

DOI: 10.47026/1810-1909-2023-4-44-56

УДК 620.179.162

ББК 30.820.51

М.Г. БАШИРОВ, Д.Ш. АКЧУРИН,
К.Н. КУВАЙЦЕВ, Д.Е. МАКСИМОЧКИН**НЕЙРОСЕТЕВАЯ ОБРАБОТКА
ЭЛЕКТРОМАГНИТНО-АКУСТИЧЕСКОГО СИГНАЛА
ДЛЯ ИДЕНТИФИКАЦИИ НАПРЯЖЕННО-ДЕФОРМИРОВАННОГО
СОСТОЯНИЯ И ПОВРЕЖДЕННОСТИ
ЭНЕРГЕТИЧЕСКОГО ОБОРУДОВАНИЯ***

Ключевые слова: напряженно-деформированное состояние, электромагнитно-акустическое преобразование, амплитудные и фазовые спектры гармоник, частотные характеристики, искусственные нейронные сети, машинное обучение.

Цель исследования – разработка и обучение искусственной нейронной сети для идентификации напряженно-деформированного состояния и поврежденности металла энергетического оборудования по значениям параметров гармонических составляющих сигнала электромагнитно-акустического преобразователя.

Материалы и методы. Экспериментальное исследование взаимосвязи параметров гармонических составляющих сигнала электромагнитно-акустического преобразователя с напряженно-деформированным состоянием и поврежденностью структуры стандартных образцов металлов, разработка искусственной нейронной сети и методики её обучения идентификации напряженно-деформированного состояния и поврежденности структуры металла согласно диаграмме нагружения.

Результаты. Анализ изменения микроструктуры и частотных моделей стандартных образцов сталей, используемых в энергетическом машиностроении, подтвердил возможность идентификации напряженно-деформированного состояния и поврежденности структуры металлов по значениям параметров гармонических составляющих сигнала электромагнитно-акустического преобразователя. Для решения этой задачи разработана и обучена искусственная нейронная сеть. После обучения эффективность сети по идентификации напряженно-деформированного состояния и поврежденности структуры металлов достигла значения 92,16%, что для задач распознавания технического состояния металлических конструктивных элементов оборудования электроустановок является приемлемым.

Выводы. Использование искусственной нейронной сети для идентификации напряженно-деформированного состояния и поврежденности металлических конструкций по значениям параметров гармоник сигнала электромагнитно-акустического преобразователя позволяет выявить зоны концентрации механических напряжений и повреждения структуры металла на ранней стадии развития, тем самым повысить надежность и безопасность эксплуатации оборудования электроустановок.

Электроэнергетическое и электротехническое оборудование электростанций, электрических сетей, подстанций, электроустановок потребителей очень разнообразно по номенклатуре, но все они имеют в своем составе различные динамические или статические металлические конструктивные составляющие, в значительной мере определяющие надежность и безопасность всей системы

* Исследование выполнено при поддержке гранта РФФИ, проект № 22-29-00327 «Исследование взаимосвязанных изменений механических, электрофизических и акустических свойств металлов для реализации интеллектуальной электромагнитно-акустической системы идентификации напряженно-деформированного состояния и поврежденности нефтегазового оборудования».

производства и потребления электроэнергии. Механические повреждения являются одними из самых распространенных повреждений металлических конструктивных элементов оборудования электроустановок, к ним можно отнести износ и срыв резьбы деталей узлов крепления, трещины и разрушения несущих опорных конструкций, корпусов, лап крепления, роторов, статоров, подшипниковых узлов. Как показали результаты расследования комиссией Ростехнадзора причин аварии на Саяно-Шушенской ГЭС, крупнейшей в истории России аварии на гидроэнергетическом объекте, основной причиной аварии явилось разрушение шпилек крепления крышки турбины гидроагрегата, имевших усталостные повреждения, под действием динамических нагрузок [1]. Согласно статистическим данным и результатам анализа причин аварий на энергоустановках, подконтрольных органам Ростехнадзора, в 2021 г. произошел рост общего количества аварий на 47% по сравнению с таковым за аналогичный период 2020 г. Отмечается, что основными техническими причинами аварий на субъектах электроэнергетики явились износ оборудования в процессе эксплуатации и производственные дефекты, приводящие к механическим повреждениям и разрушениям оборудования [3]. Результаты анализа причин аварий на объектах электроэнергетики показывают, что разрушения оборудования могут произойти даже при допустимых расчетных значениях механических нагрузок. Это объясняется тем, что различные повреждения металла оборудования ослабляют конструкцию, формируют локальные зоны концентрации механических напряжений, существенно превышающих расчетные значения. Как установлено многочисленными исследованиями, процесс деградации конструкционных свойств металла зарождается в зонах локальных концентраций механических напряжений, в них возникают неоднородности структуры металла микро- и субмикронных размеров, которые развиваются в макродефекты, приводящие к разрушению оборудования.

В настоящее время электроэнергетический комплекс страны претерпевает глубокую модернизацию в соответствии с энергетической стратегией России на основе использования инновационной организационно-технологической платформы интеллектуальной энергосистемы с активно-адаптивной сетью (ИЭС ААС), являющейся единым энергоинформационным комплексом с интеллектуальным управлением и непрерывным контролем технического состояния и режима работы всех его элементов. Помимо снижения стоимости производства и передачи электрической энергии, снижения технических и коммерческих потерь при транспортировке, внедрение новой концепции позволяет существенно повысить надежность электрооборудования за счет дистанционного интеллектуального диагностического мониторинга технического состояния. Для дистанционного интеллектуального диагностического мониторинга напряженно-деформированного состояния и поврежденности металла энергетического оборудования необходимы соответствующие методы и средства неразрушающего контроля.

Выпускаемый в России спектр средств неразрушающего контроля и диагностики позволяет выявлять уже развитые, недопустимые, согласно нормативным документам, дефекты металла в процессе изготовления, монтажа

и эксплуатации энергетического оборудования. Но для предотвращения возникновения аварий, связанных с разрушением оборудования, необходимо выявлять зоны повышенной концентрации механических напряжений и контролировать состояние структуры металла для выявления дефектов на ранних стадиях развития. Поэтому проблема разработки новых методов и средств контроля напряженно-деформированного состояния оборудования и выявления дефектов на уровне структуры металла является весьма актуальной.

В последние годы для контроля энергетического оборудования начали применять методы и средства, основанные на использовании электромагнитно-акустического преобразования (ЭМАП), позволяющие бесконтактно выявлять дефекты металлов и контролировать их напряженно-деформированное состояние. Но из-за низкой эффективности двойного взаимного преобразования электромагнитных и акустических волн они существенно уступают традиционным акустическим средствам с контактными пьезоэлектрическими преобразователями в чувствительности и точности, не позволяют выявлять микротрещины и анализировать пространственно-временное распределение механических напряжений [5, 6, 9]. Отечественные и зарубежные ученые опубликовали много работ по результатам теоретических и экспериментальных исследований, направленных на повышение чувствительности и информативности электромагнитно-акустических методов и средств контроля [2, 13, 15, 16]. Но они в основном направлены на совершенствование конструкции ЭМАП и разработку различных способов выделения и обработки информации, содержащейся в параметрах акустических волн, информативный потенциал электромагнитной составляющей ЭМАП при этом не был достаточно исследован.

В работе [14] предложен новый подход к совершенствованию электромагнитно-акустического метода контроля, основанный на использовании «параметров временных и пространственных гармоник вторичного электромагнитного поля, которые, в свою очередь, преобразуются в параметры гармонических составляющих выходного сигнала ЭМАП. Обратная задача – идентификация напряженно-деформированного состояния и уровня поврежденности структуры металла оборудования по значениям параметров гармонических составляющих сигнала ЭМАП может быть решена применением метода спектрального анализа». Но из-за большого объема исходной информации, которую необходимо при этом обработать, без использования современных интеллектуальных нейросетевых технологий это сделать практически невозможно, учитывая опыт подобных исследований, схожих по количеству обрабатываемых данных [7, 8, 12, 17–20].

Цель настоящего исследования – разработка и обучение искусственной нейронной сети (ИНС) для идентификации напряженно-деформированного состояния и поврежденности металла энергетического оборудования по значениям параметров гармонических составляющих сигнала ЭМАП.

Материалы и методы исследования. Для экспериментального исследования взаимосвязи параметров сигнала ЭМАП с напряженно-деформированным состоянием и поврежденностью структуры металлов и формирования

нового подхода к выделению и обработке параметров электромагнитно-акустического преобразования были использованы методика и информационно-измерительный комплекс, описанные в работе [9]. В качестве образцов металлов для проведения исследований были выбраны широко используемые в энергетическом машиностроении стали марок СтЗсп и 09Г2С, из которых были изготовлены пропорциональные плоские стандартные образцы по ГОСТ 1497-84. Металлы. Методы испытаний на растяжение¹.

Исследования по схеме одноосного статического растяжения образцов проводились с использованием испытательных машин УММ-5 и Walter + Bai LF TTM-600. В качестве генератора импульсов тока, электромагнитно-акустического преобразователя, усилителя сигнала электромагнитно-акустического преобразователя и согласованного фильтра в составе информационно-измерительного комплекса были использованы соответствующие модули серийно выпускаемого компанией «Октанта» электромагнитно-акустического толщиномера EM4000 с программным обеспечением ScanView. Прибор позволяет подключать любые устройства на базе ОС Android, анализировать электромагнитно-акустические сигналы в формате А-скан, В-скан, выбирать параметры обработки сигнала. С помощью ЭМАП генерировались акустические импульсы в объеме исследуемых образцов стали и исследовалось изменение пространственных и временных гармонических составляющих вторичного электромагнитного поля над их поверхностью в процессе изменения напряженно-деформированного состояния. Для спектрального анализа сигнала ЭМАП использовано программное обеспечение WinПОС «Expert». Металлографический анализ и регистрация изменений в структуре сталей в процессе испытаний образцов осуществлялись с использованием металлургического микроскопа Микромед МЕТ С.

В процессе испытаний образцов стали снимались диаграммы растяжения и на них отмечались контрольные точки О, А, В, Д, Р, в которых существенно изменялись механические, электрофизические и акустические свойства металла: исходное состояние металла σ_0 ; предел пропорциональности $\sigma_{пл}$; предел упругости $\sigma_{уп}$; предел текучести $\sigma_{т}$; предел временного сопротивления (прочности) $\sigma_{в}$; напряжение непосредственно перед разрушением образца $\sigma_{р}$. В контрольных точках проводился металлографический анализ изменений в структуре металла и спектральный анализ сигнала ЭМАП. С учетом обратимой деформации образцов они нагружались до значений напряжений и деформаций, соответствующих точкам С, Е, К на диаграмме растяжения, превышающих их значения в контрольных точках (рис. 1).

Применением частного случая метода динамической идентификации при импульсном входном воздействии на объект исследования – метода моментов [4, 10] – на основе анализа параметров сигнала ЭМАП формируется интегральный параметр $W(p)$ в операторной форме, характеризующий совокупность механических, акустических и электрофизических свойств образца металла, соответствующих напряженно-деформированному состоянию и поврежденности структуры согласно диаграмме растяжения [6].

¹ ГОСТ 1497-84. Металлы. Методы испытаний на растяжение. М.: Стандартинформ, 2008. 26 с.

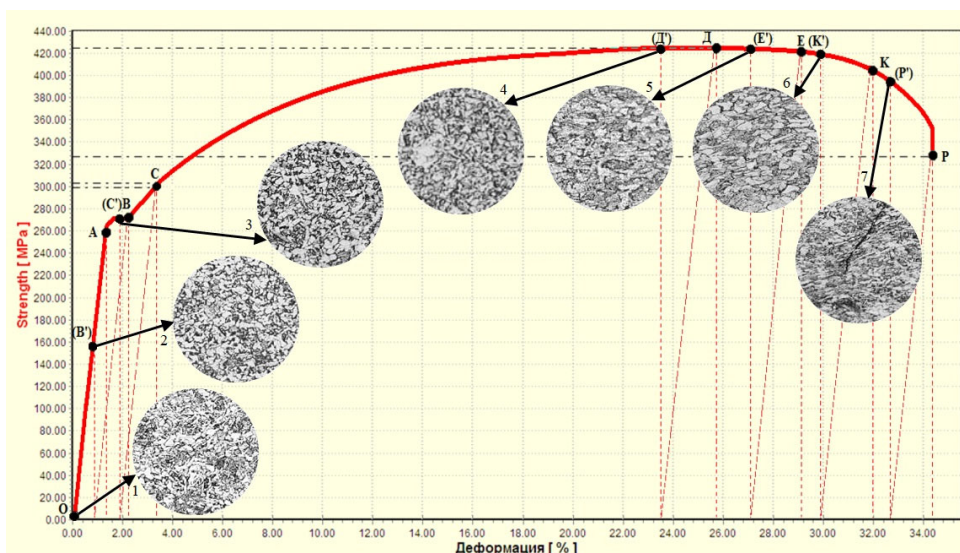


Рис. 1. Диаграмма растяжения образца из стали Ст3сп

Путем замены оператора p на $j\omega$ получаем частотные модели напряженно-деформированного состояния образцов [6, 7]:

$$W(j\omega) = \frac{Y(j\omega)}{X(j\omega)} = K \frac{b_0 + b_1 \cdot (j\omega) + \dots + b_m \cdot (j\omega)^m}{a_0 + a_1 \cdot (j\omega) + \dots + a_n \cdot (j\omega)^n} = K \frac{B(j\omega)}{A(j\omega)}, \quad (1)$$

где $Y(j\omega)$ и $X(j\omega)$ – сигналы отклика и воздействия ЭМА преобразователя в частотной форме; $B(j\omega)$ и $A(j\omega)$ – многочлены числителя и знаменателя; K – коэффициент передачи; a_i , b_i – коэффициенты многочленов числителя и знаменателя.

Каждой точке диаграммы растяжения металла соответствует своя частотная модель (1), формируемая совокупностью гармонических составляющих сигнала ЭМА преобразователя, поэтому по значениям параметров гармонических составляющих сигнала можно решить обратную задачу – идентифицировать текущее напряженно-деформированное состояние образца металла. Графическим изображением частотной модели является амплитудно-фазовая частотная характеристика (АФЧХ) объекта контроля на комплексной плоскости. На рис. 2 в качестве примера представлены АФЧХ образца из стали Ст3сп в исходном состоянии и при остаточном напряжении растяжения 320 МПа.

АФЧХ наглядно демонстрируют, что с изменением напряженно-деформированного состояния и поврежденности структуры образцов металла происходит изменение параметров частотных характеристик и, соответственно, параметров спектра гармонических составляющих сигнала ЭМАП. Для решения обратной задачи – идентификации напряженно-деформированного состояния и поврежденности структуры металла в соответствии с диаграммой нагружения используется искусственная нейронная сеть, обученная по результатам экспериментальных исследований.




Рис. 2. Амплитудно-фазовые частотные характеристики (АФЧХ) образца стали СтЗсп при растяжении: *a* – без нагрузки; *б* – при нагрузке 320 Мпа

Результаты. Для идентификации напряженно-деформированного состояния и поврежденности металла по значениям параметров гармонических составляющих сигнала ЭМА преобразователя разработана и обучена ИНС. Реализация проекта осуществлялась с использованием языка программирования C#, среды разработки Microsoft Visual Studio, библиотеки ML.NET, основанной на фреймворке .NET. В основе ML.NET лежит модель машинного обучения. Эта модель определяет шаги, которые необходимо выполнить для получения прогнозов на основе входных данных [11]. Была выбрана интеллектуальная модель классификатора данных, которая прогнозирует их распределение по нескольким классам (категориям). При обучении используется набор данных с метками, обученный классификатор уже может распределять по классам новые данные без меток.

В качестве инструмента обработки данных в ИНС-классификаторе выступает полиномиальная логистическая регрессия, которая является разновидностью множественной регрессии, общее назначение которой состоит в анализе связи между несколькими независимыми переменными (называемыми также регрессорами или предикторами) и зависимой переменной. В процессе обучения с учителем на вход и выход ИНС подаются соответствующие параметры, по значениям которых она подстраивает веса своих синаптических связей в соответствии с алгоритмом, стремящимся минимизировать ошибку. Для каждого входного вектора существует целевой вектор на выходе. Вместе они образуют представительскую или обучающую выборку. Вычисления ошибок и подстройка весов осуществляются до тех пор, пока ошибка по всему обучающему массиву не достигнет приемлемо низкого уровня.

Структура ИНС на основе модели логистической регрессии изображена на рис. 3, она содержит 3 слоя:

- входной слой (первый слой в нейронной сети, который принимает входящие сигналы и передает их на последующие уровни);
- скрытый (вычислительный) слой;
- выходной слой (последний слой в сети, целевая функция).

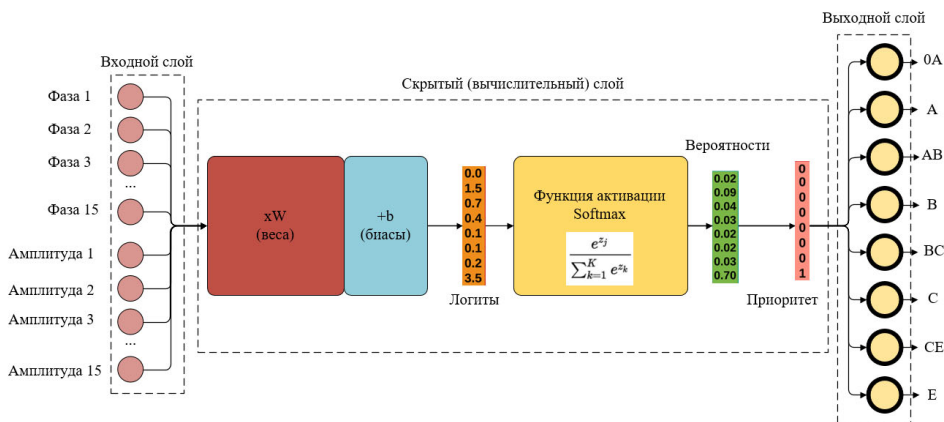


Рис. 3. Структура искусственной нейронной сети

Входными данными для ИНС служат амплитуды и фазы первых 15 гармоник сигнала ЭМАП. Выборка данных формируется в формате MS Excel для дальнейшей загрузки в ИНС для ее обучения (рис. 4). Одна строка соответствует одному измерению, состоит из 30 значений и метки класса (заранее задаем известную точку на диаграмме напряженно деформированного состояния, так как применяем «обучение с учителем»).

a1	a2	a3	a4	a5	a6	a7	a8	a9	a10	a11	a12	a13	a14	a15	f1	f2	f3	f4	f5	f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	res	
0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	1,21	0,85	0,49	0,13	-0,23	-0,59	-0,95	-1,32	1,46	1,09	0,72	0,34	-0,03	-0,40	-0,78	0A
0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	1,22	0,86	0,50	0,14	-0,22	-0,58	-0,94	-1,31	1,47	1,10	0,73	0,35	-0,02	-0,39	-0,77	0A
-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	1,20	0,84	0,48	0,12	-0,24	-0,60	-0,96	-1,33	1,45	1,08	0,71	0,33	-0,04	-0,41	-0,79	0A
-0,39	-0,39	-0,39	-0,39	-0,39	-0,39	-0,39	-0,39	-0,40	-0,41	-0,42	-0,44	-0,46	-0,48	-0,51	1,25	0,92	0,60	0,27	-0,06	-0,38	-0,71	-1,04	-1,37	1,43	1,10	0,76	0,42	0,07	-0,27	0A	
-0,38	-0,38	-0,38	-0,38	-0,38	-0,38	-0,38	-0,38	-0,39	-0,40	-0,41	-0,43	-0,45	-0,47	-0,50	1,26	0,93	0,61	0,28	-0,05	-0,37	-0,70	-1,03	-1,36	1,44	1,11	0,77	0,43	0,08	-0,26	0A	
-0,40	-0,40	-0,40	-0,40	-0,40	-0,40	-0,40	-0,40	-0,41	-0,42	-0,43	-0,45	-0,47	-0,49	-0,52	1,24	0,91	0,59	0,26	-0,07	-0,39	-0,72	-1,05	-1,38	1,42	1,09	0,75	0,41	0,06	-0,28	0A	
-0,17	-0,16	-0,14	-0,11	-0,08	-0,05	-0,01	0,03	0,06	0,10	0,12	0,13	0,13	0,10	0,05	1,24	0,92	0,59	0,26	-0,07	-0,39	-0,72	-1,05	-1,38	1,43	1,09	0,76	0,43	0,09	-0,24	0A	
-0,16	-0,15	-0,13	-0,10	-0,07	-0,04	0,00	0,04	0,07	0,11	0,13	0,14	0,14	0,11	0,06	1,25	0,93	0,60	0,27	-0,06	-0,38	-0,71	-1,04	-1,37	1,44	1,10	0,77	0,44	0,10	-0,23	0A	
-0,18	-0,17	-0,15	-0,12	-0,09	-0,06	-0,02	0,02	0,05	0,09	0,11	0,12	0,12	0,09	0,04	1,23	0,91	0,58	0,25	-0,08	-0,40	-0,73	-1,06	-1,39	1,42	1,08	0,75	0,42	0,08	-0,25	0A	
-0,12	-0,12	-0,11	-0,11	-0,10	-0,10	-0,09	-0,09	-0,09	-0,09	-0,09	-0,10	-0,11	-0,12	-0,12	1,21	0,86	0,50	0,14	-0,22	-0,58	-0,94	-1,31	1,47	1,10	0,73	0,35	-0,03	-0,40	-0,78	0A	
-0,11	-0,11	-0,10	-0,10	-0,10	-0,09	-0,09	-0,09	-0,08	-0,08	-0,08	-0,08	-0,09	-0,10	-0,11	1,22	0,87	0,51	0,15	-0,21	-0,57	-0,93	-1,30	1,48	1,11	0,74	0,36	-0,02	-0,39	-0,77	0A	
-0,13	-0,13	-0,12	-0,12	-0,12	-0,11	-0,11	-0,11	-0,10	-0,10	-0,10	-0,11	-0,12	-0,13	-0,13	1,20	0,85	0,49	0,13	-0,23	-0,59	-0,95	-1,32	1,46	1,09	0,72	0,34	-0,04	-0,41	-0,79	0A	
-0,18	-0,18	-0,16	-0,15	-0,13	-0,10	-0,07	-0,05	-0,02	0,01	0,03	0,05	0,06	0,06	0,04	1,24	0,91	0,59	0,26	-0,07	-0,40	-0,73	-1,06	-1,40	1,41	1,08	0,74	0,41	0,07	-0,26	0A	
-0,17	-0,17	-0,15	-0,14	-0,12	-0,09	-0,06	-0,04	-0,01	0,02	0,04	0,06	0,07	0,07	0,05	1,25	0,92	0,60	0,27	-0,06	-0,39	-0,72	-1,05	-1,39	1,42	1,09	0,75	0,42	0,08	-0,25	0A	
-0,19	-0,19	-0,17	-0,16	-0,14	-0,11	-0,08	-0,06	-0,03	0,00	0,02	0,04	0,05	0,05	0,03	1,23	0,90	0,58	0,25	-0,08	-0,41	-0,74	-1,07	-1,41	1,40	1,07	0,73	0,40	0,06	-0,27	0A	
-0,22	-0,22	-0,22	-0,21	-0,21	-0,20	-0,19	-0,19	-0,18	-0,18	-0,19	-0,20	-0,21	-0,23	-0,26	1,25	0,92	0,59	0,27	-0,06	-0,39	-0,72	-1,05	-1,38	1,42	1,09	0,75	0,41	0,06	-0,28	0A	
-0,21	-0,21	-0,21	-0,20	-0,20	-0,19	-0,18	-0,18	-0,17	-0,17	-0,18	-0,19	-0,20	-0,22	-0,25	1,26	0,93	0,60	0,28	-0,05	-0,38	-0,71	-1,04	-1,37	1,43	1,10	0,76	0,42	0,07	-0,27	0A	
-0,23	-0,23	-0,23	-0,22	-0,22	-0,21	-0,20	-0,20	-0,19	-0,19	-0,20	-0,21	-0,22	-0,24	-0,27	1,24	0,91	0,58	0,26	-0,07	-0,40	-0,73	-1,06	-1,39	1,41	1,08	0,74	0,40	0,05	-0,29	0A	
0,81	0,82	0,82	0,83	0,84	0,85	0,86	0,86	0,87	0,87	0,87	0,87	0,85	0,83	0,79	0,73	1,24	0,91	0,58	0,25	-0,08	-0,41	-0,74	-1,07	-1,40	1,41	1,07	0,74	0,40	0,07	-0,27	0A
0,82	0,83	0,83	0,84	0,85	0,86	0,87	0,88	0,88	0,88	0,88	0,86	0,84	0,80	0,74	1,25	0,92	0,59	0,26	-0,07	-0,40	-0,73	-1,06	-1,39	1,42	1,08	0,75	0,41	0,08	-0,26	0A	
0,80	0,81	0,81	0,82	0,83	0,84	0,85	0,86	0,86	0,86	0,86	0,84	0,82	0,78	0,72	1,23	0,90	0,57	0,24	-0,09	-0,42	-0,75	-1,08	-1,41	1,40	1,06	0,73	0,39	0,06	-0,28	0A	
1,28	1,27	1,27	1,27	1,26	1,25	1,24	1,22	1,20	1,16	1,11	1,05	0,97	0,88	0,81	1,24	0,91	0,58	0,25	-0,08	-0,41	-0,74	-1,08	-1,41	1,40	1,07	0,73	0,40	0,06	-0,27	0A	
1,29	1,28	1,28	1,28	1,28	1,27	1,26	1,25	1,23	1,21	1,17	1,12	1,06	0,98	0,89	1,25	0,92	0,59	0,26	-0,07	-0,40	-0,73	-1,07	-1,40	1,41	1,08	0,74	0,41	0,07	-0,26	0A	

Рис. 4. Выборка входных данных

Далее входные данные поступают на скрытый слой и формируют весовую матрицу и векторы смещения (биасы). Логиты – это векторы необработанных (ненормализованных) прогнозов, генерируемые моделью классификации. Данная модель, в свою очередь, передается в функцию нормализации. Модель решает задачу многоклассовой классификации, поэтому логиты становятся входными данными для функции активации – softmax. Затем функция softmax генерирует вектор (нормализованных) вероятностей с одним значением для каждого возможного класса.

Функция активации softmax математически записывается как

$$S(y)_i = \frac{\exp(y_i)}{\sum_{j=1}^n \exp(y_j)}, \quad (2)$$

где y – является входным вектором для функции softmax S (он состоит из n элементов для n классов); $\exp(y_i)$ – стандартная экспоненциальная функция.

Состояния функции активации softmax (2) соответствуют 8 заданным состояниям выходных нейронов, определяющих наибольшую вероятность принадлежности к одному из 8 диапазонов между контрольными точками на диаграмме растяжения.

Обучение ИНС осуществляется средствами библиотеки ML.NET следующим образом:

- 1) осуществляется выбор сценария обучения в зависимости от поставленной задачи;
- 2) осуществляется выбор среды обучения (персональный компьютер или выделенный удаленный сервер);
- 3) загружается выборка данных в формате .csv, .txt либо база данных SQL Server;
- 4) устанавливается длительность обучения (с).

В процессе обучения ИНС построитель моделей ML.NET исследует отдельные модели алгоритмов классификации, используя разные параметры, и выбирает среди них оптимальную модель для предоставленного набора данных. Следует отметить главное достоинство данного построителя моделей: он достаточно прост в использовании, так как процесс построения и исследования моделей полностью автоматизирован. Но в то же время это и главный недостаток данного инструмента: по своей сути построитель моделей представляет собой «черный ящик» ввиду отсутствия возможности оперирования пользователем тонкими ручными настройками и регулировками.

После загрузки заранее сформированной обучающей выборки, состоящей из 586 строк MS Excel (около 50–80 строк на каждый класс), автоматический построитель моделей ML.NET исследовал 183 модели, среди которых выделил наилучшую, точность которой достигает 92,16% (рис. 5).

Время для обучения (в секундах):

✓ Обучение завершено

Результаты обучения

Наилучшая точность:	0,9216
Наилучшая модель:	LightGbmMulti
Время обучения:	566,19 секунды
Исследовано моделей (всего):	183
Созданный код программной части:	MLModel1.consumption.cs, MLModel1.training.cs

Рис. 5. Представление результата обучения ИНС

Результатом обучения ИНС является интеллектуальная модель, которая хранится внутри сформированного исполнительного файла программы. При загрузке новых экспериментальных данных гармонических составляющих в программу входные данные обращаются к уже готовой интеллектуальной модели, которая, в свою очередь, формирует предположение, в каком промежутке между контрольными точками диаграммы напряженно-деформированного состояния находится исследуемый образец металла.

Выводы. В зонах повышенной концентрации механических напряжений металлических конструктивных элементов энергетического оборудования зарождаются неоднородности структуры металла микро- и субмикронных размеров, которые под действием постоянных и переменных нагрузок развиваются в макродефекты, приводящие к разрушению. Ранняя идентификация напряженно-деформированного состояния и поврежденности структуры металла позволяет предотвратить аварии, связанные с отказом и разрушением оборудования. Одним из перспективных направлений решения этой задачи является использование электромагнитно-акустического преобразования, информативный потенциал которого на сегодняшний день исследован недостаточно полно.

По результатам исследований предложено применение в качестве интегрального параметра для идентификации напряженно-деформированного состояния и поврежденности металла оборудования частотной модели, получаемой на основе спектрального анализа сигнала ЭМАП.

Использование искусственной нейронной сети для анализа параметров частотной модели позволяет упростить процесс идентификации напряженно-деформированного состояния и поврежденности металла конструкций, повысить её достоверность и, соответственно, надежность и безопасность эксплуатации электрооборудования. Для повышения достоверности идентификации напряженно-деформированного состояния и поврежденности металла электрооборудования будут продолжены экспериментальные исследования, направленные на расширение обучающей базы данных частотных моделей.

Литература

1. Акт технического расследования причин аварии на Саяно-Шушенской ГЭС 17 августа 2009 года [Электронный ресурс]. URL: http://www.gosnadzor.ru/news/aktSSG_bak.doc (дата обращения: 07.08.2023).
2. *Алешин Н.П.* Исследование выявляемости поверхностных объемных дефектов при ультразвуковом контроле с применением волн Рэлея, генерируемых электромагнитно-акустическим преобразователем // Дефектоскопия. 2021. № 5. С. 22–30.
3. Анализ причин аварий на энергоустановках, подконтрольных органам Ростехнадзора за 2021 год [Электронный ресурс] // Ростехнадзор. Северо-Западное Управление: сайт. URL: http://szap.gosnadzor.ru/activity/energogradzor/nesc_sluch/Анализ%20причин%20аварий%20за%202021.pdf / (дата обращения 07.08.2023).
4. *Аязян Г.К., Хоробров В.Р., Галиев Р.М.* Метод идентификации динамических характеристик объектов с запаздыванием // Автоматизация и метрологическое обеспечение в нефтяной промышленности: межвуз. науч. сб. Уфа: Изд-во УНИ, 1980. С. 29–33.
5. *Баширов М.Г., Баширова Э.М., Юсупова И.Г., Акчурин Д.Ш.* Исследование способов повышения эффективности электромагнитно-акустического преобразования средств диагностики энергетического оборудования // Промышленная энергетика. 2022. № 10. С. 2–9.
6. *Баширов М.Г., Хуснутдинова И.Г., Хуснутдинова Л.Г., Усманов Д.Р.* Электромагнитно-акустический метод оценки технического состояния энергетического оборудования // Промышленная энергетика. 2016. № 12. С. 8–13.

7. Иванов С.О., Никандров М.В., Славутский Л.А. Нейросетевое моделирование релейной защиты с временной задержкой // Вестник Чувашского университета. 2022. № 3. С. 53–60. DOI: 10.47026/1810-1909-2022-3-53-60.

8. Коцеев М.И., Ларюхин А.А., Славутский А.Л. Использование адаптивных нейроалгоритмов для распознавания аномальных режимов систем вторичного оборудования электроэнергетики // Вестник Чувашского университета. 2019. № 1. С. 47–58.

9. Моделирование и экспериментальное исследование влияния механических напряжений и поврежденности металла нефтегазового оборудования на параметры электромагнитно-акустического преобразования / М.Г. Баширов., Э.М. Баширова, И.Г. Юсупова и др. // Нефтегазовое дело. 2023. Т. 21, № 1. С. 183–194.

10. Огородников Ю.И. Задача параметрической идентификации моделей управляемых динамических систем как проблема моментов // Современные технологии. Системный анализ. Моделирование. 2017. Т. 56, № 4. С. 33–40.

11. Скоросужева О.И. Функциональные возможности ML.NET // Современные научные исследования и инновации. 2023. № 5 [Электронный ресурс]. URL: <https://web.snauka.ru/issues/2023/05/100324> (дата обращения: 19.10.2023).

12. Славутский Л.А., Славутская Е.В. Нейросетевая обработка сигналов: задачи без «глубокого обучения» // Вестник Чувашского университета. 2023. № 2. С. 151–160. DOI: 10.47026/1810-1909-2023-2-151-160.

13. Углов А.Л., Хлыбов А.А., Бычков А.Л., Кувишинов М.О. О неразрушающем контроле остаточных напряжений в деталях осесимметричной формы из стали 03Н17К10В10МТ // Вестник ИжГТУ имени М.Т. Калашникова. 2019. Т. 22, № 4. С. 3–10.

14. Хуснутдинова И.Г., Баширов М.Г. Оценка технического состояния и ресурса безопасной эксплуатации технологических трубопроводов на основе электромагнитно-акустического эффекта // Нефтегазовое дело. 2019. № 1. С. 144–162.

15. Ducoussou M., Reverdy F. Real-time imaging of microcracks on metallic surface using total fo-cusing method and plane wave imaging with Rayleigh waves. *NDT E Int.*, 2020, vol. 116, p. 102311.

16. Jiang C., Li Z., Zhang Z., Wang S. New Design to Rayleigh Wave EMAT Based on Spatial Pulse Compression. *Sensors (Basel)*, 2023, vol. 23(8), 3943.

17. Leroux S., Bohez S., Verbelen T. et al. Resource-constrained classification using a cascade of neural network layers. In: International Joint Conference on Neural Networks (IJCNN), 2015, pp. 1–7, DOI: 10.1109/IJCNN.2015.7280601.

18. Leroux S., Verbelen T., Simoens P. et al. Iterative neural networks for adaptive inference on resource-constrained devices. *Neural Comput & Applic*, 2022, vol. 34, pp. 10321–10336. DOI: 10.1007/s00521-022-06910-5.

19. Oh J.W., Jeong J. Convolutional neural network and 2-D image based fault diagnosis of bearing without retraining. In: 3rd International Conference (ICDA 2019), 2019, pp. 134–138. DOI: 10.1145/3314545.3314563.

20. Wang S., Huang S., Wang Q. et al. Accelerated optimizations of an electromagnetic acoustic transducer with artificial neural networks as metamodels, *J. Sens. Sens. Syst.*, 6, 2017, pp. 269–284.

БАШИРОВ МУССА ГУМЕРОВИЧ – доктор технических наук, профессор кафедры электрооборудования и автоматики промышленных предприятий, Институт нефтепереработки и нефтехимии, Уфимский государственный нефтяной технический университет, Россия, Салават (eapp@yandex.ru; ORCID: <https://orcid.org/0000-0001-7493-6803>).

АКЧУРИН ДАМИР ШАМИЛЕВИЧ – аспирант, ассистент кафедры электрооборудования и автоматики промышленных предприятий, Институт нефтепереработки и нефтехимии, Уфимский государственный нефтяной технический университет, Россия, Салават (akihiro177@mail.ru; ORCID: <https://orcid.org/0000-0002-2174-8216>).

КУВАЙЦЕВ КИРИЛЛ НИКОЛАЕВИЧ – магистрант направления «Автоматизация технологических процессов и производств», Институт нефтепереработки и нефтехимии, Уфимский государственный нефтяной технический университет, Россия, Салават (kirill.kuvaitsev@mail.ru).

МАКСИМОЧКИН ДМИТРИЙ ЕФИМОВИЧ – магистрант направления «Автоматизация технологических процессов и производств», Институт нефтепереработки и нефтехимии, Уфимский государственный нефтяной технический университет, Россия, Салават (03maksimochkin.de@bashgaz.ru).

Mussa G. BASHIROV, Damir Sh. AKCHURIN,
Kirill N. KUVAYTSEV, Dmitry E. MAKSIMOCHKIN
NEURAL NETWORK PROCESSING
OF ELECTROMAGNETIC ACOUSTIC SIGNALS
TO IDENTIFY THE STRESS-STRAIN STATE
AND DAMAGE OF POWER EQUIPMENT

Key words: stress-strain state, electromagnetic-acoustic diagnostic method, amplitude and phase spectra of harmonics, frequency characteristics, artificial neural networks, machine learning.

The purpose of the study is to develop and train an artificial neural network to identify the stress-strain state and damage to the metal of power equipment based on the values of the parameters of the harmonic components of the electromagnetic-acoustic transducer signal.

Materials and methods. Experimental study of the relationship between the parameters of the harmonic components of the signal of an electromagnetic-acoustic transducer with the stress-strain state and damage to the structure of standard metal samples, development of an artificial neural network and methods for its training to identify the stress-strain state and damage to the structure of the metal according to the loading diagram.

Results. Analysis of changes in the microstructure and frequency models of standard steel samples used in power engineering confirmed the possibility of identifying the stress-strain state and damage to the structure of metals based on the values of the parameters of the harmonic components of the electromagnetic-acoustic transducer signal. To solve this problem, an artificial neural network has been developed and trained. After training, the effectiveness of the network in identifying the stress-strain state and damage to the structure of metals reached 92.16%, which is acceptable for the tasks of recognizing the technical condition of metal structural elements of electrical installation equipment.

Conclusions. The use of an artificial neural network to identify the stress-strain state and damage to metal structures based on the harmonic parameters of the electromagnetic-acoustic transducer signal enables to identify areas of concentration of mechanical stress and damage to the metal structure at the early stage of development, thereby increasing reliability and safety operation of electrical equipment.

References

1. Akt tekhnicheskogo rassledovaniya prichin avarii na Sayano-Shushenskoi GES 17 avgusta 2009 goda [Report of technical investigation into the causes of the accident at the Sayano-Shushenskaya HPP on August 17, 2009]. Available at: http://www.gosnadzor.ru/news/aktSSG_bak.doc (Accessed Data: 2023, Aug. 7).
2. Aleshin N.P. Issledovanie vyavlyaemosti poverkhnostnykh ob"emnykh defektov pri ul'trazvukovom kontrole s primeneniem voln Releya, generiruemyykh elektromagnitno-akusticheskim preobrazovatelem [Study of the detectability of surface volumetric defects during ultrasonic testing using Rayleigh waves generated by an electromagnetic-acoustic transducer]. *Defektoskopiya*, 2021, no. 5, pp. 22–30.
3. Analiz prichin avarii na energoustanovkakh, podkontrol'nykh organam Rostekhnadzora za 2021 god [Analysis of the causes of accidents at power plants controlled by Rostekhnadzor for 2021]. Available at: http://szap.gosnadzor.ru/activity/energonadzor/nesc_sluch/Analiz%20prichin%20avarii-%20za%202021.pdf (Accessed Data: 2023, Aug. 7).
4. Ayazyan G.K., Khorobrov V.R., Galiev R.M. Metod identifikatsii dinamicheskikh kharakteristik ob"ektov s zapazdyvaniem [Method for identifying the dynamic characteristics of objects with delay]. *Avtomatizatsiya i metrologicheskoe obespechenie v neftyanoi promyshlennosti: mezhvuz. nauchy sbornik* [Automation and metrological support in the oil industry: Scientific Collection]. Ufa, Publ. UNI, 1980, pp. 29–33.
5. Bashirov M.G., Bashirova E.M., Yusupova I.G., Akchurin D.Sh. Issledovanie sposobov povysheniya effektivnosti elektromagnitno-akusticheskogo preobrazovaniya sredstv diagnostiki

energeticheskogo oborudovaniya [Research on ways to increase the efficiency of electromagnetic-acoustic conversion of diagnostic tools for power equipment]. *Promyshlennaya energetika*, 2022, no. 10, pp. 2–9.

6. Bashirov M.G., Khusnutdinova I.G., Khusnutdinova L.G., Usmanov D.R. *Elektromagnitno-akusticheskii metod otsenki tekhnicheskogo sostoyaniya energeticheskogo oborudovaniya* [Electromagnetic-acoustic method for assessing the technical condition of power equipment]. *Promyshlennaya energetika*, 2016, no. 12, pp. 8–13.

7. Ivanov S.O., Nikandrov M.V., Slavutskii L.A. *Neirosetevoe modelirovanie releinoi zashchity s vremennoi zaderzhkoi* [Neural network modeling of relay protection with time delay]. *Vestnik Chuvashskogo universiteta*, 2022, no. 3, pp. 53–60. DOI: 10.47026/1810-1909-2022-3-53-60.

8. Koshcheev M.I., Laryukhin A.A., Slavutskii A.L. *Ispol'zovanie adaptivnykh neuroalgoritmov dlya raspoznavaniya anomal'nykh rezhimov sistem vtorichnogo oborudovaniya elektroenergetiki* [Using adaptive neuroalgorithms to recognize anomalous modes of secondary equipment systems in the electrical power industry]. *Vestnik Chuvashskogo universiteta*, 2019, no. 1, pp. 47–58.

9. Bashirov M.G., Bashirova E.M., Yusupova I.G. et al. *Modelirovanie i eksperimental'noe issledovanie vliyaniya mekhanicheskikh napryazhenii i povrezhdennosti metalla neftegazovogo oborudovaniya na parametry elektromagnitno-akusticheskogo preobrazovaniya* [Modeling and experimental study of the influence of mechanical stresses and metal damage of oil and gas equipment on the parameters of electromagnetic-acoustic conversion]. *Neftegazovoe delo*, 2023, vol. 21, no. 1, pp. 183–194.

10. Ogorodnikov Yu.I. *Zadacha parametricheskoi identifikatsii modelei upravlyaemykh dinamicheskikh sistem kak problema momentov* [The problem of parametric identification of models of controlled dynamic systems as a problem of moments]. *Sovremennye tekhnologii. Sistemnyi analiz. Modelirovanie*, 2017, vol. 56, no. 4, pp. 33–40.

11. Skorosueva O.I. *Funktional'nye vozmozhnosti ML.NET* [Functionality ML.NET]. *Sovremennye nauchnye issledovaniya i innovatsii*, 2023, no. 5. Available at: <https://web.snauka.ru/issues/2023/05/100324> (Accessed Date: 2023, Aug. 7).

12. Slavutskii L.A., Slavutskaya E.V. *Neirosetevaya obrabotka signalov: zadachi bez «glubokogo obucheniya»* [Neural network signal processing: tasks without “deep learning”]. *Vestnik Chuvashskogo universiteta*, 2023, no. 2, pp. 151–160. DOI: 10.47026/1810-1909-2023-2-151-160.

13. Uglov A.L., Khlybov A.A., Bychkov A.L., Kuvshinov M.O. *O nerazrushayushchem kontrole ostatochnykh napryazhenii v detalyakh osesimmetrichnoi formy iz stali 03N17K10V10MT* [On non-destructive testing of residual stresses in axisymmetrically shaped parts made of steel 03N17K10V10MT]. *Vestnik IzhGTU imeni M.T. Kalashnikova*, 2019, vol. 22, no. 4, pp. 3–10.

14. Khusnutdinova I.G., Bashirov M.G. *Otsenka tekhnicheskogo sostoyaniya i resursa bezopasnoi ekspluatatsii tekhnologicheskikh truboprovodov na osnove elektromagnitno-akusticheskogo effekta* [Assessment of the technical condition and resource of safe operation of process pipelines based on the electromagnetic-acoustic effect]. *Neftegazovoe delo*, 2019, no. 1, pp. 144–162.

15. Ducouso M., Reverdy F. Real-time imaging of microcracks on metallic surface using total fo-cusing method and plane wave imaging with Rayleigh waves. *NDT E Int.*, 2020, vol. 116, p. 102311.

16. Jiang C., Li Z., Zhang Z., Wang S. New Design to Rayleigh Wave EMAT Based on Spatial Pulse Compression. *Sensors (Basel)*, 2023, vol. 23(8), 3943.

17. Leroux S., Bohez S., Verbelen T. et al. Resource-constrained classification using a cascade of neural network layers. In: International Joint Conference on Neural Networks (IJCNN), 2015, pp. 1–7, DOI: 10.1109/IJCNN.2015.7280601.

18. Leroux S., Verbelen T., Simoens P. et al. Iterative neural networks for adaptive inference on resource-constrained devices. *Neural Comput & Applic*, 2022, vol. 34, pp. 10321–10336. DOI: 10.1007/s00521-022-06910-5.

19. Oh J.W., Jeong J. Convolutional neural network and 2-D image based fault diagnosis of bearing without retraining. In: 3rd International Conference (ICDA 2019), 2019, pp. 134–138. DOI: 10.1145/3314545.3314563.

20. Wang S., Huang S., Wang Q. et al. Accelerated optimizations of an electromagnetic acoustic transducer with artificial neural networks as metamodels, *J. Sens. Sens. Syst.*, 6, 2017, pp. 269–28.

MUSSA G. BASHIROV – Doctor of Technical Sciences, Professor, Department of Electrical Equipment and Automation of Industrial Enterprises, Institute of Oil Refining and Petrochemistry, Ufa State Petroleum Technical University, Russia, Salavat (eapp@yandex.ru; ORCID: <https://orcid.org/0000-0001-7493-6803>).

DAMIR Sh. AKCHURIN – Post-Graduate Student, Assistant Lecturer, Department of Electrical Equipment and Automation of Industrial Enterprises, Institute of Oil Refining and Petrochemicals, Ufa State Petroleum Technical University, Russia, Salavat (akihiro177@mail.ru; ORCID: <https://orcid.org/0000-0002-2174-8216>).

KIRILL N. KUVAYTSEV – Master’s Program Student of the Direction «Automatization of Technological Processes and Productions», Institute of Oil Refining and Petrochemistry, Ufa State Petroleum Technical University, Russia, Salavat (kirill.kuvaitsev@mail.ru).

DMITRY E. MAKSIMOVICHKIN – Master’s Program Student of the Direction «Automatization of Technological Processes and Productions», Institute of Oil Refining and Petrochemistry, Ufa State Petroleum Technical University, Russia, Salavat (03maksimovichkin.de@bashgaz.ru).

Формат цитирования: *Баширов М.Г., Акчуринов Д.Ш., Кувайцев К.Н., Максимовичкин Д.Е.* Нейросетевая обработка электромагнитно-акустического сигнала для идентификации напряженно-деформированного состояния и поврежденности энергетического оборудования // Вестник Чувашского университета. – 2023. – № 4. – С. 44–56. DOI: 10.47026/1810-1909-2023-4-44-56.