

Диагностика неисправностей редукторов горных машин на основе непрерывного вейвлет-преобразования и машинного обучения

Ю. Н. Кожубаев, В. Н. Хохловский, М. П. Королев✉, Р. В. Ершов, С. Э. Сараджишвили

Санкт-Петербургский государственный политехнический университет, Санкт-Петербург, Россия

✉ korolev.mp@edu.spbstu.ru

Аннотация. В условиях ускоряющегося процесса интеллектуализации и автоматизации угольных шахт значение редукторов в горнодобывающей промышленности неоспоримо. Стабильность их рабочего состояния напрямую связана с безопасностью и эффективностью добычи угля. Однако, учитывая их широкое распространение в промышленности, редукторы в большей степени, чем двигатели, подвержены поломкам в течение длительного периода эксплуатации. Если такие отказы не обнаружить и не устранить своевременно, они могут привести к повреждению горного оборудования, тем самым оказывая пагубное влияние на процесс добычи угля в целом. Поэтому возможность прогнозирования неисправностей редукторов в реальном времени имеет огромное практическое значение. Использование различных методов диагностики различных механизмов, включающих анализ вибрационных сигналов, находит все большее применение и развитие в промышленных условиях. В данной статье исследуется потенциал непрерывного вейвлет-преобразования (CWT) как метода обнаружения неисправностей в редукторах, которые являются важнейшими компонентами электромеханических систем горных машин.

Ключевые слова: вейвлет-преобразования, диагностика неисправностей, редуктор

Для цитирования: Диагностика неисправностей редукторов горных машин на основе непрерывного вейвлет-преобразования и машинного обучения / Ю. Н. Кожубаев, В. Н. Хохловский, М. П. Королев, Р. В. Ершов, С. Э. Сараджишвили // Изв. СПбГЭТУ «ЛЭТИ». 2026. Т. 19, № 3. С. 52–63. doi: 10.32603/2071-8985-2026-19-3-52-63.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Original article

Fault Diagnosis of Mining Machine Gearboxes Based on Continuous Wavelet Transform and Machine Learning

Yu. N. Kozhubaev, V. N. Khokhlovsky, M. P. Korolev✉, R. V. Ershov, S. E. Sarajishvili

Saint Petersburg State Polytechnical University, St Petersburg, Russia

✉ korolev.mp@edu.spbstu.ru

Abstract. In the context of the accelerating process of digitalization and automation of coal mines, the role of gearboxes in the mining industry is undeniable. The stability of their operational condition is directly related to the safety and efficiency of coal production. However, considering their widespread industrial use, gearboxes are more prone to failures over long periods of operation than electric motors. If such faults are not detected and corrected in time, they can lead to damage to mining equipment, thereby having a detrimental effect on the overall coal extraction process. Therefore, the ability to predict gearbox faults in real time is of great practical importance. The application of various diagnostic methods for mechanical systems, including vibration sig-

nal analysis, is increasingly used and developed in industrial environments. This paper explores the potential of the Continuous Wavelet Transform (CWT) as a method for detecting faults in gearboxes, which are critical components of the electromechanical systems of mining machines.

Keywords: wavelet transform, fault diagnosis, gearbox

For citation: Fault Diagnosis of Mining Machine Gearboxes Based on Continuous Wavelet Transform and Machine Learning / Yu. N. Kozhubaev, V. N. Khokhlovsky, M. P. Korolev, R. V. Ershov, S. E. Sarajishvili // LETI Transactions on Electrical Engineering & Computer Science. 2026. Vol. 19, no. 3. P. 52–63. doi: 10.32603/2071-8985-2026-19-3-52-63.

Conflict of interests. The authors declare no conflicts of interests.

Появление технологий искусственного интеллекта привело к разработке методов диагностики неисправностей на основе глубокого обучения и машинного обучения, которые нашли применение во многих областях [1]–[3]. Для обработки последовательных данных в задаче прогнозирования состояния редукторов предлагается исследовать модель глубокого обучения с комбинированной долгосрочной и краткосрочной памятью. Предлагается исследовать модель глубокой нейронной сети с морфологическим конволюционным самокодированием, которая может быть эффективно использована для извлечения и распознавания информации о неисправностях редукторов. Исследуется усовершенствованная методология диагностики неисправностей коробки передач трансформатора, которая улучшает способность обработки информации о локальных признаках посредством введения многомасштабного перцептивного слоя и слоя линейного встраивания, которые могут анализировать признаки неисправности на нескольких временных масштабах и сохранять позиционную информацию исходных сигналов. Однако следует отметить, что входные данные этих моделей глубокого обучения ограничены одномерными сигналами [4], что означает, что весь потенциал глубокого обучения для распознавания образов не используется.

Для решения этих проблем в данной работе используется непрерывное вейвлет-преобразование (CWT) для преобразования сигналов вибрации редукторов, полученных с помощью датчиков, в частотно-временные карты, что позволяет выявить скрытые признаки неисправностей. По сравнению с обычным спектральным анализом, который способен отображать только общие частотные компоненты, график временных рядов дает четкое представление о точном моменте отказа и соответствующем диапазоне частот. Следовательно, даже незначительные начальные неисправности могут быть эффективно обнаружены

по локальным энергетическим аномалиям, обеспечивая визуальную основу для быстрой идентификации типа неисправности.

Что касается распознавания образов, то сверточная нейронная сеть (CNN) оказалась особенно эффективной при обработке двумерных данных – таких, как временно-частотные диаграммы. Она автоматически извлекает пространственные признаки на частотно-временной диаграмме вибрационных сигналов с помощью многослойного конволюционного ядра, выполняет уменьшение размерности признаков и подавление шума с помощью объединяющего слоя и, наконец, завершает классификацию неисправностей с помощью полностью связанного слоя. Модель сетей с долгой краткосрочной памятью (LSTM) была разработана для решения проблемы долгосрочной зависимости, присутствующей в данных временных рядов. Эта модель эффективно отражает временные характеристики вибрационных сигналов и демонстрирует повышенную устойчивость к шумовым помехам и усечению сигнала.

В данной статье предлагается модель CWT-CNN-LSTM для решения проблемы диагностики неисправностей коробки передач. Используя по данным вибромониторинга 10 типичных условий работы редукторов, исходные сигналы во временной области преобразуются в частотно-временные карты с использованием CWT в качестве входных данных модели. Затем с помощью CNN из частотно-временных карт извлекаются пространственно-чувствительные признаки. Последующее использование слоя объединения пространственных пирамид облегчает объединение признаков, и, наконец, закон динамической эволюции признаков разлома во временно-частотном измерении фиксируется с помощью LSTM.

Непрерывное вейвлет-преобразование (CWT). CWT – это эффективный метод [5], [6] извлечения информации о частотно-временных сигналах при помощи многомасштабного анализа

функций или сигналов с помощью операций масштабирования и трансляции. В данном исследовании для построения модели отображения временной частоты используется улучшенная сложная вейвлет-функция Морлета с учетом нестационарных характеристик сигнала вибрации трансмиссии. Собранный сигнал виброускорения разлагается на несколько масштабов с помощью адаптивного алгоритма согласования масштабного параметра и центральной частоты, а его непрерывное вейвлет-преобразование имеет вид

$$X_w(u, v) = \int_{-\infty}^{+\infty} x(t) \varphi_{u,v}(t) dt = \\ = \frac{1}{\sqrt{v}} \int_{-\infty}^{+\infty} x(t) \varphi\left(\frac{t-v}{u}\right) dt,$$

где u – коэффициент трансляции; v – коэффициент масштабирования; t – независимая переменная времени; $x(t)$ – анализируемый сигнал виброускорения редуктора во временной области; $\varphi_{u,v}(t)$ называется вейвлет-базисной функцией, и ее выражение выглядит следующим образом:

$$\varphi_{u,v}(t) = \frac{1}{\sqrt{|u|}} \varphi\left(\frac{t-v}{u}\right).$$

Выбор вейвлет-базисной функции играет решающую роль при выполнении непрерывного вейвлет-преобразования. При ее определении важно, чтобы форма волны базисной функции соответствовала характерным особенностям исследуемого сигнала неисправности. В данной статье в качестве базисной функции непрерывного вейвлет-преобразования использована функция Морле [1].

Применение подходящей вейвлет-базисной функции повышает эффективность преобразования: в процессе анализа базисная функция и вибрационный сигнал редуктора усиливаются схожим образом, что способствует подавлению различий и выделению значимых компонентов. Среди вейвлетных базисных функций комплексная вейвлетная базисная функция Морле и сигнал вибрации демонстрируют наивысшую степень сходства. Следовательно, в данной статье комплексная вейвлетная базисная функция Морле используется в качестве вейвлет-преобразования базисной функции.

Количество точек выборки установлено на 1024 для десяти условий эксплуатации, и для каждого условия эксплуатации собрано 1000 графиков временных частот с использованием метода SWT, описанного ранее.

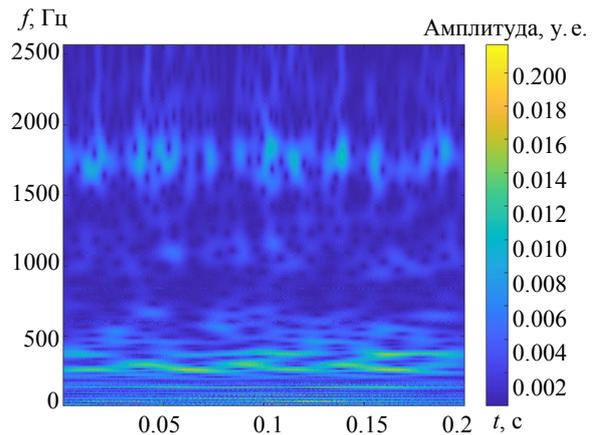


Рис. 1. Состояние трещины шестерни
Fig. 1. Condition of the gear crack

Как видно из рис. 1, в интервале от 0 до 0.2 с отмечаются выраженные области концентрации энергии сигнала в диапазонах частот 0...500 Гц и 1000...2000 Гц. В низкочастотной области (0...500 Гц) распределение энергии отличается стабильностью, что указывает на наличие устойчивых низкочастотных периодических компонентов. Такие компоненты могут быть связаны как с нормальными вибрациями, возникающими при рабочей частоте шестерни, так и с проявлением дефектов в виде трещин.

В отличие от этого, в высокочастотном диапазоне (1000...2000 Гц) наблюдается более сложная структура распределения энергии, характеризующаяся множественными переходными импульсами. Подобные импульсы, вероятнее всего, обусловлены появлением трещин в зубьях шестерни. Особый интерес представляет временной участок 0.05...0.15 с, где сигнал демонстрирует ряд высокочастотных пиков, что может указывать на переходные процессы, вызванные повреждениями поверхности.

Кроме того, вблизи отметки 0.1 с фиксируется значительное изменение энергетического распределения, что может свидетельствовать о развитии или усилении дефекта. Совокупность наблюдаемых признаков позволяет предположить наличие трещины в шестерне [7]. Для подтверждения данной гипотезы рекомендуется провести дополнительный анализ с учетом эксплуатационных параметров и исторических данных, что позволит своевременно выявить и устранить потенциальную неисправность.

В исправном состоянии (рис. 2) наблюдается равномерное распределение энергии сигнала без выраженных высокочастотных компонентов или пиков мощности. Это свидетельствует о стабильности частотного спектра при нормальной работе

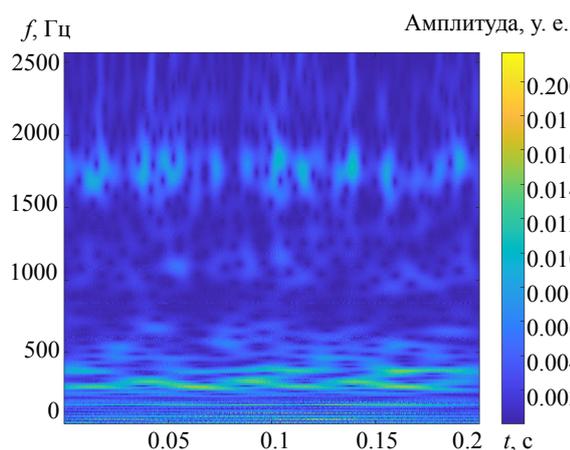


Рис. 2. Нормальное состояние
Fig. 2. Normal condition

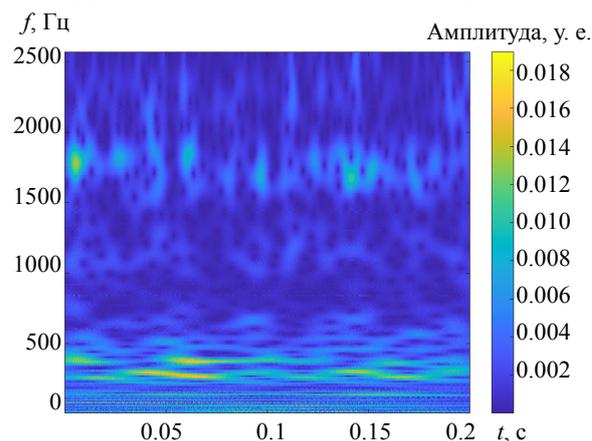


Рис. 4. Состояние трещины корневой части шестерни
Fig. 4. Condition of the crack in the root part of the gear

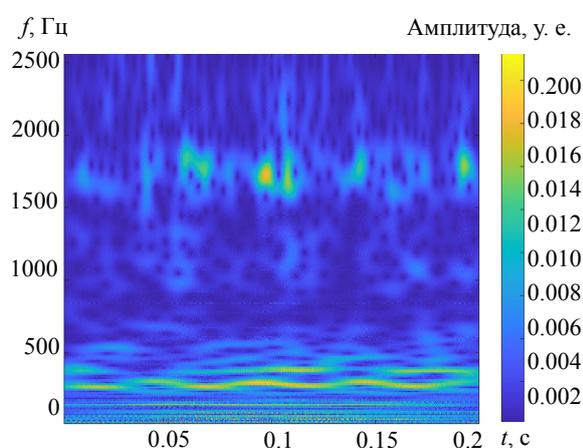


Рис. 3. Состояние сломанного зуба
Fig. 3. Condition of a broken tooth

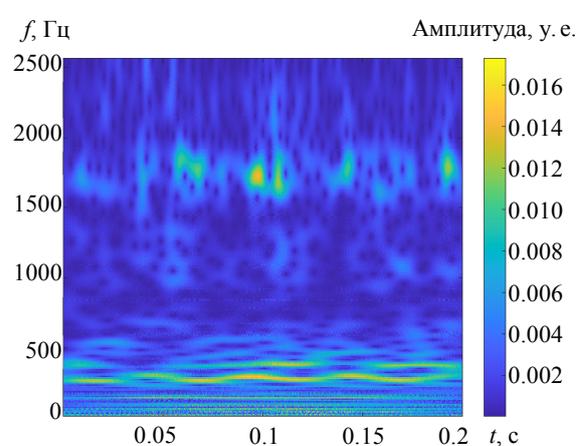


Рис. 5. Состояние износа поверхности зуба
Fig. 5. Condition of tooth surface wear

шестерни и об отсутствии переходных ударных импульсов, характерных для возникновения трещин или других дефектов.

Как показано на рис. 3, в высокочастотном диапазоне 1000...2500 Гц наблюдается более сложное распределение энергии сигнала, включающее несколько выраженных высокочастотных компонентов. Эти компоненты представляют собой переходные импульсы, возникающие при динамических изменениях в работе механизма. Особенно заметны энергетические пики в интервале времени от 0.05 до 0.15 с, что может указывать на переходные процессы, связанные с отсутствием или повреждением зубьев шестерни. Около отметки 0.1 с распределение энергии претерпевает значительные изменения, при этом в высокочастотной области пики становятся более выраженными, что подтверждает наличие нестабильностей в вибрационном сигнале.

Из рис. 4 видно, что в случае коробки передач при отсутствии зубчатых колес энергия сигнала в основном сосредоточена в низкочастотном диапа-

зоне от 0 до 500 Гц, а распределение энергии неравномерно. В высокочастотном диапазоне от 1000 до 2500 Гц распределение энергии сигнала более сложное, и в нем присутствует несколько высокочастотных составляющих.

Как видно из рис. 5, в интервале времени от 0 до 0.2 с основная часть энергии сигнала сосредоточена в низкочастотной области 0...500 Гц, где распределение энергии остается относительно равномерным. В то же время в высокочастотном диапазоне 1000...2500 Гц наблюдается более сложная структура распределения с наличием нескольких высокочастотных компонентов. Эти компоненты, вероятно, представляют собой переходные импульсы, возникающие вследствие износа рабочих поверхностей зубьев шестерни.

Модель сверточной нейронной сети (CNN). CNN – это архитектура глубокого обучения [8], основанная на иерархическом обучении признаков. На входной слой сети поступает нормализо-

ванный трехмерный тензор (высота \times ширина \times количество каналов), который пропускается через набор обучаемых конволюционных ядер для локального выделения признаков. Каждое конволюционное ядро выполняет операции интеркорреляции методом скользящего окна в пространственном измерении для создания соответствующей карты признаков. Слой пулинга выполняет сжатие пространственных размеров, агрегируя признаки в локальных областях. Это позволяет повысить устойчивость модели к небольшим деформациям входных данных при сохранении наиболее значимых характеристик. По мере увеличения глубины нейронной сети количество каналов карты признаков возрастает, тогда как пространственное разрешение последовательно уменьшается. В выходном слое применяется функция Softmax, обеспечивающая вычисление распределения вероятностей по категориям. Оптимизация параметров сети осуществляется минимизацией функции потерь кросс-энтропии в процессе обратного распространения. Структурная схема модели представлена на рис. 6.

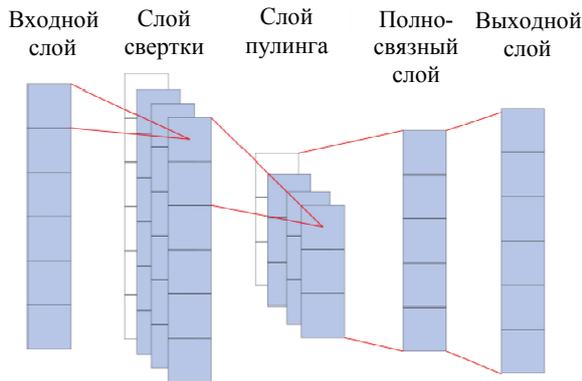


Рис. 6. Схема структуры сети CNN
Fig. 6. Diagram of the CNN network structure

CNN представляет собой модель машинного обучения, способную выявлять зависимости между входными данными и выходными результатами в процессе обучения. Регулируя внутренние веса в соответствии с входными сигналами, сеть стремится минимизировать ошибку и обеспечить корректные выходные значения.

В задаче диагностики неисправностей редуктора CNN использует в качестве входных данных частотно-временные карты, полученные в результате вейвлет-преобразования вибрационных сигналов, и выполняет классификацию состояния механизма на основе выделенных признаков.

Во входном слое сети выполняется подготовка данных – репликация, усреднение и нормали-

зация. Извлечение признаков осуществляется в сверточных слоях посредством операции свертки, после чего результаты проходят через слой объединения (пулинга), снижающий размерность и выделяющий наиболее информативные характеристики. Финальная классификация выполняется с помощью полносвязного слоя.

Функция потерь служит для оценки расхождения между предсказанным результатом модели $f(x)$ и истинной меткой y . Она определяет направление корректировки весов, способствуя уменьшению ошибки и улучшению точности прогнозирования. При приближении значения функции потерь к нулю точность и достоверность модели возрастают.

Выбор оптимальной функции потерь – ключевой фактор при обучении CNN, поскольку для различных типов задач требуются разные функции, обеспечивающие наиболее эффективное управление процессом оптимизации. Выражение функции потерь перекрестной энтропии выглядит следующим образом:

$$L(y, f(x)) = -\frac{1}{n} \sum_{i=1}^n [-m(i) \lg(w(i))].$$

Здесь n обозначает количество выборок признаков, $m(i)$ – истинную метку выборки, а $w(i)$ – прогнозируемую моделью вероятность.

Функция потерь на основе перекрестной энтропии используется для оптимизации процесса обучения в моделях глубокого обучения, благодаря адаптивной регуливке скорости обучения. Если предсказание значительно отличается от фактической метки, градиенты становятся большими, что ускоряет обучение модели. Напротив, когда прогноз близок к истинному значению, значение градиента уменьшается, что позволяет сети тонко настраивать параметры и повышать точность. Такой механизм обеспечивает баланс между скоростью сходимости и устойчивостью модели в процессе обучения.

Выражение функции потерь по среднеквадратичным ошибкам выглядит как

$$L(y, f(x)) = \frac{\sum_{i=1}^n (y_i - f(x_i))^2}{n}.$$

Функция потерь в средних квадратах – это широко используемый метод в глубоком обучении. Он количественно оценивает общую ошибку между прогнозируемым значением модели и фактическим значением и очень чувствителен к вы-

бросам. Для поддержания численной стабильности перед выходным слоем модели обычно вводится функция активации, ограничивающая диапазон выходного значения.

На этапе обучения модели параметры корректируются на основе градиентной обратной связи от функции потерь, с целью минимизации ее значения. Этот процесс реализуется с помощью метода градиентного спуска или его модифицированных вариантов. В ходе обучения сеть постепенно адаптируется, улучшая соответствие прогнозов обучающим данным, снижая ошибку предсказания и повышая способность модели к обобщению, что обеспечивает ее устойчивость и точность при работе с новыми входными данными.

Модель с долгой краткосрочной памятью (LSTM). Рекуррентные нейронные сети (RNN) – это класс архитектур глубокого обучения, предназначенных для моделирования временных данных, основной особенностью которых служит эффективное отражение динамических зависимостей последовательности посредством временной рекурсивной передачи скрытых состояний. В отличие от традиционных нейронных сетей с прямолинейным движением, RNN обмениваются параметрами во временном измерении через рекуррентную структуру связей (как показано на рис. 8), что имеет неотъемлемое преимущество при работе с последовательностями переменной длины. На рис. 7 показана структурная схема RNN сети, h_i обозначает скрытое состояние сети на i -м временном шаге.

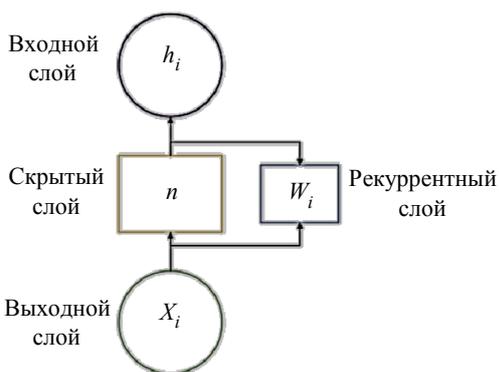


Рис. 7. Структурная схема нейронной сети RNN
Fig. 7. Structural diagram of the RNN neural network

В RNN входная последовательность представляется набором временных шагов $[X_0, X_1, \dots, X_t]$, где данные каждого шага зависят не только от текущего входного значения, но и от состояния скрытого слоя, сформированного на предыдущем шаге. Матрица весов определяет силу связей между нейронами скрытого и выходного слоев.

Во время обработки данных на каждом временном шаге RNN одновременно учитывает текущее значение входного сигнала и накопленную информацию из предыдущих состояний. Такая архитектура позволяет сети динамически обновлять внутреннее состояние и передавать информацию по временной оси, что обеспечивает способность моделировать временные зависимости.

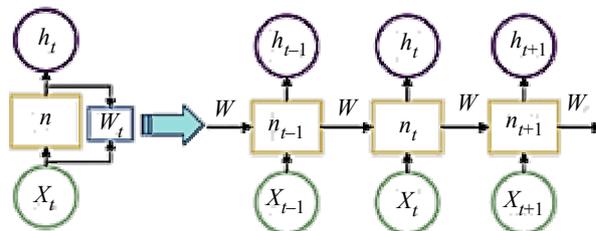


Рис. 8. Схема структуры рекуррентной сети РНС
Fig. 8. Diagram of the structure of the recurrent neural network

Благодаря этому механизму RNN особенно эффективна при анализе временных последовательностей и сигналов, зависящих от контекста во времени. Как показано на рис. 9, структура сети демонстрирует наличие циклических связей, обеспечивающих обработку данных с учетом временной последовательности.

RNN хорошо подходят для задач прогнозирования временных рядов, однако их простая архитектура не накладывает строгих ограничений на входные и выходные данные. Такая гибкость может приводить к тому, что RNN не способны автоматически фильтровать или оптимизировать поступающую информацию, что в отдельных случаях вызывает увеличение ошибок прогноза. Поэтому при использовании RNN требуется проведение дополнительной предварительной обработки данных – таких как отбор признаков, нормализация и сглаживание – для повышения точности и устойчивости модели.

Модель LSTM была разработана для решения проблемы долгосрочных зависимостей, характерной для классических RNN при анализе протяженных временных последовательностей [8]. Она эффективно устраняет проблемы исчезающего и взрывающегося градиента, возникающие при обучении стандартных RNN, благодаря введению специальной структуры ворот – входных, забывания и выходных.

Следует отметить, что LSTM – это разновидность RNN, и сохраняет ее базовую цепочечную архитектуру, состоящую из повторяющихся модулей нейронной сети. Такая структура позволяет как RNN, так и LSTM обрабатывать последова-

тельности произвольной длины и улавливать сложные временные зависимости между элементами данных. Схема структуры сети LSTM представлена на рис. 9.

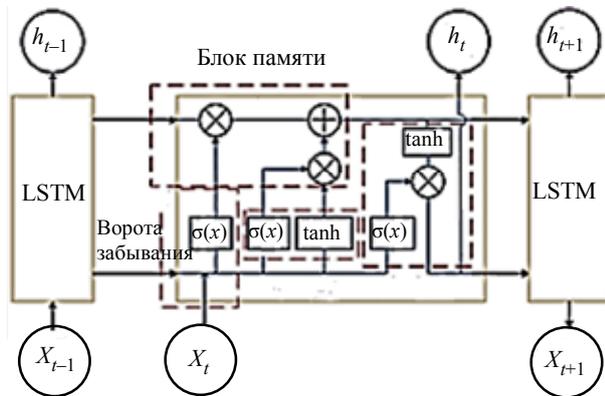


Рис. 9. Схема структуры рекуррентной сети LSTM
Fig. 9. Diagram of the structure of an LSTM recurrent network

Основная структура LSTM содержит три блока стробирования (Oblivion Gate, Input Gate, Output Gate) и состояние ячейки. Среди них ворота забывания генерируют коэффициенты забывания между 0 и 1 с помощью сигмоидальной функции

$$f_t = \sigma(W_f [h_{t-1}, x_t] + \mathbf{b}_f),$$

где f_t – значение уровня удержания; h_{t-1} – выход предыдущего момента; x_t – вход текущего момента; W_f – вес входных ворот; \mathbf{b}_f – вектор смещения; $\sigma(x)$ – сигмоидальная функция.

Входной гейт управляет обновлением памяти с помощью двухступенчатого механизма отбора информации: сначала слой сигмоидальных функций присваивает веса текущему входу и историческому состоянию, чтобы отсеять ключевую информацию, которая нуждается в обновлении; затем слой функций \tanh генерирует новые признаки-кандидаты для моделирования потенциальных паттернов, которые должны быть помещены в банк памяти. Эти две функции работают согласованно, пропорционально объединяя отобранные новые признаки с исторической памятью, тем самым динамически регулируя содержание обновлений в состоянии ячейки:

$$i_t = \sigma(W_i [h_{t-1}, x_t] + \mathbf{b}_i),$$

где i_t – значение степени, добавленное в текущий момент; h_{t-1} – выход предыдущего момента; x_t – вход текущего момента; W_i – вес ворот забывания; \mathbf{b}_i – вектор смещения.

Избирательное запоминание и обновление временных характеристик достигается благодаря механизму тонкой настройки Cell State. Суть заключается в двойном отборе информации входными воротами: сначала на основе совместных особенностей текущего входа и исторического скрытого состояния генерируются весовые коэффициенты с помощью сигмоидальной функции для количественной оценки силы обновления новой информации; в то же время, функция \tanh используется для генерирования векторов признаков-кандидатов. В конечном итоге входной шлюз поэлементно перемножает весовые коэффициенты с признаками кандидатов и пропорционально объединяет их в состояние ячейки, а шлюз забывания параллельно регулирует степень сохранения исторической информации:

$$c_t = f c_{t-1} + i_t \hat{c}_t,$$

где c_t – текущее состояние; \hat{c}_t – текущая ячейка памяти; c_{t-1} – состояние памяти в предыдущий момент.

Выходной гейт генерирует весовой вектор в интервале $[0, 1]$ с помощью сигмоидальной функции для количественной оценки степени вклада различной размерной информации в состоянии ячейки в текущий выход; в то же время состояние ячейки нормируется к диапазону $[-1, 1]$ с помощью функции \tanh для устранения потенциальных градиентных аномалий. В итоге эти две функции путем поэлементного перемножения генерируют скрытое состояние текущего временного шага, которое служит как выходом сети, так и носителем временной памяти для следующего временного шага.

$$h_t = \tanh \left\{ \sigma(W_o [h_{t-1}, x_t] + \mathbf{b}_o) \right\},$$

где W_o – вес выходных ворот; h_t – выход; \tanh – гиперболическая касательная функция; \mathbf{b}_o – вектор смещения.

Модели CNN-LSTM. Для того чтобы лучше объединить преимущества сетей CNN и LSTM, в данной работе предлагается гибридная нейросетевая модель CNN-LSTM [9], [10]. Эффективность глубоких нейросетевых архитектур при анализе и интерпретации изображений и высоко-размерных признаков подробно рассмотрена в обзорных работах, посвященных методам глубокого обучения [11]. Во-первых, CNN используется для обработки пространственных корреляционных характеристик данных, а пространственные характеристики извлекаются из временно-

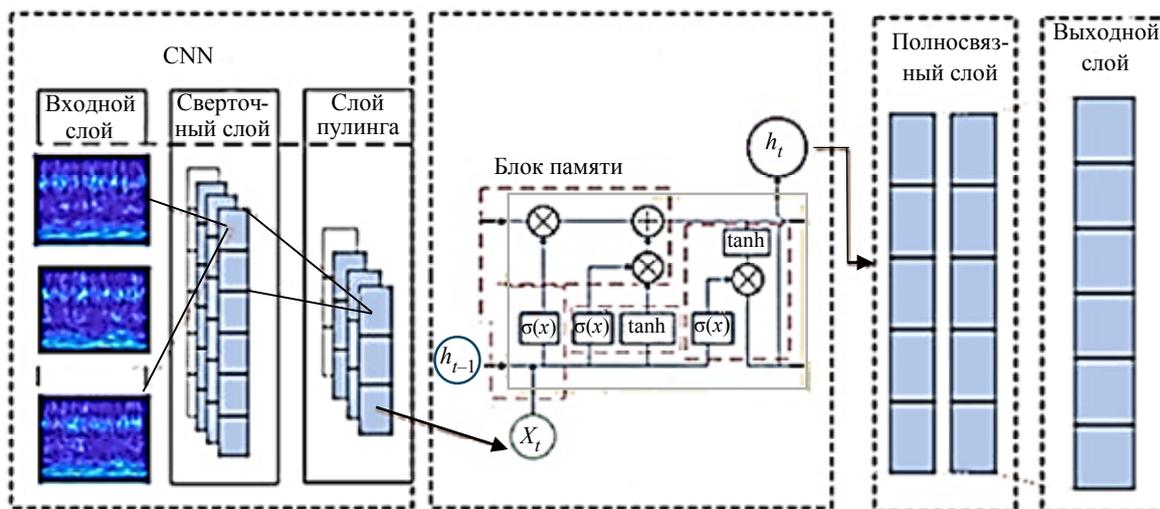


Рис. 10. Схема модели CNN-LSTM

Fig. 10. Diagram of the CNN-LSTM model

частотных карт, полученных с помощью преобразования CWT, и понижаются для уменьшения последовательности, чтобы построить временные векторы характеристик в высокоразмерном пространстве отображения. Извлеченные с помощью CNN последовательности признаков поступают в LSTM, чтобы уловить временные особенности данных временных рядов. LSTM может моделировать временные зависимости этих последовательностей признаков, чтобы лучше понять временную информацию в данных. Затем выходы объединяются, чтобы сформировать комплексное представление признаков, и это представление признаков обрабатывается через слой с полным подключением. Наконец, функция активации используется для вывода непрерывных прогнозов. Блок-схема модели CNN-LSTM показана на рис. 10.

Параметры для настройки модели CNN-LSTM приведены в таблице.

Параметры CNN-LSTM
CNN-LSTM parameters

Параметр	Числовое значение
Количество слоев	10
Количество выходных слоев	1
Количество скрытых слоев	2
Максимальное количество итераций	200
Алгоритм оптимизации	Adam
Скорость обучения	0.001

В данном исследовании для экспериментальной проверки используется эталонный набор данных редукторов. После фильтрации сглаживания и стандартной предварительной обработки 1024 последовательные точки выборки перехватываются для формирования одной выборки. Набор данных включает две основные категории

рабочих состояний: режим без нагрузки (0 % от номинальной) и режим с полной нагрузкой (100 % от номинальной). Каждая категория содержит по пять типов механических состояний: нормальная работа, трещина зуба, излом зуба, комбинированные дефекты (трещины и износ зубьев) и чистый износ зубьев. Таким образом, сформировано 10 типичных комбинаций состояний редуктора. Для каждого состояния было собрано по 1025 образцов данных, на основе которых с использованием непрерывного вейвлет-преобразования (CWT) построены карты временно-частотного распределения. Датасет был разделен на три части: 700 образцов использованы для обучения, 200 – для валидации и 125 – для тестирования модели.

Результаты. Набор данных был импортирован в модель, и после обучения модели получены следующие результаты.

Как показано на рис. 11, модель CNN-LSTM демонстрирует устойчивое поведение в процессе обучения на протяжении 200 эпох. Точность на обучающей выборке постепенно возрастает с увеличением числа итераций и в итоге достигает почти 100 %, тогда как точность на проверочной выборке стабилизируется около 90 % после примерно 100 циклов. Это свидетельствует о способности модели эффективно выделять дискриминационные признаки вибрационных сигналов, связанных с износом, повреждением зубьев и другими типами отказов. Рост кривых обучения и проверки происходит синхронно, при этом точность валидации сохраняется высокой и стабильной. Это подтверждает эффективную сходимость метода градиентного спуска и соответствие ха-

рактических характеристик модели заданным проектным требованиям. Отсутствие выраженных колебаний в конце кривой проверки дополнительно указывает на устойчивость модели при анализе сложных вибрационных спектров, что делает ее надежной основой для классификации и мониторинга состояния редукторов.

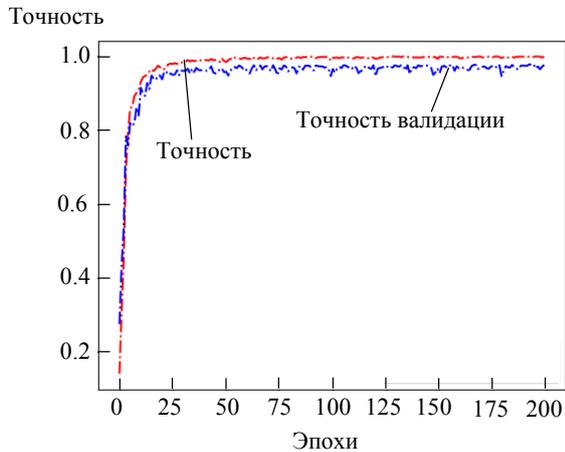


Рис. 11. Кривые точности
Fig. 11. Accuracy curves

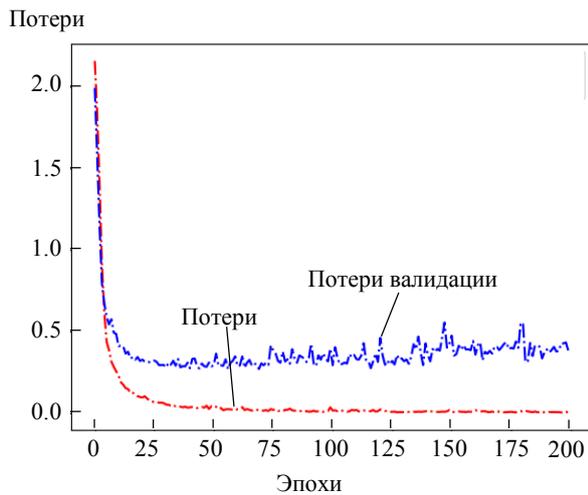


Рис. 12. Кривые потерь
Fig. 12. Loss curves

Модель CNN-LSTM демонстрирует характерное поведение оптимизации в течение 200 циклов обучения. Потери на обучающей выборке снижаются от исходного уровня (примерно 2.0) по мере увеличения числа итераций и достигают значения менее 0.5 (рис. 12), что свидетельствует о том, что алгоритм обратного распространения эффективно минимизирует ошибку предсказания на обучающих данных. Кривая потерь на проверочной выборке имеет двухэтапную динамику: в первые 100 циклов она заметно отстает от обучающей, а затем темп уменьшения замедляется, стабилизируясь около уровня 1.0. Постепенное увеличение разрыва между потерями на обучении и проверке (при-

мерно 0.5) указывает на наличие некоторой переадаптации модели к обучающим данным.

Тем не менее, отсутствие существенного роста потерь при проверке показывает, что модель сохраняет способность адекватно обрабатывать ранее не встречавшиеся данные, несмотря на определенный уровень переобучения. Плавная сходимость кривых потерь без выраженных колебаний говорит о корректности выбора параметров оптимизатора (например, Adam), а также о стабильности и управляемости процесса обновления градиентов. Такая динамика потерь согласуется с ранее полученными результатами по точности (около 90 % на проверочной выборке), что подтверждает эффективность и устойчивость сходимости модели при решении задачи классификации неисправностей коробки передач.

Заключение. Редукторы играют ключевую роль в промышленном оборудовании, обеспечивая передачу и преобразование крутящего момента. В данной статье объединяются методы непрерывного вейвлет-преобразования (CWT) и глубокого обучения для создания интеллектуальной модели диагностики неисправностей редукторов.

Предложенный подход преобразует исходные вибрационные сигналы в частотно-временные изображения с помощью CWT, извлекает пространственные особенности из этих изображений благодаря способности CNN к локальному восприятию, а затем использует рекуррентную сеть LSTM для моделирования временных зависимостей между последовательностями признаков. В результате достигается высокая точность классификации различных типов неисправностей.

Экспериментальные исследования показали, что предложенная модель обеспечивает среднюю точность распознавания на уровне 96.7 % при анализе данных десяти режимов работы коробок передач, что примерно на 8.2 % превышает результаты, полученные при использовании только одной из моделей – CNN или LSTM. Визуальный анализ показал, что временно-частотная диаграмма, сгенерированная CWT, может значительно улучшить межклассовую разделимость признаков неисправности (например, неисправность сломанного зуба представляет собой явление концентрации энергии признаков в полосе частот 4 кГц), а совместная модель CNN-LSTM эффективно справляется с недостатками традиционного метода, зависящего от искусственного проектирования признаков, и недостаточен в динамическом моделировании времени, посредством пространственно-временного бимодального слияния признаков.

Список литературы

1. Fault diagnosis of gearboxes using wavelet support vector machine, least square support vector machine and wavelet packet transform / M. Heidari, H. Homaei, H. Golestanian, A. Heidari // *J. of Vibroengin.* Vol. 18, no. 2. P. 860–875. doi: 10.21595/jve.2015.16184.
2. Xu F., Tse W. tai P., Tse Y. L. Roller bearing fault diagnosis using stacked denoising autoencoder in deep learning and Gath–Geva clustering algorithm without principal component analysis and data label // *Appl. Soft Comp.* 2018. Vol. 73. P. 898–913. doi: 10.1016/j.asoc.2018.09.037.
3. Mechanism-based automatic fault diagnosis method for gearboxes / L. Xu, T. Wang, J. Xie, J. Yang, G. Gao // *Sensors.* 2022. Vol. 22, no. 23. P. 9150. doi: 10.3390/s22239150.
4. A novel hierarchical algorithm for bearing fault diagnosis based on stacked LSTM / L. Yu, J. Qu, F. Gao, Y. Tian // *Shock and Vibration.* 2019. Vol. 2019, no. 1. P. 1–10. doi: 10.1155/2019/2756284.
5. Autocorrelation aided random forest classifier-based bearing fault detection framework / S. S. Roy, S. Dey, S. Chatterjee // *IEEE Sensors J.* 2020. Vol. 20, no. 18. P. 10792–10800. doi: 10.1109/jsen.2020.2995109.
6. A compound fault diagnosis model for gearboxes using correlation information between single faults / M. Zeng, H. Wang, Y. Cheng, J. Wei // *Measurement Sci. and Technol.* 2023. Vol. 35, no. 3. P. 036202. doi: 10.1088/1361-6501/ad1312.
7. An engine-fault-diagnosis system based on sound intensity analysis and wavelet packet pre-processing neural network / Y. S. Wang, N. N. Liu, H. Guo, X. L. Wang // *Eng. Appl. of Artificial Intelligence.* 2020. Vol. 94. P. 103765. doi: 10.1016/j.engappai.2020.103765.
8. Sun H., Zhao S. Fault Diagnosis for Bearing Based on 1DCNN and LSTM // *Shock and Vibration.* 2021. Vol. 2021, no. 1. P. 1–17. doi: 10.1155/2021/1221462.
9. Compound fault diagnosis of gearboxes via multi-label convolutional neural network and wavelet transform / P. Liang, C. Deng, J. Wu, Z. Yang, J. Zhu, Z. Zhang // *Comp. in Industry.* 2019. Vol. 113. P. 103132. doi: 10.1016/j.compind.2019.103132.
10. Ramteke D. S., Pachori R. B., Parey A. Automated gearbox fault diagnosis using entropy-based features in flexible analytic wavelet transform (FAWT) domain // *J. of Vibration Engin. & Technol.* 2021. Vol. 9, no. 7. P. 1703–1713. doi: 10.1007/s42417-021-00322-w.
11. Image Segmentation Using Deep Learning: A Survey / S. Minaee, Y. Y. Boykov, F. Porikli, A. J. Plaza, N. Kehtarnavaz, D. Terzopoulos // *IEEE Trans. on Pattern Analysis and Machine Intelligence.* IEEE, 2022. Vol. 44, no. 7. P. 3523–3542. doi: 10.1109/tpami.2021.3059968.

Информация об авторах

Кожубаев Юрий Нургалиевич – канд. техн. наук, доцент, Высшая школа управления киберфизическими системами, Санкт-Петербургский политехнический университет Петра Великого, ул. Политехническая, д. 29, Санкт-Петербург, 195251, Россия.

E-mail: kozhubaev_yun@spbstu.ru
<http://orcid.org/0009-0006-1822-7117>

Хохловский Владимир Николаевич – канд. техн. наук, доцент, Высшая школа управления киберфизическими системами, Санкт-Петербургский политехнический университет Петра Великого, ул. Политехническая, д. 29, Санкт-Петербург, 195251, Россия.

E-mail: hohlovskij_vn@spbstu.ru
<http://orcid.org/0009-0001-5298-5580>

Королев Михаил Петрович – студент Высшей школы управления киберфизическими системами, Санкт-Петербургский политехнический университет Петра Великого, ул. Политехническая, д. 29, Санкт-Петербург, 195251, Россия.

E-mail: korolev.mp@edu.spbstu.ru
<https://orcid.org/0009-0000-2114-7472>

Ершов Роман Викторович – зам. ген. директора АО «Воркутауголь», 169908, ул. Ленина, д. 62, г. Воркута, Республика Коми, 169908, Россия.

E-mail: Um-urii@rambler.ru
<http://orcid.org/0000-0003-0440-1824>

Сараджишвили Сергей Эрикович – канд. техн. наук, доцент, Высшая школа программной инженерии, Санкт-Петербургский политехнический университет Петра Великого, ул. Политехническая, д. 29, Санкт-Петербург, 195251, Россия.

E-mail: saradzh_se@spbstu.ru
<http://orcid.org/0000-0002-1291-1675>

Вклад авторов:

Кожубаев Ю. Н. – разработка методологии обработки вибрационных сигналов; подготовка и предварительная обработка экспериментальных данных; участие в построении моделей CNN-LSTM.

Хохловский В. Н. – постановка научной задачи; разработка концепции диагностики редукторов на основе SWT и глубокого обучения; научное руководство и интерпретация результатов.

Королев М. П. – программная реализация алгоритмов SWT, CNN и LSTM; обучение нейросетевых моделей; формирование датасета и проведение вычислительных экспериментов.

Ершов Р. В. – организация и проведение экспериментов на промышленных редукторах; сбор и верификация вибрационных данных; анализ эксплуатационных режимов оборудования.

Сараджишвили С. Э. – анализ и обобщение научной литературы; подготовка графического материала (вейвлет-карты, кривые обучения); редактирование рукописи и формулировка выводов.

References

1. Fault diagnosis of gearboxes using wavelet support vector machine, least square support vector machine and wavelet packet transform / M. Heidari, H. Homaei, H. Golestanian, A. Heidari // *J. of Vibroengin.* Vol. 18, no. 2. P. 860–875. doi: 10.21595/jve.2015.16184.
2. Xu F., Tse W. tai P., Tse Y. L. Roller bearing fault diagnosis using stacked denoising autoencoder in deep learning and Gath-Geva clustering algorithm without principal component analysis and data label // *Appl. Soft Comp.* 2018. Vol. 73. P. 898–913. doi: 10.1016/j.asoc.2018.09.037.
3. Mechanism-based automatic fault diagnosis method for gearboxes / L. Xu, T. Wang, J. Xie, J. Yang, G. Gao // *Sensors.* 2022. Vol. 22, no. 23. P. 9150. doi: 10.3390/s22239150.
4. A novel hierarchical algorithm for bearing fault diagnosis based on stacked LSTM / L. Yu, J. Qu, F. Gao, Y. Tian // *Shock and Vibration.* 2019. Vol. 2019, no. 1. P. 1–10. doi: 10.1155/2019/2756284.
5. Autocorrelation aided random forest classifier-based bearing fault detection framework / S. S. Roy, S. Dey, S. Chatterjee // *IEEE Sensors J.* 2020. Vol. 20, no. 18. P. 10792–10800. doi: 10.1109/jsen.2020.2995109.
6. A compound fault diagnosis model for gearboxes using correlation information between single faults / M. Zeng, H. Wang, Y. Cheng, J. Wei // *Measurement Sci. and Technol.* 2023. Vol. 35, no. 3. P. 036202. doi: 10.1088/1361-6501/ad1312.
7. An engine-fault-diagnosis system based on sound intensity analysis and wavelet packet pre-processing neural network / Y. S. Wang, N. N. Liu, H. Guo, X. L. Wang // *Eng. Appl. of Artificial Intelligence.* 2020. Vol. 94. P. 103765. doi: 10.1016/j.engappai.2020.103765.
8. Sun H., Zhao S. Fault Diagnosis for Bearing Based on 1DCNN and LSTM // *Shock and Vibration.* 2021. Vol. 2021, no. 1. P. 1–17. doi: 10.1155/2021/1221462.
9. Compound fault diagnosis of gearboxes via multi-label convolutional neural network and wavelet transform / P. Liang, C. Deng, J. Wu, Z. Yang, J. Zhu, Z. Zhang // *Comp. in Industry.* 2019. Vol. 113. P. 103132. doi: 10.1016/j.compind.2019.103132.
10. Ramteke D. S., Pachori R. B., Parey A. Automated gearbox fault diagnosis using entropy-based features in flexible analytic wavelet transform (FAWT) domain // *J. of Vibration Engin. & Technol.* 2021. Vol. 9, no. 7. P. 1703–1713. doi: 10.1007/s42417-021-00322-w.
11. Image segmentation using deep learning: A survey / S. Minaee, Y. Y. Boykov, F. Porikli, A. J. Plaza, N. Kehtarnavaz, D. Terzopoulos // *IEEE Trans. on Pattern Analysis and Machine Intelligence.* IEEE, 2022. Vol. 44, no. 7. P. 3523–3542. doi: 10.1109/tpami.2021.3059968.

Information about the authors

Yuriy N. Kozhubaev – Cand. Sci. (Eng.), Associate Professor, Associate Professor at the Higher School of Cyber-Physical Systems Management, Institute of Computer Science and Cybersecurity, Peter the Great St. Petersburg Polytechnic University (SPbPU), Polytechnicheskaya St., 29, St. Petersburg, 195251, Russia.

E-mail: kozhubaev_yun@spbstu.ru

<http://orcid.org/0009-0006-1822-7117>

Vladimir N. Khokhlovsky – Cand. Sci. (Eng.), Associate Professor, Higher School of Cyber-Physical Systems Management, Peter the Great St. Petersburg Polytechnic University, Politechnicheskaya St., 29, St. Petersburg, 195251, Russia.

E-mail: hohlovskij_vn@spbstu.ru

<http://orcid.org/0009-0001-5298-5580>

Mikhail P. Korolev – student, Higher School of Cyber-Physical Systems Management, Peter the Great St. Petersburg Polytechnic University, 29 Politekhnicheskaya St., St. Petersburg, 195251, Russia.

E-mail: korolev.mp@edu.spbstu.ru

<https://orcid.org/0009-0000-2114-7472>

Roman V. Ershov – Deputy General Director of Vorkutaugol JSC, Lenin St., 62, Vorkuta, Komi Republic, 169908, Russia.

E-mail: um-urii@rambler.ru

<http://orcid.org/0000-0003-0440-1824>

Sergey E. Saradjishvili – Candidate of Technical Sciences, Associate Professor, Higher School of Software Engineering, Peter the Great St. Petersburg Polytechnic University, 29 Politekhnicheskaya St., St. Petersburg, 195251, Russia.

E-mail: saradh_se@spbstu.ru

<http://orcid.org/0000-0002-1291-1675>

Contribution of the authors:

Kozhubaev Yu. N. – development of vibration signal processing methodology; preparation and preprocessing of experimental data; contribution to the construction of CNN-LSTM models.

Khokhlovsky V. N. – formulation of the research problem; development of the concept for gearbox fault diagnosis based on CWT and deep learning; scientific supervision and interpretation of the results.

Korolev M. P. – software implementation of CWT, CNN and LSTM algorithms; neural network training; dataset construction and computational experiments.

Ershov R. V. – organization and execution of experiments on industrial gearboxes; acquisition and verification of vibration data; analysis of operating conditions.

Saradjishvili S. E. – literature review and synthesis; preparation of graphical materials (wavelet maps, learning curves); manuscript editing and formulation of conclusions.

Статья поступила в редакцию 21.11.2025; принята к публикации после рецензирования 25.01.2026; опубликована онлайн 30.03.2026.

Submitted 21.11.2025; accepted 25.01.2026; published online 30.03.2026.
