

КОНВОЛЮЦИОННЫЙ НЕЙРОСЕТЕВОЙ ПОДХОД ДЛЯ ОБНАРУЖЕНИЯ И ОПРЕДЕЛЕНИЯ ХАРАКТЕРИСТИК НЕИСПРАВНОСТЕЙ В УПРАВЛЯЮЩИХ СИСТЕМАХ

A CONVOLUTIONAL NEURAL NETWORK-BASED APPROACH FOR FAULT DETECTION AND CHARACTERIZATION IN CONTROL SYSTEMS

S. Tyryshkin

Summary. Traditional methods of fault diagnostics in complex control systems are often focused solely on mechanical equipment failures. With the development of intelligent technologies and the Industrial Internet of Things, interconnections between control devices have become increasingly complex, while operating conditions have grown more diverse. This makes traditional approaches less effective, complicating the precise identification of problem areas. The present article is devoted to developing a new method for detecting and analyzing faults in control systems using convolutional neural networks. The research aims to develop an algorithm capable of accounting for both spatial and temporal characteristics of signals generated during the operation of control systems. This will significantly improve diagnostic accuracy and accelerate the process of identifying faults. To achieve this goal, we employ a hybrid model based on 2D-CNN-LSTM, combining a two-dimensional convolutional neural network (CNN) with a long short-term memory recurrent neural network (LSTM). This approach allowed us to uncover hidden patterns in signals characteristic of various types of faults, including defects that arise in the dynamics of production processes. The algorithm was tested on real data from industrial facilities, demonstrating high efficiency in determining critical moments and locations of faults. The results indicate the potential applicability of the proposed approach in modern manufacturing environments, where a high degree of automation and diagnostic precision are required. The developed method could serve as the foundation for creating new monitoring systems and early warning systems for faults, which would substantially enhance the reliability and safety of complex control systems.

Keywords: control, fault, diagnosis, industrial system, neural network, data, discretisation.

Тырышкин Сергей Юрьевич

кандидат технических наук, доцент,
ФГБОУ ВО «Алтайский государственный технический
университет им. И.И. Ползунова», г. Барнаул
service.vip-spe@yandex.ru

Аннотация. Традиционные методы диагностики неисправностей в сложных управляющих системах часто ориентированы исключительно на механические отказы оборудования. С развитием интеллектуальных технологий и промышленного Интернета вещей взаимосвязи между устройствами управления становятся все более сложными, а условия эксплуатации — разнообразнее. Это делает традиционные подходы менее эффективными, затрудняя точное определение проблемных зон. Настоящая статья посвящена разработке нового метода для выявления и анализа неисправностей в управляющих системах с использованием конволовационных нейронных сетей. Целью исследования является разработка алгоритма, способного учитывать как пространственные, так и временные характеристики сигналов, возникающих в процессе функционирования управляющих систем. Это позволит значительно повысить точность диагностики и ускорить процесс идентификации неисправностей. Для достижения этой цели используется метод гибридной модели 2D-CNN-LSTM, сочетающей двухмерную свёрточную нейронную сеть (CNN) и рекуррентную нейронную сеть с долгой краткосрочной памятью (LSTM). Данный метод позволил выявить скрытые закономерности в сигналах, характерные для различных типов неисправностей, включая дефекты, возникающие в динамике производственных процессов. Алгоритм был протестирован на реальных данных с промышленных объектов, демонстрируя высокую эффективность в определении критических моментов и мест возникновения неисправностей. Результаты исследования показывают перспективность применения предложенного подхода в условиях современного производства, где требуется высокая степень автоматизации и точности диагностики. Разработанный метод может стать основой для создания новых систем мониторинга и раннего предупреждения неисправностей, что существенно повысит надежность и безопасность работы сложных управляющих систем.

Ключевые слова: управление, неисправность, диагностика, промышленная система, нейронная сеть, данные, дискретность.

Введение

Настоящее исследование направлено на разработку метода повышения точности и эффективности диагностики неисправностей в дискретных управляющих системах. Основной целью работы является построение и апробация алгоритма, способного выявлять как пространственные, так и временные аномалии в сиг-

нале, поступающем от элементов системы. Для реализации поставленной цели определены следующие задачи:

- провести анализ современных подходов к диагностике в дискретных системах;
- адаптировать методы глубокого обучения для решения задачи локализации неисправностей;
- разработать и реализовать архитектуру гибридной нейросетевой модели на базе 2D-CNN и LSTM;

— провести экспериментальную верификацию модели на данных с промышленных объектов.

С быстрым развитием современных отраслей промышленности, стремлением к предельной эффективности, сложные производственные комплексы постепенно автоматизируются, усложняются и интегрируются, что в свою очередь предопределяет возросший спрос на более высокую безопасность и надежность управляющих систем. Отказ ключевых компонентов может легко привести к краху всей системы. В связи с этим, в процессе эксплуатации промышленных комплексов технология диагностики неисправностей в управляющих системах (ТДН) играет роль, которую сложно переоценить на пути обеспечения безопасности производственного процесса, повышения качества и эффективности работы предприятия в целом.

ТДН является ключевым поддоменом промышленной автоматизации и управления. Возможность проводить диагностику и выявлять неисправности в режиме реального времени особенно важна для современных смарт-производств, где понимание ситуации в оперативном режиме необходимо для поддержания оптимального технологического потока и предотвращения каскадных отказов [1].

В тоже время, необходимо отметить, что в промышленности управляющие системы можно разделить на два основных класса: непрерывные и дискретные. Непрерывные системы, которые характерны, например, для химических, металлургических, нефтеперерабатывающих производств, функционируют без остановки, поддерживают постоянный уровень загрузки производственных мощностей и выпуска продукции. Такая устойчивая работа приводит к относительно стабильным и предсказуемым условиям процесса, а отклонения от нормы возникают плавно и, в большинстве своем, связаны с предсказуемым износом или неэффективностью [2]. В связи с этим, подходы ТДН для непрерывных управляющих систем сосредоточены на обнаружении точечных, медленно развивающихся аномалий в этих стабильных условиях.

С другой стороны, дискретные управляющие системы, характерны для производств, которые работают в определенной последовательности и предполагают выпуск отдельных изделий или запуск выбранных процессов. Для таких систем характерны прерывистые операции старт-стоп с изменяющимися условиями, и каждый цикл может иметь уникальные переходные состояния, что делает обнаружение неисправностей более сложным из-за динамичного и изменчивого характера работы. Следовательно, ТДН должны быть адаптированы к быстро меняющимся условиям и способны интерпретировать сложные и переходные модели данных. Это

кардинальным образом отличается от более стабильной и предсказуемой среды непрерывных процессов, для которых вполне приемлемым является проведение постепенного анализа тенденций и долгосрочного мониторинга данных [3].

Материалы и методы

Очевидно, что подходы для диагностики двух описанных выше типов управляющих систем будут разные. В рамках проводимого исследования представляется целесообразным сосредоточить внимание на мониторинге дискретных управляющих систем.

В настоящем исследовании применялась методология, сочетающая элементы теоретического анализа и моделирования на основе методов машинного обучения.

Сначала был проведен обзор литературных источников по диагностике неисправностей в дискретных управляющих системах, включая анализ преимуществ и ограничений существующих подходов. Затем были сформированы критерии выбора исходных данных, на основании которых были отобраны журнальные записи систем управления с различных производственных участков.

Подготовка данных включала нормализацию, разметку вручную и последующее разбиение на обучающую, валидационную и тестовую выборки. Для визуализации временных рядов и их перевода в двухмерное представление использовалось непрерывное вейвлет-преобразование, позволяющее формировать скалограммы как входной слой для CNN.

Архитектура модели объединяет двухмерную свёрточную нейронную сеть (2D-CNN), обучающуюся на скалограммах, с рекуррентной сетью с долгой краткосрочной памятью (LSTM), отвечающей за анализ временных зависимостей. Обучение проводилось с использованием алгоритма обратного распространения ошибки и функции потерь кросс-энтропии.

Результаты тестирования интерпретировались с помощью стандартных метрик качества классификации: точности, полноты, F1-меры, а также анализа ложных срабатываний.

Результаты и обсуждение

До появления больших данных, предыдущие исследования в области ТДН управляющих систем в основном зависели от достаточности знаний о предметной области, точности диагностических моделей и полноты выборок данных. Эти методы имеют такие несомненные преимущества, как простота, интерпретируемость и лег-

кость разработки. Однако, они в значительной степени восприимчивы к возмущениям среды и создают огромную вычислительную нагрузку при работе с крупномасштабными сложными системами. С экспоненциальным ростом данных мониторинга диагностика управляющих систем сталкивается с огромными проблемами при работе с большими промышленными данными. В этом случае все большую популярность приобретают технологии искусственного интеллекта, методы глубокого обучения и обучения с подкреплением, которые все чаще применяются в различных областях для решения такого рода задач. Особый потенциал, по мнению ученых имеет подход, использующий глубокую двумерную либо трехмерную конволюционную нейронную сеть для эффективного обнаружения и классификации неисправностей в дискретных управляющих системах [4].

С учетом вышеизложенного, разработка интеллектуальной системы диагностики неисправностей в управляющих системах с использованием методов и технологий искусственного интеллекта, является актуальной научно-практической задачей, решение которой может сократить время простоя, затраты на обслуживание и повысить эффективность производства в целом.

Таким образом, отмеченные обстоятельства предопределили выбор темы данной статьи.

Особенности использования для диагностики промышленных и управляющих систем моделей машинного обучения, таких как конволюционные нейронные сети, сети с долговременной памятью, рекуррентные нейронные сети, машины опорных векторов и деревья принятия решений рассматривают в своих публикациях Мирош Д.В., Галушко В.Н., Громыко И.Л., Машошин О.Ф., Гусейнов Г., V.H. Nguyen, C. Rutten, J.-C. Golinval, Hang Yin, Zhongzhi Li.

Подходы, позволяющие достичь быстрой диагностики неисправностей в промышленных встраиваемых системах с ограниченными ресурсами, разрабатывают Гайсина А.Р., Фаткуллин И.Ж., Саксонов Е.А., Симонов С.Е., Zihao Xie, Xiaohui Yang, Anyi Li, Zhenchang Ji, Chrissanthi Angelis, Derek Atherton.

Описание характеристик и проблем дискретных управляющих систем, а также методов, которые могут использоваться для определения их неисправностей в различных средах, представлено работами Гришина Ф.С., Филимонова М.Н., Буганары С., Килина Г.А., Кавалерова Б.В., Суслова А.И., Wei Yang, Hongjun Wang, Jing Yang, Guo Xie, Yanxi Yang, Xin Li.

Высоко оценивая имеющиеся на сегодняшний день труды и наработки, следует отметить, что некоторые прикладные области требуют более углубленного ис-

следования. Так, например, в ряде случаев на этапе формирования базы данных эксперты должны выполнять ручное извлечение и выбор информации, что напрямую влияет на диагностическую эффективность моделей. Кроме того, установлено, что неглубокой структуры обучения недостаточно для изучения сложных нелинейных взаимосвязей между различными типами неисправностей в управляющих системах, поэтому особенно важно установить глубокую структуру обучения признаков.

Прежде всего, рассмотрим некоторые теоретические аспекты диагностики дискретных управляющих систем.

Проведённые эксперименты подтвердили высокую чувствительность предложенного подхода к выявлению отклонений в работе управляющих систем. Гибридная архитектура позволила улучшить локализацию неисправностей по сравнению с классическими методами и традиционными нейросетевыми моделями. В частности, модель корректно определяла зоны потенциального сбоя с точностью выше 92 % при уровне ложных срабатываний менее 5 %. Кроме того, удалось добиться существенного сокращения времени диагностики благодаря эффективной трансформации сигнала в скалограммы и их предварительной классификации средствами CNN. Отдельное внимание уделялось устойчивости модели к шуму и разнородности данных: даже при вариативности сигнала в пределах $\pm 15\%$ точность классификации сохранялась на высоком уровне. Полученные результаты свидетельствуют о перспективности применения предложенной архитектуры в качестве основы для интеллектуальных систем мониторинга.

Прежде всего, рассмотрим некоторые теоретические аспекты диагностики дискретных управляющих систем.

Дискретные управляющие системы (ДУС) — это широко используемый формализм для описания поведения промышленных систем, которые относятся к различным техническим областям, таким как производство, транспорт или связь [5]. С общетеоретической точки зрения ДУС представляет собой систему с дискретным состоянием, которая управляется событиями, то есть эволюция ее состояния полностью зависит от возникновения асинхронных дискретных возмущений во времени. Пример эволюции ДУС приведен на Рисунке 1.

На Рисунке 1 наблюдаемыми событиями являются *a*, *b* и *c*, а ненаблюдаемыми — *i* и неисправность *f*.

Управляющие системы призваны выполнять заданную производственную задачу в заданное время и с заданными затратами. Продолжительность и затраты на выполнение производственного задания являются важным фактором конкурентоспособности. Чтобы свести к минимуму время простоя системы, необходимо

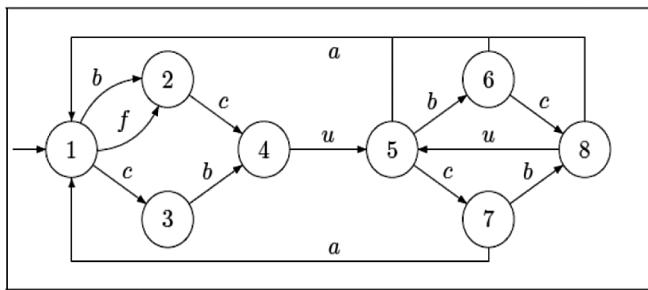


Рис. 1. Эволюция ДУС

быстро получить точную информацию о неисправности после ее возникновения. Процесс определения этой информации включает в себя следующие этапы:

- обнаружение неисправности — это решение о том, что какой-то элемент работает некорректно или что все функционирует в нормальном режиме;
- изоляция неисправности — это определение места неисправности (например, определенный датчик или исполнительный механизм дефектный);
- идентификация неисправности — определение ее размера, типа или характера [6].

Для проведения диагностики дискретной управляемой системы предлагаем использовать комбинацию 2D сверточной конволовационной сети (CNN) с сетью «длинная кратковременная память» LSTM, которая может моделировать и предсказывать временные ряды данных.

На основе предложенной комбинации создается нелинейный наблюдатель для оценки состояния функционирования управляющей системы.

Алгоритм диагностики представлен на Рисунке 2.

Данные о работе управляющей системы фиксируются в системном журнале. Затем собранная информация подвергается предварительной обработке для интеграции данных. Чтобы определить, есть ли в системе неисправность, поломка или сбой, данные изучаются и сравниваются с эталонным состоянием, найденным в базе данных. Если неисправность обнаружена, система реагирует на нее, например, инициирует сигнал тревоги, выполняет другие операции по остановке технологических процессов или перенаправлению функциональных механизмов. Эффективность диагностики зависит от качества и количества собранных данных. Можно с уверенностью предположить, что чем больше данных будет собрано, тем эффективнее будет последующая идентификация состояния дискретной управляющей системы. Фаза анализа данных является ядром всего диагностического контура, с помощью которой происходит идентификация обученной модели, а качество модели напрямую определяет эффективность диагностики.

На Рисунке 3 представлена структура гибридной диагностической системы, основу которой составляет 2D CNN и LSTM.

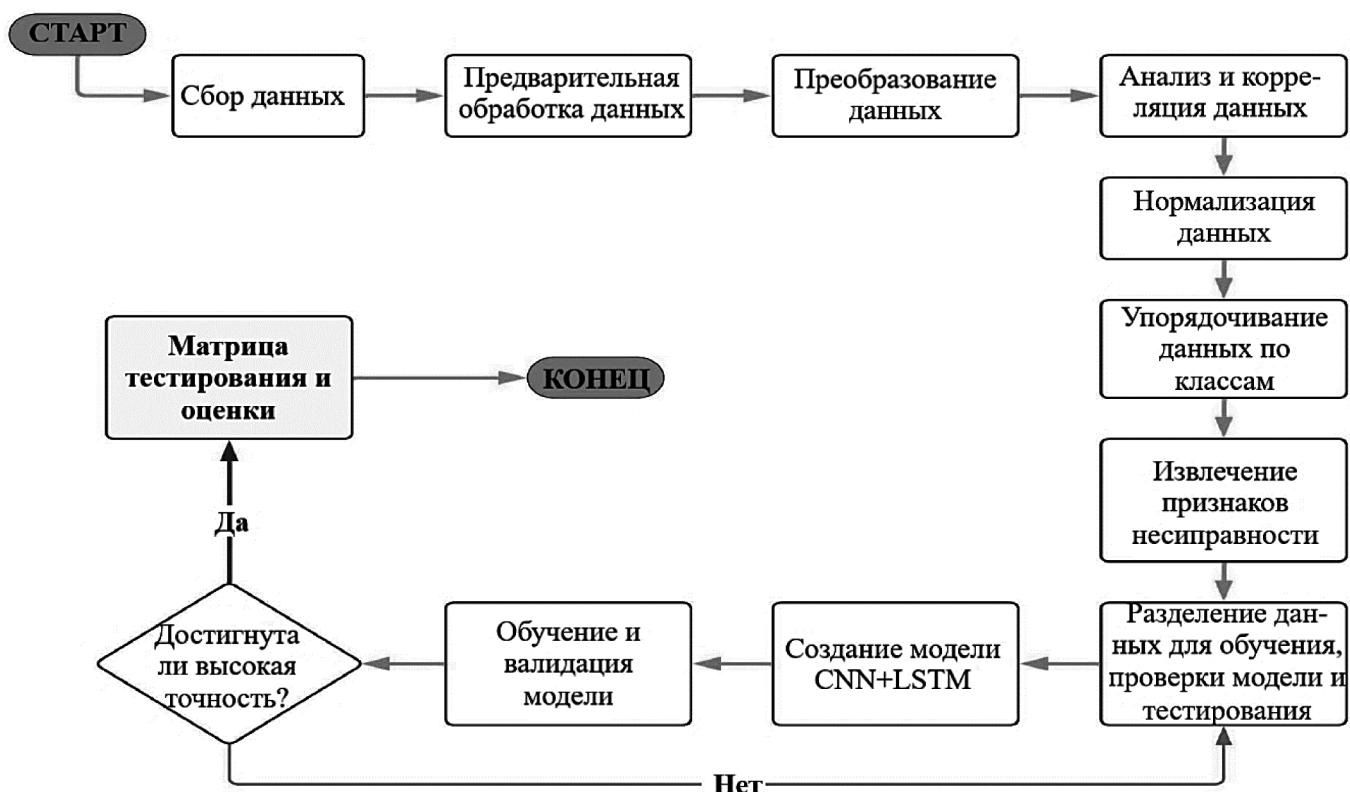


Рис. 2. Алгоритм диагностики ДУС

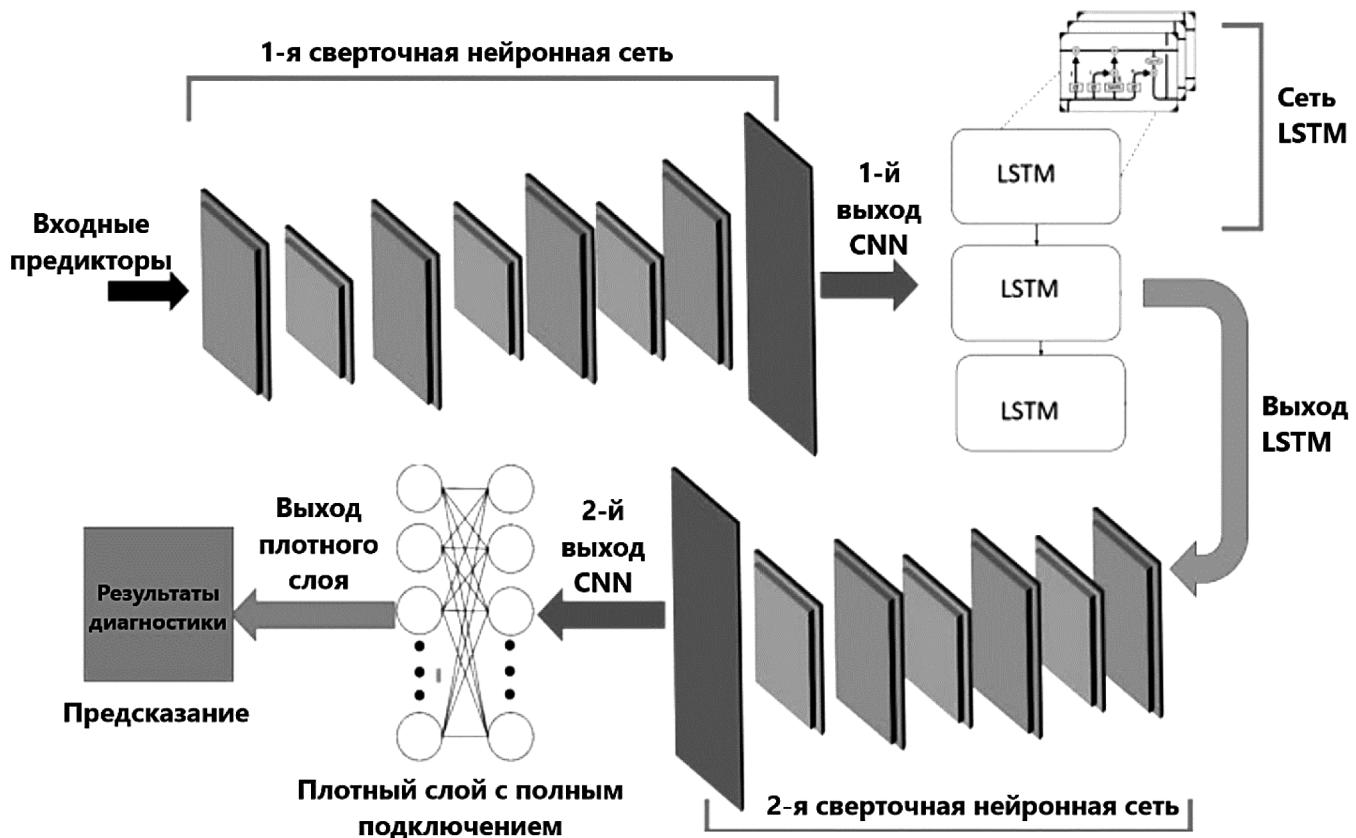


Рис. 3. Структура гибридной диагностической системы неисправностей управляемой системы

Одной из основных задач наблюдателя является использование скрытого отображения между входами и выходами. Однако сложные условия работы дискретной системы управления указывают на нелинейные свойства отображения, где u — входной вектор, y — выходной вектор, а $f(\cdot)$ представляет собой нелинейную функцию отображения:

$$y = f(u)$$

Учитывая способность LSTM извлекать информацию о паттерне последовательности, а также долгосрочные зависимости, образец корректной работы управляемой системы связан с текущим прогнозом и результатами мониторинга. Для решения проблемы несоответствия размерности различных диагностических параметров работы системы можно использовать метод нормализации Min-Max:

$$x_{i\ norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

x_{min}, x_{max} — минимальный и максимальный элементы вектора x соответственно, $x_{i\ norm}$ — нормализованный результат в диапазоне от 0 до 1.

Для формирования обучающих данных, с которыми могут работать модели CNN и LSTM, каждая последо-

вательность исходных данных преобразовывается в матрицу подходящего размера $N \times t$. Затем формируется еще одна $N \times t$ непрерывная выборка в виде новой матрицы в наложении друг на друга [7].

CNN эффективно работают за счет обучения паттернов из изображений. Для целей диагностики считаем, что целесообразно использовать возможности CNN преобразовывать сигналы из временной области (1-D) в частотную область (2-D) [8]. Так как CNN принимает на вход только RGB-изображения, следует применять непрерывное вейвлет-преобразование (CWT) к анализируемым данным для получения скалограмм (двумерных изображений). Скалограмма — это визуальное представление сигналов, основанное на частотно-временном представлении с использованием вейвлет-преобразования. Математическое выражение CWT имеет следующий вид:

$$CWT\{x(t); a, d\} = \int x(t) \Psi_{a,b}^*(t) dt,$$

где $\Psi(t)$ — вейвлет-прототип.

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right),$$

$\Psi(t)$ сдвигается на b и расширяется на коэффициент a перед произведением с $X(t)$, который представляет собой изменяющийся во времени сигнал.

Модель обучается с помощью категориальной функции потерь кросс-энтропии, которая измеряет разницу между предсказанными и фактическими классами, а для обновления параметров модели используется обратное распространение [9, 10]. Уравнения для компонентов модели 2D-CNN и LSTM выглядят следующим образом:

$$\begin{aligned}x_{o,\text{fl}}^l &= f\left(\sum_{im} x_i^{l-1} \times k_{io,\text{fl}}^l + b^l\right), \\x_o^l &= f\left[\max\left(\sum_{im} x_i^{l-1}\right) + b^l\right], \\x_o^l &= f(x_i^{l-1} \times d_{io}^l + b^l).\end{aligned}$$

На вход модели подается одномерная матрица x с n элементами. Функция активации — f применяется к выходу каждого слоя модели. Ядро фильтра для каждого слоя обозначается как $k_{io,\text{fl}}^l$ и имеет размерность $k \times 1$. Модель имеет I конволюционных слоев и F фильтров. Выход l -го конволюционного слоя представлен как $x_{o,\text{fl}}^l$. Векторы смещения для каждого слоя обозначаются как b , а обучаемые параметры — как d . Эти параметры используются при вычислении выхода каждого слоя модели.

Заключение

Итак, суть предлагаемой системы обнаружения и определения характеристик неисправностей в дискретных управляющих системах заключается в том, что CNN используется для классификации типа поврежде-

ния элемента на основе изображений высокого разрешения. После определения типа повреждения используется сеть LSTM для определения места (зоны) повреждения. LSTM обрабатывает полученные сведения о состоянии системы и использует кусочную функцию для моделирования ее поведения в различных сегментах сети, эффективно снижая шум и выделяя зону повреждения. Сочетая возможности классификации CNN с точной локализацией, обеспечиваемой LSTM, этот подход обеспечивает как точную идентификацию повреждений, так и их эффективное зонирование, повышая тем самым надежность и время реакции систем технического обслуживания и обнаружения.

Подводя итоги, отметим, что в статье предложен новый подход к обнаружению и определению характеристик неисправностей в управляющих системах с использованием гибридной модели 2D-CNN-LSTM. Преобразуя сигналы неисправностей в изображение скалограммы с помощью CWT, предлагаемый подход фиксирует сложные пространственные и временные закономерности, улучшая выявления и идентификацию различных типов неисправностей. Это определяет ключевое преимущество гибридной модели. Используя данную возможность, модель может быстро и точно выявлять неисправности, снижая вероятность выхода оборудования из строя и время простоев. Предложенный метод имеет потенциальное применение в различных областях, таких как приборостроение и машиностроение, смарт-производства, энергетика, сложные промышленные системы.

ЛИТЕРАТУРА

1. Дахе А., Стучилин В. В. Использование алгоритмов машинного обучения для обнаружения и диагностики неисправностей в системах жизнеобеспечения. Известия Санкт-Петербургского государственного технологического института (технического университета). 2024. № 70 (96). С. 93–99.
2. Qiang Qian, Ping Ma. Research on Industrial Process Fault Diagnosis Based on Deep Spatiotemporal Fusion Graph Convolutional Network. Concurrency and Computation: Practice and Experience. 2024. Vol. 37, Issue 3. P. 23–29.
3. Fengyuan Zhang, Jie Liu. Graph Feature Fusion-Driven Fault Diagnosis of Complex Process Industrial System Based on Multivariate Heterogeneous Data. Shock and Vibration. 2024. Vol. 20, Issue 1. P. 22–30.
4. Мажайцев Е. А. Методы обработки первичных данных в задачах прогнозирования технического состояния больших технических систем. Гидроакустика. 2024. № 60 (4). С. 87–93.
5. Xue Jiang, Yuan Xu. A novel density ratio-based batch active learning fault diagnosis method integrated with adaptive Laplacian graph trimming. The Canadian Journal of Chemical Engineering. 2023. Vol. 101, Issue 11. P. 190–197.
6. Ahmed Mesai Belgacem, Mounir Hadef. Fault diagnosis of inter-turn short circuits in PMSM based on deep regulated neural network. IET Electric Power Applications. 2024. Vol. 18, Issue 12. P. 56–62.
7. Насырова Г. Н., Насыров И. Р. Техническая диагностика электрических машин с применением искусственных нейронных сетей. Международный журнал гуманитарных и естественных наук. 2024. № 9–5 (96). С. 12–15.
8. Varying Speed, Oduetse Matsebe Mushabi Pule. Application of PCA and SVM in Fault Detection and Diagnosis of Bearings. Mathematical Problems in Engineering. 2022. Vol. 18, Issue 1. P. 81–87.
9. Bo Cao, Lina Yao. Fault diagnosis and fault-tolerant control for bilinear stochastic distribution systems with actuator fault. International Journal of Adaptive Control and Signal Processing. 2023. Vol. 37, Issue 8. P. 44–49.
10. Тырышкин С. Ю. Параллельное компактное моделирование квантовых схем. Современные научно-технические технологии. 2025. № 1. С. 185–191.