс от данного нейрона передается на другие нейроны. Аксон одного нейрона присоединяется к дендритам других нейронов с помощью синапсов [8]. Синапсом называют место стыка выхода одного нейрона и входа другого, в котором происходит усиление или ослабление сигнала.

ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ

В настоящее время искусственными нейронными сетями (ИНС) (Artificial neural networks, ANN) называют упрощенные модели биологических нейронных сетей [6].

Гипотетическая структура, которая принимает сигнал, преобразует его (примерно так, как это делают настоящие нейроны) и передает другим нейронам, называется искусственными нейронами [8].

Искусственный нейрон (Artificial neuron) — упрощенная модель биологического нейрона [6]. На рис. 2 представлено упрощенное изображение биологического и искусственного нейронов.

Искусственные нейроны, которые используются для создания нейронных сетей, сильно упрощены по сравнению с их биологическими прототипами. Нейронные сети, которые можно создать в настоящее время, примитивны по сравнению с биологическими нейронными сетями.

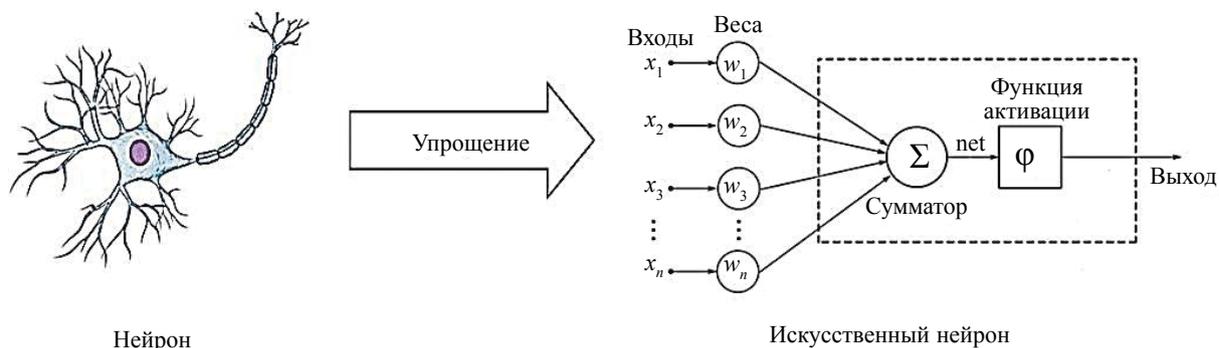


Рис. 2. Упрощенное изображение биологического и искусственного нейронов [6].

Искусственные нейронные сети появились как следствие применения математического аппарата к изучению функционирования нервной системы [9]. Полученные при этом результаты с успехом используются при решении проблем распознавания образов, моделирования, прогнозирования, оптимизации и управления.

Нейроном называется единица обработки информации в нейронной сети [10]. В модели искусственного нейрона, представленной на рис. 2, можно выделить четыре основных элемента.

1. Входы. У каждого нейрона, в том числе и у искусственного, должны быть входы, через которые он принимает сигналы x_i .

2. Синапсы, которые характеризуют силу (вес) w_i связи между двумя нейронами. Поступившие на входы сигналы умножаются на свои веса. Сигнал первого входа x_1 умножается на соответствующий этому входу вес w_1 . Получаем $x_1 w_1$. И так до n -ого входа. В итоге на последнем входе получаем $x_n w_n$.

3. Сумматор складывает входные сигналы, умноженные на соответствующие веса:

$$x_1 w_1 + x_2 w_2 + \dots + x_n w_n = \sum_{i=1}^n x_i w_i.$$

Результатом работы сумматора является число, называемое взвешенной суммой.

Взвешенная сумма (Weighted sum) (net) — сумма входных сигналов, умноженных на соответствующие им веса.

4. Преобразователь выполняет функцию одного аргумента — выхода сумматора. Эта функция названа функцией активации или функцией сжатия. Преобразователь ограничивает амплитуду выходного сигнала нейрона. Как правило, нормированный диапазон амплитуд выхода нейрона лежит в интервале $[0, 1]$ или $[-1, 1]$.

По структуре межнейронных связей искусственные нейронные сети делятся на три основных класса [5].

1. Однослойные искусственные нейронные сети прямого распространения. Это такие сети, в которых сигнал передается только от нейронов входного слоя к нейронам выходного слоя (вычислительным).

2. Многослойные сети прямого распространения. К многослойным искусственным нейронным сетям прямого распространения относится такой класс нейронных сетей, который характеризуется наличием одного или нескольких скрытых слоев. Узлы таких скрытых слоев называются скрытыми нейронами. Функция скрытых нейронов включает посредничество между внешним входным сигналом и выходом нейронной сети.

3. Рекуррентные сети. Рекуррентные нейронные сети характеризуются наличием одной или нескольких обратных связей локального или глобального типов.

В последние годы наблюдается рост популярности глубоких нейронных сетей — многослойных искусственных нейронных сетей с числом внутренних (скрытых) слоев более одного. Это объясняется существенным увеличением производительности современных компьютеров, накоплением большого объема данных, необходимого для обучения глубоких нейронных сетей, а также совершенствованием методов обучения сетей, состоящих из большого количества слоев [11, 12]. Характерная особенность глубоких нейронных сетей состоит в том, что сеть автоматически выделяет из данных важные признаки, необходимые для решения задачи.

Для решения задач нахождения сложных признаков из большого объема данных и применения в области эффективного распознавания и классификации изображений используются нейронные сети, называемые сверточными (convolutional neural network, CNN). Сверточная нейронная сеть представляет собой однонаправленную нейронную сеть, состоящую из чередующихся определенным образом множества слоев — сверточных слоев (convolution layers) и субдискретизирующих слоев или слоев подвыборки (subsampling layers, pooling layers) [11—13]. При обучении на основе исследуемых изображений одного класса сверточная нейронная сеть самостоятельно с помощью сверточных слоев формирует наборы (карты) признаков, характеризующие этот класс и отделяющие их от других изображений [13]. Слои подвыборки уменьшают масштаб изображения.

Области применения искусственных нейронных сетей весьма разнообразны. Нейронные сети нашли применение в следующих сферах деятельности [14]:

экономика и бизнес: прогнозирование временных рядов (курсов валют, объемов продаж, спроса, цен на сырье и т. д.), выявление недооцененных и переоцененных фирм, предсказание банкротств, оптимизация денежных и товарных потоков [4, 15, 16];

медицина и здравоохранение: диагностика заболеваний, обработка медицинских изображений, уменьшение шумов показаний приборов, прогнозирование результатов применения разных методов лечения [17—20];

робототехника: распознавание объектов и препятствий перед роботом, прокладка маршрута движения роботов [21, 22];

безопасность, охранные системы: распознавание лиц; идентификация личности по отпечаткам пальцев, лицу, голосу, подписи; распознавание автомобильных номеров [11, 23];

промышленность химическая, нефтеперерабатывающая, энергетика: анализ технического состояния оборудования, прогнозирование электропотребления [24—26].

Ниже приводится описание современного состояния и опыта практического применения нейронных сетей в неразрушающем контроле.

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В РАДИАЦИОННОМ НЕРАЗРУШАЮЩЕМ КОНТРОЛЕ

В [27] описана автоматическая система идентификации для распознавания различных типов дефектов сварки по рентгенографическим изображениям. Для отделения дефектов от фона реализованы такие технологии обработки изображений как вычитание фона и пороговая обработка. Для представления каждого вида дефекта выделены двенадцать числовых признаков, описывающих информацию о местоположении, форме, размере и «интенсивности» дефектов. Значения выделенных признаков впоследствии использованы для классификации дефектов сварки на разные типы с помощью двух известных классификаторов: классификаторов нечетких k -ближайших соседей и многослойных персептронных нейронных сетей.

Нелинейные классификаторы изображений для классификации дефектов сварных швов по рентгенографическому изображению, реализуемые с помощью искусственных нейронных сетей, применены в [28] для более успешной дискриминации дефектов, по сравнению с линейными классификаторами. В качестве входных данных классификаторов использовались геометрические признаки различных классов дефектов. Чтобы преодолеть недостаточность данных при малом количестве образцов для обучения нейронной сети, некоторые из классов дефектов с малым количеством данных дублировались. Для оценки способности к распознаванию классов, изученных с помощью

используемых геометрических признаков, был применен критерий нейронной релевантности, показывающий, что качество признаков более важно, чем количество используемых признаков.

Авторы [29] провели исследование для оценки точности классификации основных видов дефектов сварного шва, таких как пористость, шлаковое включение, трещина или непровар. Для выполнения этой работы разработаны нелинейные классификаторы изображений с использованием нейронных сетей. Было проанализировано 67 радиографических изображений сварных швов. Для расчета точности классификации дефектов сварного шва применены два метода случайного выбора данных: метод без репозиционирования и метод с репозиционированием с использованием метода бутстрепа. Результаты показали, что точность классификации проанализированных дефектов составила примерно 80 %.

В [30] описана автоматическая система обнаружения дефектов сварки на радиографических изображениях сварных швов. На первом этапе для обнаружения участков сварного шва, содержащих дефекты, и распознавания типа дефекта были реализованы такие методы обработки изображений как уменьшение шума, повышение контрастности, пороговая обработка и маркировка. На втором этапе был предложен и выделен набор геометрических признаков, характеризующих форму и ориентацию дефекта между образами дефектов с использованием метода Оцу (Otsu). На третьем этапе использовалась искусственная нейронная сеть для классификации дефектов сварного шва. С целью достижения наилучшей производительности классификатора авторами [30] использовано для обучения три различных метода обобщения сети. Результаты сравнивали с методом без обобщения. Для уменьшения размерности входного вектора признаков классификатора использовали метод анализа основных компонентов.

Новый подход к выделению признаков дефектов по радиографическим изображениям сварного шва, полученным с помощью гамма-лучей, представлен в [31]. В этом подходе изображения были лексикографически упорядочены в 1D-сигналы. Затем по этим сигналам вычисляли кепстральные коэффициенты, используемые, как правило, для распознавания речи [32], которые служили признаками для распознавания дефектов. Для сопоставления признаков в предлагаемом подходе использованы нейронные сети. Оценку эффективности предлагаемого подхода проводили с использованием шестнадцати радиографических изображений сварных швов, содержащих семьдесят три дефекта. Для оценки производительности тестируемые изображения ухудшались гауссовыми, импульсивными, спекл- или пуассоновскими шумами с размытием и без него. Экспериментальные результаты показали, что предлагаемый подход позволяет с высокой достоверностью проводить автоматическое обнаружение дефектов на радиографических изображениях при наличии шума и размытости.

В [33] рассмотрен подход к идентификации по радиографическому изображению дефектов сварки. Этот подход основан на генерации базы данных признаков дефектов с использованием мел-частотных кепстральных коэффициентов и полиномиальных коэффициентов, полученных из спектров плотности мощности сегментированных областей сварного шва после выполнения стадий предварительной обработки и сегментации. Искусственные нейронные сети использованы для процесса сопоставления признаков с целью автоматической идентификации дефектов на радиографических изображениях. Для реализации предлагаемого подхода использовано 150 радиографических изображений при наличии различных типов шума и размытости. Экспериментальные результаты показали, что предлагаемый подход обеспечивает высокую достоверность автоматической идентификации дефектов сварки по радиографическим изображениям в шумных средах и позволяет достичь высоких скоростей распознавания.

В [34] представлен метод автоматического обнаружения и классификации дефектов на рентгенографических изображениях сварных соединений. Согласно предлагаемому методу, по рентгенографическим изображениям определяется местонахождение сварного шва, неоднородности сегментов (потенциальные дефекты) в области сварного шва и выделяются признаки этих неоднородностей. Выделенные признаки используются в многослойном персептроне с обратной связью с алгоритмом обучения обратного распространения для классификации неоднородностей «дефект—отсутствие дефекта». Точность классификатора для тестовых данных достигла 88,6 %. Сравнение результатов с более ранними исследованиями с использованием радиографических изображений свидетельствует о том, что предложенный метод является многообещающим. Авторы утверждают, что работа способствует совершенствованию автоматического обнаружения дефектов сварки на рентгенографических изображениях, результаты которого могут быть использованы инспекторами сварки в качестве поддержки при подготовке технических отчетов.

Авторы [35] описывают автоматическую систему обнаружения, распознавания и классификации дефектов сварки по рентгенографическим изображениям и оценивают эффективность двух

нейроклассификаторов: на основе искусственной нейронной сети и системы нечеткого вывода с адаптивной сетью. На первом этапе распознавания областей сварки и обнаружения потенциальных дефектов были реализованы методы обработки изображений, включающие шумоподавление, повышение контрастности, пороговую обработку и маркировку. На втором этапе был предложен и выделен набор из 12 геометрических признаков, которые характеризуют форму и ориентацию дефекта между потенциальными дефектами. На третьем этапе проведено сравнение между искусственной нейронной сетью и системой нечеткого вывода с адаптивной сетью для классификации дефектов сварки. Предлагаемая автоматическая система распознавания и классификации выполняет обнаружение на практике четырех основных типов дефектов сварного шва, а также типа «недефект». Результаты сравнивали с целью узнать метод, который обеспечивает наилучшую точность классификации. Для этого были определены коэффициенты корреляции, матрица верификации и точность для искусственной нейронной сети и системы автоматического контроля. Точность или доля общего числа прогнозов, которые были правильными, составили 78,9 % для искусственной нейронной сети и 82,6 % для системы нечеткого вывода с адаптивной сетью.

В [36] был предложен эффективный и адаптивный метод автоматического обнаружения дефектов подвижного сварного шва с использованием отслеживания дефектов в режиме рентгенографического изображения в реальном времени. При этом использовался алгоритм сегментации изображений с низким порогом с целью обнаружения всех потенциальных дефектов сварного шва в каждом изображении последовательности. Затем применялось модифицированное преобразование Хафа (Hough) для отслеживания центра тяжести потенциальных дефектов в последовательности изображений, а потенциальные дефекты, которые невозможно было отслеживать, устранялись как ложные дефекты. Полученные экспериментальные результаты подтверждают, что использование предлагаемого метода позволяет обнаруживать дефекты сварного шва с высокой степенью уверенности и избегать ложных тревог, вызванных шумом.

Авторами [37] предлагается метод, основанный на фильтрации Калмана для обнаружения дефектов сварки спиральных труб по радиографическим изображениям в реальном времени. Наличие шумов изображения и неоднородность фона вызывают многочисленные ложные тревоги. В этой работе непрерывность траекторий дефектов в последовательности изображений определяется с помощью фильтрации Калмана для идентификации истинных дефектов. Потенциальные области дефектов без непрерывного движения считаются ложными тревогами и устраняются. Проведенные эксперименты продемонстрировали адаптивность предлагаемого метода. Наряду с этим проверялась устойчивость метода при неустойчивой скорости обнаружения.

Учитывая актуальность рентгенографического обследования для контроля качества технологического оборудования, изделий, металлоконструкций, в различных отраслях промышленности, было выполнено множество научно-исследовательских проектов, направленных на автоматизацию анализа и интерпретацию сварных разрывов. В [38] автоматическое управление и проверка дефектов сварки производилась методом обнаружения границ рентгенографических изображений, основанных главным образом на использовании многослойного персептрона. Авторами [38] описан метод обнаружения дефектов сварки по радиографическим изображениям, основанный на использовании искусственных нейронных сетей, ориентированный на классификацию дефектов и увеличение процента успешности распознавания. Работа выполнялась в четыре этапа: первый этап состоял в подготовке базы данных, которая использовалась позже на втором этапе для обучения. Следующий этап выполнялся в двух основных частях: первая часть посвящена обнаружению контуров, вторая часть состояла в устранении дополнительных контуров. И наконец, проводилось распознавание дефектов по реальным изображениям сварных швов.

В [39] представлен метод обнаружения и классификации дефектов на рентгенограммах сварных швов. Этот метод был применен для обнаружения и распознавания разрывов на изображениях сварных швов, которые могут соответствовать ложным тревогам или дефектам, таким как пористость, шлаковые включения, поры газа, отсутствие плавления или трещины. Набор из 43 дескрипторов, соответствующих измерениям текстуры и геометрическим признакам, извлекается для каждого сегментированного объекта и задается как вход в классификатор. Классификатор обучается распределять каждый из объектов в один из классов дефектов или характеризовать его как «недефект». Использовалась трехкратная перекрестная проверка, а экспериментальные результаты представлены для трех разных классификаторов (метод опорных векторов, нейронная сеть, классификатор k -NN).

Система обнаружения дефектов сварки с использованием радиографических изображений представлена в [40]. Основная цель работы заключалась в создании надежной системы, потому что человек-оператор не является стабильным оценщиком. Авторы предоставили новый метод обна-

ружения и классификации дефектов сварного шва с помощью геометрических особенностей. Во-первых, выполняется шумоподавление, поскольку рентгенографические изображения содержат шум. После этого дефекты должны быть локализованы с максимальной дисперсией между классами и минимальной дисперсией внутри класса. Далее проводится извлечение признаков, описывающих форму локализованных объектов в сегментированных изображениях. Используя эти дескрипторы формы (геометрические особенности), дефекты классифицировались с помощью искусственной нейронной сети.

В [41] дана оценка того, насколько важны характерные параметры дефектов сварки с помощью метода линейной корреляции, а также для использования соответствующих параметров в линейном классификаторе шаблонов, разработанных с применением нейронных сетей. Полученные результаты подтверждают эффективность метода, представляя собой важный шаг к разработке автоматизированной системы радиографического контроля.

Авторы [42] разработали способ определения размеров дефектов сварного соединения на основе объединения метода фотометрирования изображения дефекта с компьютерной обработкой изображения по специальной программе, что позволило ускорить процесс обработки и увеличить точность расчета глубины непровара в корне сварного шва. Также были приведены результаты апробации метода на искусственных и натуральных дефектах. Для анализа изображения рентгеновского снимка и расчетов параметров непровара применялась программа Weld. В процессе тестирования было обработано 15 образцов с заранее заданными параметрами непровара (ширина, глубина). Результаты тестирования показали, что в среднем рассчитанная величина глубины дефекта линейно зависит от истинного значения.

В [43] рассмотрена задача автоматизации компьютерной расшифровки радиационных изображений сварных соединений, для решения которой был разработан комплекс архивации и автоматизированной компьютерной расшифровки радиографических изображений сварных соединений «КАРС». Комплекс обеспечивает формирование цифровых изображений путем сканирования радиографических снимков сварных соединений, а также архивацию и автоматизированную расшифровку этих изображений.

В ПО «КАРС» реализованы следующие основные операции расшифровки радиационных изображений сварных соединений:

- 1) поиск, определение размеров и классификация изображений одиночных дефектов и их (дефектов) оценка;
- 2) поиск скоплений изображений дефектов и их (скоплений дефектов) оценка;
- 3) поиск и оценка наихудшего участка сварного соединения;
- 4) оценка качества сварного соединения в целом;
- 5) выпуск заключения о качестве одного или нескольких сварных соединений.

В [44] представлена математическая модель цифрового радиационного изображения, соответствующего объекту контроля, содержащему дефекты двух типов — поры и трещины (либо непровары). Были разработаны два алгоритма автоматического распознавания образов данных дефектов на цифровом радиационном изображении объекта и получены оценки эффективности указанных алгоритмов посредством математического моделирования. Сущность первого алгоритма заключается в сегментации исследуемого изображения путем его предварительной фильтрации с последующей бинаризацией и использовании для распознавания максимальной и минимальной осей инерции сегмента. Сущность второго алгоритма заключается в сегментации исследуемого изображения с использованием процедуры кумулятивных сумм и применении оригинального решающего правила, основанного на теоретико-множественном подходе. По результатам тестирования следует, что второй алгоритм распознавания лучше первого по эффективности и при этом значительно лучше для объектов малой площади и низкого отношения сигнал/шум. Авторы предлагают использовать второй алгоритм за основу для сравнения с ним других алгоритмов аналогичного предназначения и его дальнейшей адаптации к распознаванию реальных дефектов в исследуемых объектах.

Эффективность алгоритмов автоматической сегментации цифрового радиационного изображения объекта контроля, являющихся соответствующими составными элементами алгоритмов, представленных в [44], проанализирована в [45].

В [46] рассмотрена возможность применения сверточных нейронных сетей при решении задачи неразрушающего контроля изделий. Рассмотрена организация сверточных нейронных сетей, преимущества их использования при обработке нестационарной и слабо формализуемой информации. На основе выполненного анализа сделан вывод о перспективности применения сверточных нейронных сетей для распознавания дефектов поверхностей металлов на радиографических изображениях.

Авторы [47] предложили алгоритм автоматического обнаружения дефектов сварного шва на рентгеновских изображениях, в котором использована упрощенная процедура предварительной обработки изображения для определения местоположения области сварки. Алгоритм основан на использовании глубокой нейронной сети, которая обучается и тестируется на участках, выделенных из рентгеновских изображений сварных швов. Результаты экспериментов показали, что предложенный алгоритм весьма эффективен для оценки качества сварных соединений.

В [48] для выявления дефектов сварных швов на рентгеновских изображениях и для классификации различных типов дефектов в условиях их неравномерного распределения разработана модель, основанная на глубокой сверточной нейронной сети (DCNN). В качестве обучающего набора данных использованы выделенные участки на рентгеновских изображениях. Использование разработанной нейронной сети позволило получить точность 97,2 % при проведении классификации дефектов.

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В ДРУГИХ ВИДАХ НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ

В [49] рассмотрена концепция распознавания образов, основанная на объединении сигналов, близких к оригиналу в ультразвуковом контроле. Предложен новый тип нейрона, который реализует элементарную операцию распознавания. Рассмотрены принципы работы некоторых детерминированных нейронных сетей. Приведены примеры обнаружения и классификации сигналов при наличии искажений, шумов и помех. Главная идея состоит в самом понимании образа как сигнала с охватывающим его множеством. На этом построена концепция устройств распознавания. Присутствие ожидаемого образа в исследуемом сигнале определяется посредством корреляции, а распознавание осуществляется путем проверки, попадает ли исследуемый сигнал во множество образа. Конечно, существует еще много вариантов ограничения множества образа и разграничения множеств нескольких образов или классов. В предлагаемом подходе, в отличие от нейронных сетей, нет процедур обучения, основанных на алгоритмах случайного поиска, и, следовательно, нет непредсказуемых реакций устройства распознавания. В данном случае процесс обучения заменяется конструированием. По мнению автора, наиболее перспективным является алгоритм распознавания, основанный на анализе деталей. Рациональное разложение класса сигналов на детали позволит создать сложные и многогранные устройства распознавания.

В [50] разработан новый тип нейронной сети, позволяющий проводить разделение сигналов от дефектов различного типа. Для исследования работы нейросетей была создана программа NEURON1. В качестве примера рассмотрена задача обнаружения эхосигнала ультразвукового дефектоскопа. Для решения этой задачи использовалась довольно простая однослойная нейронная сеть. Сеть имела 4 нейрона во входном слое и 1 выходной нейрон. Обучение сети на сигналах занимало примерно 30 секунд. Информационные векторы нейронов входного слоя образуют четырехмерное подпространство, в котором, собственно, и происходит разделение эхосигналов. Остальная часть информационного пространства имеет размерность 146. Здесь разделяющие плоскости имеют произвольное расположение, т. к. при обучении нейронной сети не были предъявлены сигналы из этой части пространства. Следовательно, существует множество сигналов, на которые реагирует данная нейронная сеть (создает сигнал на выходе). В этом смысле поведение сети непредсказуемо. Полное разделение эхосигнала от всех других сигналов может быть достигнуто, если в набор обучения добавить как минимум 146 альтернативных сигналов. В этом случае четырех нейронов во входном слое недостаточно. Нужно 150 нейронов. Возможно, необходимо еще увеличить количество слоев в нейронной сети.

В [51] нейронные сети архитектуры Fuzzy ARTMAP предлагается использовать для решения задачи автоматизированного анализа дефектограмм, получаемых при ультразвуковом неразрушающем контроле деталей двигателей и несущих конструкций летательных аппаратов. Автоматизированная система анализа дефектограмм, построенная на основе указанных нейронных сетей, позволит повысить эффективность процесса анализа и скорость обработки данных, а также повысить надежность результатов.

Авторы [52] провели идентификацию внутренних дефектов с применением методов ультразвукового контроля в комбинации с аппаратом искусственных нейронных сетей. Построены модели сечения трубы, усиленной внутренней кольцевой накладкой, и распространения ультразвуковой волны. Исследовано влияние различных геометрических параметров изучаемых объектов на показатели обучения нейронных сетей. Установлена оптимальная структура нейронной сети и форма обучающих векторов для некоторых методов ультразвукового контроля и их комбинаций.

Возможность применения нейронных сетей для распознавания образов акустико-эмиссионного контроля металлических конструкций исследована в [53]. Для классификации входных данных предложено использовать нейронную сеть LVQ (Learning Vector Quantization), состоящую из двух слоев: скрытого (конкурирующего) и линейного (выходного). Количество нейронов конкурирующего слоя выбиралось методом подбора и при их числе, равном 12. Нейронная сеть имела минимальную ошибку обучения, а дальнейшее увеличение количества нейронов не приводило к повышению качества работы сети. В выходном слое имелось 2 нейрона, что соответствовало двум типам распознаваемых сигналов. Создание и обучение нейронной сети проводили с применением пакета MATLAB.

В [54] был проанализирован процесс обучения и тестирования нейронных сетей обратного распространения для дефектных сигналов путем наложения разных уровней шума. Рассмотрены результаты классификации путем кластеризации. Используя численное моделирование, показано, что кластеризация увеличивает вероятность распознавания сигнала.

В [55] предложено определять положение обнаруженного дефекта на теплообменной трубке и оценивать его геометрические параметры с помощью искусственной нейронной сети по некоторым информативным признакам соответствующих сигналов дифференциальных вихретоковых преобразователей на разных частотах. Для обучения нейронной сети, реализующей требуемую передаточную функцию из пространства признаков вихретоковых сигналов в пространство параметров дефектов, как и в стандартной задаче аппроксимации, требуется набор характерных точек, через которые эта функция проходит. Для получения набора таких точек необходимо располагать базой данных, которую можно сформировать при помощи адекватной математической модели, а также путем накопления экспериментальных сигналов от искусственных и реальных дефектов с известными параметрами. Моделирование процедуры вихретокового контроля проводилось методом конечных элементов, реализованным в программе MagNum3D. Поскольку на входы нейронной сети подается не сам сигнал, а характерные параметры этого сигнала, для решения задачи классификации и геометрической параметризации дефектов сформирован набор этих характерных параметров, а также разработано соответствующее программное обеспечение выделения этих признаков. Сформированные наборы признаков для каждого из целевых параметров использовались при создании нейронных сетей. Для решения задачи определения каждого геометрического параметра дефекта было решено реализовать каскадную нейронную сеть, причем в каждой «ячейке» использован двухслойный персептрон с сигмоидальными функциями активации.

Задача распознавания образов конструктивных элементов железнодорожных рельсов по дефектограммам многоканальных вихретоковых и магнитных дефектоскопов с помощью нейронных сетей решалась в [56]. При решении этой задачи рассматривались такие конструктивные элементы рельсового пути как болтовой стык с прямым или скошенным соединением рельсов, электроконтактная сварка рельсов, алюмотермитная сварка рельсов, а также образы, которые не могут быть отнесены к этим конструктивным элементам — дефекты. Для распознавания образов конструктивных элементов на вихретоковых дефектограммах применялась нейронная сеть, реализованная в рамках открытой библиотеки TensorFlow и состоящая из трех слоев, расположенных последовательно друг за другом. Для обучения нейронной сети по методу стохастического градиентного спуска в модификации Adam использовался набор данных, состоящий из 48028 графических образов. По полезным сигналам на дефектограмме выделялась отметка в виде матрицы амплитуд, проводилось удвоение количества строк в образе отметки, затем текущий образ отметки представлялся в виде картинки в градации серого цвета, далее проводилось построчное сжатие графического образа отметки. На основании результатов исследования авторы [56] сделали вывод, что простая последовательная полносвязная трехслойная модель нейронной сети достаточна для решения задачи распознавания конструктивных элементов рельсов и их дефектов.

Возможность применения сверточных нейронных сетей для задач распознавания образов дефектов по результатам диагностики с применением вихретокового и магнитного методов неразрушающего контроля показана в [57]. Разработанная автоматизированная система реализована на основе упрощенной модифицированной архитектуры четырехслойной сверточной сети без слоев субдискретизации. При этом были получены удовлетворительные результаты, хотя показано, что в процессе выделения образов дефектов из массива исходных данных образуется класс матриц, имеюемых библиотекой новых образов, который априори относит область исходных данных к дефектной области. Это приводит к увеличению количества ошибок второго рода, но исключает возможность пропуска дефекта при автоматическом выделении образа дефекта. Для создания библиотек дефектов в [57] использованы нейронные сети, основанные на применении адаптивной резонансной теории.

В [58] для обработки результатов теплового контроля углепластикового композита были использованы две нейронные сети. Однослойный персептрон с двадцатью пятью входами и одним бинарным выходом для классификации векторов входа по двум классам «дефект/недефект», реализованный с помощью математического редактора MatLab, применен для тепловой дефектоскопии. Для осуществления тепловой дефектоскопии и тепловой томографии была разработана однослойная нейронная сеть, состоящая из S персептронов с произвольным числом выходов. Эффективность нейронной сети проверена для случая шести выходов при обработке результатов теплового контроля стандартного образца из углепластика. Показано, что нейронные сети применяются наиболее эффективно при неразрушающем контроле однотипных изделий, что требует только однократного обучения сети.

ВЫВОДЫ

1. В настоящее время происходит активное внедрение систем идентификации, основанных на нейронных сетях, которые предназначены для распознавания различных типов дефектов сварки по рентгенографическим изображениям.

2. Основные направления обработки и анализа радиационных изображений объектов связаны с разработкой методов уменьшения шума на изображении, повышения контрастности изображения, определения набора геометрических признаков дефектов и разработкой процедуры классификации дефектов.

3. В последние десятилетия в мире бурно развиваются искусственные нейронные сети, которые (помимо радиационного неразрушающего контроля) нашли широкое применение в таких видах контроля, как тепловой, ультразвуковой и вихрековый.

СПИСОК ЛИТЕРАТУРЫ

1. Приборы для неразрушающего контроля материалов и изделий / Справочник. В 2 кн. Кн. 1. Под ред. В.В. Клюева. 2-е изд., перераб. и доп. М.: Машиностроение, 1986. 488 с.
2. Удод В.А., Ван Я., Осипов С.П., Чахлов С.В., Усачёв Е.Ю., Лебедев М.Б., Темник А.К. Современное состояние и перспективы развития систем цифровой рентгенографии для дефектоскопии, диагностики и досмотрового контроля объектов (обзор) // Дефектоскопия. 2016. № 9. С. 11—28.
3. Ковалев А.В. Антитеррористическая диагностика // Контроль. Диагностика. 2011. Т. 4. № 2. С. 44—46.
4. Барский А.Б. Нейронные сети: распознавание, управление, принятие решений. М.: Финансы и статистика, 2004. 176 с.
5. Хайкин С. Нейронные сети. М.: ООО «И.Д. Вильямс», 2006. 1104 с.
6. Нейронные сети. Учебник по нейронным сетям [Электронный ресурс]. URL: <http://neuralnet.info/book/> (дата обращения: 12.04.2017).
7. Лапина А.В. Интеллектуальные информационные системы / Учебное пособие. Красноярск: СФУ ИКИТ, 2012. 204 с.
8. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. М.: Изд-во физико-математической литературы, 2000. 224 с.
9. Спицин В.Г., Цой Ю.Р. Интеллектуальные системы / Учебное пособие. Томск: Изд-во ТПУ, 2012. 176 с.
10. Лепский А.Е., Броневич А.Г. Математические методы распознавания образов / Курс лекций. Таганрог: Изд-во ТТИ ЮФУ, 2009. 155 с.
11. Liu W., Wang Z., Liu X., Zeng N., Liu Y., Alsaad F.E. A survey of deep neural network architectures and their applications // Neurocomputing. 2017. V. 234. P. 11—26.
12. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУрГУ. Сер. Вычислительная математика и информатика. 2017. Т. 6. № 3. С. 28—59.
13. LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient-based learning applied to document recognition // Proceedings of the IEEE. 1998. V. 86. № 11. P. 2278—2324.
14. Ежов А.А., Шумский С.А. Нейрокомпьютинг и его применение в экономике и бизнесе. М.: МИФИ, 1998. 224 с.
15. Десяренко Г.А., Долгова И.В. Искусственные нейронные сети для прогнозирования социально-экономических показателей в энергетической сфере // Вестник ТвГУ. Сер. Экономика и управление (2). 2014. С. 379—386.
16. Трофимова Е.А., Мазуров Вл.Д., Гилёв Д.В. Нейронные сети в прикладной экономике / Под общ. ред. Е.А. Трофимовой. Екатеринбург: Изд-во Урал. ун-та, 2017. 96 с.
17. Веденяпин Д.А., Лосев А.Г. Об одной нейросетевой модели диагностики венозных заболеваний // Управление большими системами. 2012. Вып. 39. С. 219—229.

18. *Мустафаев А.Г.* Применение искусственных нейронных сетей для ранней диагностики заболевания сахарным диабетом // Кибернетика и программирование. 2016. № 2. С. 1—7.
19. *Zhu S., Wang L., Duan S.* Memristive pulse coupled neural network with applications in medical image processing // Neurocomputing. 2017. V. 227. P. 149—157.
20. *Лазаренко В.А., Антонов А.Е., Markapuram V.K., Awad K.* Опыт нейросетевой диагностики и прогнозирования язвенной болезни по результатам анализа факторов риска // Бюллетень сибирской медицины. 2018. 17 (3). С. 88—95.
21. *Окуловский Ю.С.* Алгоритм активного автоматического исследования: использование двух взаимосвязанных эволюционных алгоритмов для автономной калибровки робота // Системы управления и информационные технологии. 2010. 1(39). С. 96—99.
22. *Чиров Д.С., Стецюк А.Н.* Применение искусственных нейронных сетей в бортовых системах специальных робототехнических комплексов // Нейрокомпьютеры: разработка, применение. 2017. № 3. С. 42—43.
23. *Друки А.А.* Система поиска, выделения и распознавания лиц на изображениях // Изв. Томского политех. ун-та. 2011. Т. 318. № 5. Управление, вычислительная техника и информатика. С. 64—70.
24. *Воронов И.В.* Краткосрочное прогнозирование электропотребления энергосистем с помощью искусственных нейронных сетей // Электрические станции. 2009. № 12. С. 15—18.
25. *Воронов И.В.* Создание прогнозной модели электропотребления предприятия химической отрасли на основе искусственных нейронных сетей // Промышленная энергетика. 2011. № 3. С. 23—28.
26. *Крюков О.В., Серебряков А.В.* Искусственные нейронные сети прогнозирования технического состояния электродвигателей газоперекачивающих агрегатов // Вестник ЮУрГУ. Сер. Энергетика. 2016. Т. 16. № 1. С. 66—74.
27. *Wang G., Liao T.W.* Automatic identification of different types of welding defects in radiographic images // NTD & E International. 2002. V. 35. P. 519—528.
28. *Silva R.R., Caloba L.P., Siqueira M.H.S., Rebello J.M.A.* Pattern recognition of weld defects detected by radiographic test // NTD & E International. 2005. V. 37. P. 461—470.
29. *Silva R.R., Siqueira M.H.S., Souza M.P., Rebello J.M.A., Caloba L.P.* Estimated accuracy of classification of defects detected in welded joints by radiographic tests // NTD & E International. 2005. V. 38. P. 335—343.
30. *Vilar R., Zapata J., Ruiz R.* An automatic system of classification of weld defects in radiographic images // NTD & E International. 2009. V. 42. P. 467—476.
31. *Kasban H., Zahran O., Arafa H., El-Kordy M., Elaraby S.M.S., Abd El-Samie F.E.* Welding defect detection from radiography images with a cepstral approach // NTD & E International. 2011. V. 44. P. 226—231.
32. *Заковряшин А.С., Малинин П.В., Лепендин А.А.* Применение распределений мел-частотных кепстральных коэффициентов для голосовой идентификации личности // Изв. Алтайского гос. ун-та. Управление, вычислительная техника и информатика. Т. 1. С. 156—160.
33. *Zahran O., Kasban H., El-Kordy M., Abd El-Samie F.E.* Automatic weld defect identification from radiographic images // NTD & E International. 2013. V. 57. P. 26—35.
34. *Boaretto N., Mezzadri Centeno T.* Automated detection of welding defects in pipelines from radiographic images DWDI // NTD & E International. 2017. V. 86. P. 7—13.
35. *Zapata J., Vilar R., Ruiz R.* Performance evaluation of an automatic inspection system of weld defects in radiographic images based on neuro-classifiers // Expert Systems with Applications. 2011. V. 38. P. 8812—8824.
36. *Shao J., Du D., Chang B., Shi H.* Automatic weld defect detection based on potential defect tracking in real-time radiographic image sequence // NTD & E International. 2012. V. 46. P. 14—21.
37. *Zou Y., Du D., Chang B., Ji L., Pan J.* Automatic weld defect detection method based on Kalman filtering for real-time radiographic inspection of spiral pipe // NTD & E International. 2015. V. 72. P. 1—9.
38. *Yahia N.B., Belhadj T., Brag S., Zghal A.* Automatic detection of welding defects using radiography with a neural approach // Procedia Engineering. 2011. V. 10. P. 671—679.
39. *Valavanis I., Kosmopoulos D.* Multiclass defect detection and classification in weld radiographic images using geometric and texture features // Expert Systems with Applications. 2010. V. 37. P. 7606—7614.
40. *Hassan J., Majid Awan A., Jalil A.* Welding Defect Detection and Classification Using Geometric Features / Proceedings of the 10th International Conference on Frontiers of Information Technology. Islamabad, Pakistan. 2012. P. 139—144.
41. *Silva R.R., Siqueira M.H.S., Silva I.C., Carvalho A.A., Rebello J.M.A.* Contribution to the development of a radiographic inspection automated system // NDT.net. 2002. V. 7. No. 12.
42. *Круглова Е.В., Князюк Л.В.* Определение размеров дефектов сварных соединений по сканированному рентгеновскому снимку // Дефектоскопия. 2004. № 1. С. 57—60.
43. *Григорченко С.А., Ефименко Л.А.* Автоматизация компьютерной расшифровки радиационных изображений сварных соединений // Дефектоскопия. 2015. № 1. С. 21.
44. *Воробейчиков С.Э., Фокин В.А., Удод В.А., Темник А.К.* Исследование двух алгоритмов распознавания образов для классификации дефектов в объекте контроля по его цифровому изображению // Дефектоскопия. 2015. № 10. С. 54—63.

45. Воробейчиков С.Э., Фокин В.А., Удод В.А., Темник А.К. Оценка эффективности двух алгоритмов сегментации цифрового радиационного изображения объекта контроля // Дефектоскопия. 2017. № 2. С. 60—67.
46. Поляков А.В. О применении сверточных сетей при решении задачи неразрушающего контроля изделий // Успехи современной науки. 2017. Т. 1. № 5 С. 204—207.
47. Hou W., Wei Y., Guo J., Jin Y., Zhu C. Automatic Detection of Welding Defects using Deep Neural Network // IOP Conf. Series: Journal of Physics: Conf. Series. 2018. V. 933. 012006.
48. Hou W., Wei Y., Zhu C. Deep features based on a DCNN model for classifying imbalanced weld flaw types // Measurement. 2019. V. 131. P. 482—489.
49. Бархатов В.А. Обнаружение сигналов и их классификация с помощью распознавания образов // Дефектоскопия. 2006. № 4. С. 14—27.
50. Бархатов В.А. Распознавание дефектов с помощью искусственной нейронной сети специального типа // Дефектоскопия. 2006. № 2. С. 28—39.
51. Стенюшкин В.В., Гуськов Г.Ю., Шишкин В.В. Применение искусственных нейронных сетей в задачах ультразвукового неразрушающего контроля // Теоретические и практические аспекты развития отечественного авиационного: тезисы Всерос. науч.-техн. конф. Ульяновск: УЛГТУ, 2012. С. 76.
52. Соловьев А.Н., Соболев Б.В., Васильев П.В. Ультразвуковая локация внутренних трещиноподобных дефектов в составном упругом цилиндре с применением аппарата искусственных нейронных сетей // Дефектоскопия. 2016. № 3. С. 3—9.
53. Фомичев С.К., Пор Г., Пирумов А.Е., Яременко М.А. Возможность применения искусственных нейронных сетей для распознавания АЭ образов // Journal of Mechanical Engineering NTUU «Kyiv Polytechnic Institute». 2011. Т. 1. № 61. С. 199—203.
54. Khandetsky V., Antonyuk I. Signal processing in defect detection using back-propagation neural networks // NTD & E International. 2002. V. 35. P. 483—488.
55. Лунин В.П., Жданов А.Г., Лазуткин Д.Ю. Нейросетевой классификатор дефектов для многочастотного вихретокового контроля теплообменных труб // Дефектоскопия. 2007. № 3. С. 37—45.
56. Кузьмин Е.В., Горбунов О.Е., Плотников П.О., Тюкин В.А., Башкин В.А. Применение нейронных сетей для распознавания конструктивных элементов рельсов на магнитных и вихретоковых дефектограммах // Моделирование и анализ информационных систем. 2018. № 25(6). С. 667—679.
57. Шубочкин А.Е. Развитие методов и средств вихретокового и магнитного контроля металлопродукта для оценки его остаточного ресурса / Дис. ... д-ра техн. наук. Научно-исследовательский институт интроскопии МНПО «Спектр». ЗАО. Москва, 2014. 237 с.
58. Вавилов В.П., Нестерук Д.А. Активный тепловой контроль композиционных материалов с использованием нейронных сетей // Дефектоскопия. 2011. № 10. С. 10—18.