

УДК 621.891:681.51.08

А. Н. Парфиевич, кандидат технических наук, доцент,**В. А. Сокол, Ю. Н. Саливончик**Учреждение образования «Брестский государственный технический университет»,
ул. Московская, 267, 224017 Брест, Республика Беларусь, +375 (162) 32 17 52, lstrector@bstu.by

НЕЙРОСЕТЕВОЙ ПОДХОД К КЛАССИФИКАЦИИ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЗУБЧАТЫХ ПЕРЕДАЧ В СОСТАВЕ МНОГОВАЛЬНЫХ ПРИВОДОВ НА ОСНОВЕ АНАЛИЗА АКУСТИЧЕСКОГО СИГНАЛА

В статье представлен нейросетевой подход к диагностике состояния зубчатых передач в составе много-вальных приводов на основе анализа акустического сигнала. Предложена комплексная система, объединяющая аппаратно-программный комплекс для регистрации и обработки акустических сигналов и многослойную нейронную сеть с элементами самоорганизующейся карты Кохонена для классификации состояний. В ходе экспериментов исследовались пять состояний зубчатого колеса: от эталонного до полного отсутствия зуба, включая промежуточные дефекты (25 % длины зуба отсутствует, 50 % длины зуба отсутствует, 75 % длины зуба отсутствует). Для каждого состояния проведено по 25 измерений, сформирован обучающий набор из 125 примеров с 60 диагностическими признаками, извлеченными из спектра сигнала. Признаки включают амплитуды низкочастотных составляющих, кратных частоте вращения валов, частот зацепления и их боковых полос. Сеть была обучена с использованием размеченных данных, а её архитектура позволила эффективно кластеризовать и классифицировать состояния. Экспериментальные результаты показали высокую общую точность классификации — 92,2 %. Наилучшие результаты достигнуты для промежуточных дефектов (100 %), несколько ниже — для эталонного состояния и полного отсутствия зуба. Выявлено, что недостаточная однородность обучающей выборки для крайних состояний влияет на точность. Работа демонстрирует эффективность применения нейронных сетей с самоорганизацией для автоматизации диагностики, повышения достоверности и оперативности выявления дефектов в сложных механических системах.

Ключевые слова: диагностика; зубчатые передачи; акустический сигнал; искусственная нейронная сеть; самоорганизующаяся карта; классификация.

Рис. 4. Табл. 2. Библиогр.: 12 назв.

A. N. Parfievich, PhD in Technical Sciences, Associate Professor,**V. A. Sokol, Yu. N. Salivonchik**Institution of Education “Brest State Technical University”, 267 Moskovskaya Str., 224017 Brest,
the Republic of Belarus, +375 (162) 32 17 52, lstrector@bstu.by

A NEURAL NETWORK APPROACH TO THE CLASSIFICATION OF THE TECHNICAL CONDITION OF GEAR TRANSMISSIONS IN MULTI-AXIS DRIVES BASED ON ACOUSTIC SIGNAL ANALYSIS

The article presents a neural network approach to diagnosing the condition of gear pairs within multi-shaft drives based on acoustic signal analysis. A comprehensive system is proposed, combining hardware and software for the registration and processing of acoustic signals with a multi-layer neural network featuring elements of a self-organizing Kohonen map for state classification. During the experiments, five states of the gear were investigated: from the benchmark condition to complete tooth loss, including intermediate defects (25 %, 50 % and 75 % of tooth length missing). For each state, 25 measurements were taken, creating a training set of 125 examples with 60 diagnostic features extracted from the signal spectrum. The features include amplitudes of low-frequency components, multiples of the shaft rotation frequency, engagement frequencies, and their sidebands. The network was trained using labeled data, and its architecture allowed for effective clustering and classification of states. Experimental results showed a high overall classification accuracy of 92.2 %. The best results were achieved for intermediate defects (100 %), while slightly lower accuracy was noted for the benchmark condition and complete tooth loss. It was found that insufficient homogeneity of the training sample for extreme states affects accuracy. This work demonstrates the effectiveness of using self-organizing neural networks for automating diagnostics, enhancing reliability, and improving the promptness of defect detection in complex mechanical systems.

Key words: diagnostics; gear transmissions; acoustic signal; artificial neural network; self-organizing map; classification.

Fig. 4. Table 2. Ref.: 12 titles.

Введение. Современные промышленные объекты, такие как станки, транспортные механизмы, подъёмно-транспортное оборудование и энергетические установки, всё чаще оснащаются сложными многовальными зубчатыми приводами, обеспечивающими передачу крутящего момента между различными исполнительными органами. Надёжная и бесперебойная работа таких систем напрямую зависит от технического состояния их ключевых элементов — зубчатых передач. Даже незначительные дефекты, такие как микротрещины, выкрашивание, износ или сколы зубьев, могут со временем прогрессировать, приводя к полному выходу из строя узла, остановке технологического процесса, повреждению сопряжённых деталей, значительным финансовым потерям и в ряде случаев аварийным ситуациям. В этой связи своевременная и достоверная диагностика технического состояния зубчатых передач приобретает особую актуальность как важнейший элемент систем технического обслуживания и предиктивной диагностики.

Традиционные методы диагностики, основанные на анализе вибрационных или акустических сигналов, зачастую требуют глубокой экспертной интерпретации, длительной обработки данных и высокой квалификации персонала, что делает их трудоёмкими, субъективными и малоприменимыми для автоматизации [1; 2]. Кроме того, в условиях многовальных приводов спектр сигнала становится чрезвычайно насыщенным и сложным, поскольку содержит частотные составляющие от нескольких пар зацеплений, валов и подшипников, что затрудняет выделение информативных признаков, однозначно указывающих на наличие и характер дефекта.

В последние годы всё большее распространение получают методы технической диагностики, основанные на применении искусственных нейронных сетей (далее — ИНС) [3—6]. Так, ИНС обладают способностью к обучению на примерах, самоорганизации и распознаванию образов, что позволяет им эффективно обрабатывать большие объёмы зашумленных данных, выявлять скрытые закономерности и классифицировать состояния оборудования с высокой точностью. Особый интерес представляют архитектуры с использованием самоорганизующихся карт (Self-Organizing Maps, SOM), предложенных Т. Кохоненом, которые не только классифицируют данные, но и визуализируют их структуру, формируя топологически корректные кластеры. В данной работе представлено исследование по разработке и внедрению нейросетевой системы для акустической диагностики многовальных зубчатых приводов, сочетающей аппаратно-программный комплекс для извлечения диагностических признаков и многослойную нейронную сеть с элементами Кохонена для классификации состояний.

Методология и методы исследования. Искусственная нейронная сеть представляет собой математическую, программную или аппаратную модель, имитирующую принципы функционирования биологических нейронных сетей мозга. Она состоит из большого числа взаимосвязанных вычислительных элементов — искусственных нейронов, которые обрабатывают информацию и передают её по синаптическим связям. Каждый нейрон получает входные сигналы, взвешивает их с помощью коэффициентов (весов), суммирует и передаёт результат через нелинейную активационную функцию, формируя выходной сигнал. Эта структура позволяет сети моделировать сложные нелинейные зависимости между входными и выходными данными, что делает ИНС мощным инструментом для решения задач, которые трудно формализовать традиционными алгоритмами.

Ключевые свойства ИНС: способность к обучению, самоорганизации, адаптации к изменениям окружающей среды и распознаванию зашумленных или неполных образов. Эти качества делают их идеальными кандидатами для решения задач классификации, распознавания образов, прогнозирования и аппроксимации функций, что особенно актуально в области технической диагностики, где требуется высокая устойчивость к помехам и вариативности условий эксплуатации [4].

Одним из наиболее распространённых подходов в задачах диагностики является обучение с учителем (supervised learning). В этом случае нейронная сеть обучается на размеченном наборе данных, где каждому входному вектору (например, набору амплитуд

частотных составляющих акустического сигнала) сопоставлен правильный ответ — класс, к которому он принадлежит (например, «норма», «скол 25 %», «отсутствие зуба»). В процессе обучения сеть корректирует свои весовые коэффициенты в целях минимизации ошибки между предсказанным и истинным выходами. После завершения обучения сеть способна обобщать полученные знания и классифицировать новые, ранее неизвестные данные.

Среди множества архитектур ИНС для решения поставленной задачи была выбрана многослойная сеть прямого распространения с одним скрытым слоем, где в качестве скрытого слоя использованы нейроны Кохонена. Этот выбор обусловлен необходимостью не только классифицировать состояния, но и выявить внутреннюю структуру данных, сгруппировать схожие признаки и снизить размерность входного пространства. Нейроны Кохонена являются основой самоорганизующихся карт [7]. В отличие от традиционных слоёв с фиксированными весами, нейроны Кохонена обучаются по конкурентному принципу: на каждом шаге только один нейрон — «победитель» — активируется и корректирует свои веса, приближаясь к входному вектору. Этот процесс позволяет сети формировать топологически корректное отображение входных данных, где близкие по значению векторы активируют соседние нейроны на карте. Такой подход особенно эффективен при анализе сложных многомерных данных, таких как акустические спектры, где требуется выделение кластеров, соответствующих определённым техническим состояниям [9—11].

Кроме того, нейронные сети обладают рядом достоинств по сравнению с классическими методами: высокая степень параллелизма обработки информации, способность к обобщению, устойчивость к шумам и частичной потере данных, а также возможность адаптации к изменяющимся условиям работы оборудования [8]. Учитывая эти преимущества, использование ИНС с элементами самоорганизации представляет собой перспективное направление для создания автоматизированных систем диагностики, способных работать в реальном времени и обеспечивать высокую достоверность результатов.


Результаты исследования и их обсуждение. В качестве объекта исследования был выбран горизонтальный редуктор с цилиндрическими прямозубыми колесами (рисунок 1). Для получения акустических данных использовался аппаратно-программный комплекс [1], который включал измерительный микрофон с капсулем M101. Сигналы с микрофона записывались и обрабатывались в реальном времени. Для точного определения частот вращения валов и частот, характерных составляющих сигнала, применялись преобразователи угловых перемещений.

На одном из колес редуктора моделировался локальный дефект — скол зуба (рисунок 2). Исследования проводились для пяти различных состояний:

- 1) зубчатое колесо без дефекта (эталон);
- 2) зубчатое колесо с локальным дефектом длиной 25 % от полной длины зуба;
- 3) зубчатое колесо с локальным дефектом длиной 50 % от полной длины зуба;
- 4) зубчатое колесо с локальным дефектом длиной 75 % от полной длины зуба;
- 5) зубчатое колесо с полным отсутствием зуба (дефект 100 %).

Для каждого состояния было проведено по 25 измерений, что позволило накопить достаточный объем экспериментальных данных (125 измерений). Результаты, полученные с эталонной шестерней, были приняты за базу сравнения.

Спектр анализируемого сигнала, полученный с помощью микрофона, представляет собой чрезвычайно насыщенную информационную структуру, содержащую множество частотных компонент, порожденных всеми элементами привода. Прямое ручное извлечение всех значимых характеристик практически невозможно из-за высокой сложности и объема данных.



а) — общий вид редуктора; б) — кинематическая схема редуктора

Рисунок 1. — Цилиндрический двухступенчатый редуктор:




Рисунок 2. — Общий вид исследуемой шестерни с локальным дефектом в виде скола зуба

На основе анализа литературных источников [2; 3; 11] была определена совокупность ключевых частотных составляющих, несущих информацию о состоянии зубчатой передачи (рисунок 3):

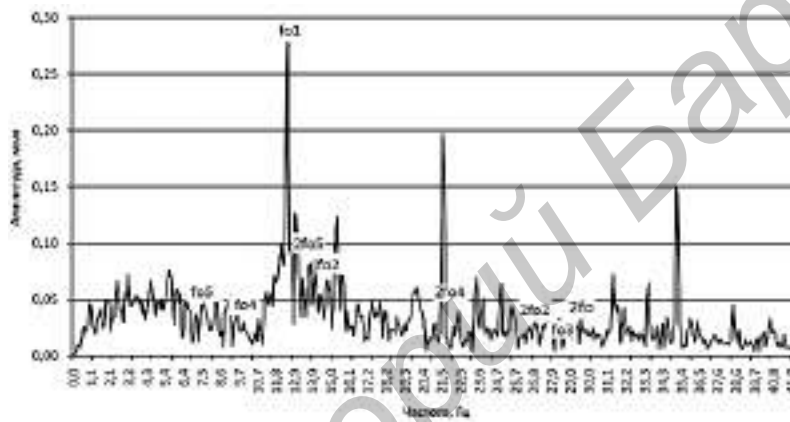
1) низкочастотные составляющие, кратные частоте вращения валов (f_0 , Гц). Эти спектральные компоненты соответствуют частотам, кратным частоте вращения валов ($f_0 = n / 60$, где n — частота вращения вала, мин⁻¹). Они возникают вследствие периодических сил, обусловленных вращением элементов многовального привода и циклическим характером передачи крутящего момента. Каждый раз, когда зуб шестерни проходит мимо зуба колеса, возникает небольшой импульс нагрузки, повторяющийся с частотой вращения вала. Эти циклические изменения вызывают модуляцию акустического сигнала, что проявляется в виде выраженных пиков на частотах f_0 , $2f_0$, $3f_0$ и т. д. в спектре сигнала. Амплитуда этих гармоник может возрастать в зависимости от дефектов зубчатых колес, поскольку любые геометрические или массовые неоднородности усиливают периодические колебания. Таким образом, анализ уровня и динамики изменения амплитуд низкочастотных составляющих позволяет выявлять макроскопические нарушения в работе привода и оценивать общее техническое состояние роторной системы, что делает их важным диагностическим признаком;

2) высокочастотные составляющие с частотами пересопряжения зубьев всех пар (f_z) и их кратными значениями. Частота пересопряжения (или частота зацепления) f_z определяется как произведение частоты вращения шестерни на число её зубьев ($f_z = f_0 z$, Гц). Это одна из наиболее информативных частот в спектре сигнала зубчатой передачи. Она соответствует частоте, с которой происходит контакт (вход в зацепление и выход из него) отдельных зубьев шестерни и колеса. При каждом таком контакте возникает ударный характерный импульс, генерирующий высокочастотные колебания в акустическом и вибрационном поле. В спектре эти процессы проявляются в виде доминирующих пиков на частоте f_z и её гармониках ($2f_z$, $3f_z$ и т. д.). Эти компоненты являются прямыми индикаторами механических взаимодействий в зацеплении и чрезвычайно чувствительны к изменениям в состоянии зубьев. При наличии дефектов, таких как сколы, выкрашивание, износ или трещины, амплитуда частоты зацепления и её гармоник существенно возрастают, а форма импульсов становится более сложной. Кроме того, появление дополнительной энергии на этих частотах может свидетельствовать о нарушении условий смазки, увеличении зазоров или потере жесткости в передаче. Таким образом, мониторинг амплитуд высокочастотных составляющих позволяет оперативно выявлять локальные повреждения и оценивать интенсивность износа зубчатого зацепления;

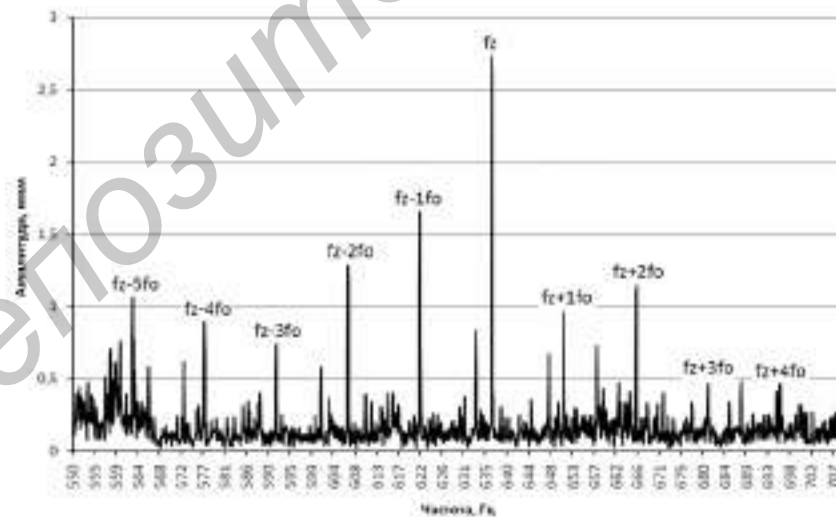
3) комбинированные (модулированные) частоты вида $lf_z \pm nf_0$, где l, n — целые числа, например: 1, 2, 3 и т. д. Эти частоты, часто называемые боковыми полосами, возникают в результате амплитудной и (или) фазовой модуляции сигнала зацепления. Модуляция происходит вследствие переменных контактных сил, вызванных нестационарными факторами, характерными для поврежденных или изношенных зубьев. Например, при наличии локального дефекта (такого как скол или трещина) каждый раз, когда поврежденный зуб входит в зацепление, происходит резкий скачок нагрузки, что приводит к кратковременному увеличению амплитуды сигнала зацепления. Этот процесс эквивалентен модуляции основной частоты зацепления f_z низкочастотным сигналом f_0 . В результате в спектре появляются дополнительные составляющие на частотах вида $f_z \pm f_0$, $f_z \pm 2f_0$, $2f_z \pm f_0$ и т. д. Наличие и рост амплитуды таких боковых полос является ярким признаком существования локального дефекта и считается одним из наиболее достоверных диагностических признаков. Анализ структуры боковых полос (их количества, ширины и амплитуды) позволяет не только обнаружить дефект, но и оценить его размер, локализацию и стадию развития. Особенно информативны такие составляющие при анализе сложных многовальных приводов, где традиционные методы могут быть недостаточно чувствительными. Таким образом, комбинированные частоты служат ключевым индикатором нестационарных процессов в зацеплении и играют решающую роль в ранней диагностике дефектов зубчатых передач.



а)



б)



в)

а — фрагмент спектра акустического сигнала многовального привода с разрешением спектра 524 000; б — фрагмент спектра акустического сигнала в области оборотных частот f_0 ; в — фрагмент исходного спектра в области частот $(f_z - kf_0) - (f_z + kf_0)$ шестерни $z_2 = 43$

Рисунок 3. — Результат обработки спектра акустического сигнала с помощью функции аппаратно-программного комплекса «Анализ гармоник»

Для автоматизации процесса извлечения этих параметров была разработана и реализована в программной части комплекса новая функция — «Анализ гармоник», которая автоматически выделяет и фиксирует амплитуды указанных выше частотных компонент, формируя набор диагностических признаков.

На основе извлеченных диагностических признаков был сформирован обучающий набор данных, включающий 60 параметров (амплитуд различных частотных компонент), полученных с помощью функции «Анализ гармоник» для каждого из 125 измерений. Данные были размечены по пяти классам, соответствующим пяти экспериментально моделируемым состояниям зубчатого колеса: зубчатое колесо без дефекта (эталон), зубчатое колесо с локальным дефектом длиной 25 % от полной длины зуба, зубчатое колесо с локальным дефектом длиной 50 % от полной длины зуба, зубчатое колесо с локальным дефектом длиной 75 % от полной длины зуба, зубчатое колесо с полным отсутствием зуба (дефект 100 %). Этот набор данных был разделен на обучающую и тестовую выборки в соотношении 4 : 1, что обеспечило адекватную оценку обобщающей способности модели.

Структура разработанной многослойной нейронной сети (рисунок 4) представляет собой классическую архитектуру прямого распространения сигнала и состоит из трех последовательных слоев. Входной слой формируется 60 нейронами, каждый из которых принимает на вход одну из амплитудных характеристик спектра, составляющих вектор признаков. Этот вектор подвергается предварительной нормализации в диапазоне [0, 1] для устранения влияния масштаба и ускорения процесса сходимости обучения.

Скрытый слой реализован в виде самоорганизующейся карты Кохонена, содержащей 30 нейронов. В отличие от слоев в традиционных сетях, нейроны в карте Кохонена обучаются по принципу конкурентного обучения (winner-take-all). При подаче входного вектора на каждом шаге вычисляются Евклидовы расстояния между ним и весовыми векторами всех 30 нейронов. Нейрон с минимальным расстоянием объявляется «победителем». Только его весовые коэффициенты обновляются по правилу $\omega_{ci}(t+1) = \omega_{ci}(t) + \alpha(X_i - \omega_{ci}(t))$, где α — коэффициент скорости обучения, постепенно уменьшающийся во времени, а X_i — компонента входного вектора. Этот процесс позволяет карте Кохонена кластеризовать входные данные, формируя топологически корректное представление, где близкие по признакам состояния активируют соседние нейроны на двумерной карте. Это свойство особенно ценно для визуализации структуры данных и выявления закономерностей.




Рисунок 4. — Структура нейронной сети

Выходной слой состоит из пяти нейронов, каждый из которых соответствует одному из классов состояния шестерни. Связи между скрытым и выходным слоями настраиваются в процессе обучения, сопоставляя кластеры на карте Кохонена с конкретными классами. После завершения обучения на выходе сети активируется только один нейрон, соответствующий наиболее вероятному классу, что обеспечивает четкую интерпретацию результата. Обучение сети продолжалось до достижения стабильной карты кластеров и минимальной ошибки классификации на обучающей выборке.

Обучение сети продолжалось до достижения желаемой степени согласованности между входными данными и весовыми векторами. Общая средняя квадратичная ошибка обучения составила 0,00533, что свидетельствует о достаточно высокой степени адаптации сети к данным.

После завершения обучения нейронная сеть была протестирована на независимом тестовом наборе данных. Полученные результаты представлены в таблице 1.

Общая точность классификации составила 92,2 %. Анализ результатов показывает, что сеть отлично справляется с распознаванием состояний с умеренными дефектами (25, 50, 75 %) и эталонного состояния. Однако точность распознавания самого экстремального состояния — отсутствия зуба — оказалась значительно ниже (72,7 %).

Более детальный анализ процесса обучения (таблица 2) выявил причину этого недостатка. В ходе обучения сеть не смогла корректно научиться классифицировать образы из пятого класса, хотя на тестовом наборе она показала более высокую точность (93,3 %). Это указывает на то, что обучающая выборка для этого класса была недостаточной или неоднородной, что привело к тому, что сеть не смогла сформировать надежный кластер для данного типа дефекта [5; 10—12].

Заключение. В ходе проведенного исследования была разработана и экспериментально апробирована нейросетевая система акустической диагностики состояния зубчатых передач в многовальных приводах. Предложенный подход, сочетающий использование специализированного аппаратно-программного комплекса для извлечения диагностических признаков и многослойной нейронной сети с применением элементов самоорганизующихся карт Кохонена для классификации, показал высокую эффективность. Общая точность распознавания состояний шестерни составила 92,2 %, что подтверждает работоспособность и перспективность метода.

Т а б л и ц а 1. — Результаты решения задачи классификации, %

Зубчатое колесо без дефекта (эталон)	Зубчатое колесо с локальным дефектом длиной 25 % от полной длины зуба	Зубчатое колесо с локальным дефектом длиной 50 % от полной длины зуба	Зубчатое колесо с локальным дефектом длиной 75 % от полной длины зуба	Зубчатое колесо с полным отсутствием зуба (дефект 100 %)
88,9	100,0	100,0	100,0	72,7

Т а б л и ц а 2. — Результаты обучения нейросетевого классификатора, %

Зубчатое колесо без дефекта (эталон)	Зубчатое колесо с локальным дефектом длиной 25 % от полной длины зуба	Зубчатое колесо с локальным дефектом длиной 50 % от полной длины зуба	Зубчатое колесо с локальным дефектом длиной 75 % от полной длины зуба	Зубчатое колесо с полным отсутствием зуба (дефект 100 %)
20,0	20,0	20,0	20,0	18,7

Полученные результаты демонстрируют, что ИНС, в особенности архитектуры с элементами самоорганизации, являются мощным инструментом для автоматизации процесса диагностики и способны значительно повысить достоверность и оперативность выявления дефектов по акустическим сигналам. Наиболее выраженный результат достигнут при распознавании промежуточных стадий повреждения (от 25 до 75 %), тогда как для крайнего состояния (полное отсутствие зуба) точность оказалась ниже, что указывает на необходимость расширения обучающей выборки и её тщательной балансировки.

Таким образом, разработанная система представляет собой перспективное решение для создания автоматизированных систем мониторинга технического состояния сложных механических приводов, способных работать в реальном времени и снижать риск аварийных ситуаций. Дальнейшие исследования будут направлены на совершенствование алгоритмов извлечения признаков, включая применение методов глубокого обучения, и на адаптацию системы для диагностики других типов дефектов и более сложных кинематических схем.

Список цитируемых источников

1. Новые аппаратно-программные средства для исследования и диагностики механических систем / А. В. Драган, И. П. Стецко, Д. А. Ромашко, Н. В. Левкович // Вестник Брестского государственного технического университета. — 2006. — № 4. — С. 17—26.
2. Барков, А. В. Мониторинг и диагностика роторных машин по вибрации / А. В. Барков, Н. А. Баркова, А. Ю. Азовцев. — URL: <http://www.vibrotek.com/russian/articles/book/index.htm> (дата обращения: 01.04.2025).
3. Diagnosing Gear Transmission Using a New Condition Monitoring Method for Rotating Equipment / Anil Jacob, Dr. Y. I. Sharaf-Eldeen. — URL: http://www.vibration.ru/d_zub_peredach.shtml (date of access: 01.04.2025).
4. Головкин, В. А. Нейронные сети: обучение, организация, применение / В. А. Головкин // Нейрокомпьютеры и их применение : учеб. пособие. — М., 2001. — 256 с.
5. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. — М. : Вильямс, 2006. — 1104 с.
6. Chen, J. Deep Learning-Based Fault Diagnosis of Gearboxes Using Acoustic Signals / J. Chen, Z. Wang, Q. Zhao // Sensors. — 2021. — Vol. 21, no. 10. — P. 3456. — DOI: 10.3390/s21103456.
7. Kohonen, T. Self-organized formation of topologically correct feature maps / T. Kohonen // Biological Cybernetics. — 1982. — Vol. 43, no. 1. — P. 59—69.
8. Haykin, S. Neural Networks and Learning Machines / S. Haykin; 3rd ed. — Pearson Education, 2014. — 1080 p.
9. Gao, R. X. Wavelet Theory and Its Applications for Machinery Condition Monitoring / R. X. Gao, R. Yan. — Springer, 2015. — 342 с.
10. Zhang, X. Application of Artificial Neural Networks in Gearbox Fault Diagnosis: A Review / X. Zhang, B. Li, H. Liu // Journal of Mechanical Engineering and Sciences. — 2020. — Vol. 14, no. 1. — P. 4567—4583. — DOI: 10.15282/jmes.14.1.2020.01.0485.
11. Lu, Y. A Hybrid Method of Feature Extraction and Classification for Gear Fault Detection Using Neural Networks / Y. Lu, W. Yang // International Journal of Advanced Manufacturing Technology. — 2019. — Vol. 104, no. 5—8. — P. 1897—1909. — DOI: 10.1007/s00170-019-03744-6.
12. Sun, Y. Research on the Application of SOM in Mechanical Fault Diagnosis / Y. Sun, M. Xu, L. Wang // Proceedings of the 2017 International Conference on Intelligent Manufacturing Systems. — IEEE, 2017. — P. 112—116. — DOI: 10.1109/ICIMS.2017.8081245.

Поступила в редакцию 06.10.2025.