

Обнаружение многоклассовых неисправностей в системах управления электросетями с использованием данных PMU уровня передачи

Прешиоус Огенеоро
Отуазохор

*Кафедра компьютерных наук и
техники
Санкт-Петербургский
государственный
электротехнический
университет «ЛЭТИ»
им. В.И. Ульянова (Ленина)
potuazokhor@stud.etu.ru*

Адейе Адебусола Ияну

*Кафедра компьютерных наук и
техники
Санкт-Петербургский
государственный
электротехнический
университет «ЛЭТИ»
им. В.И. Ульянова (Ленина)
adebusolayeye@gmail.com*

Яна А. Бекенева

*Кафедра компьютерных наук и
техники
Санкт-Петербургский
государственный
электротехнический
университет «ЛЭТИ»
им. В.И. Ульянова (Ленина)
yabekeneva@etu.ru*

Эзе Чуквука Деннис

*Кафедра компьютерных наук и
техники
Санкт-Петербургский
государственный
электротехнический
университет «ЛЭТИ»
им. В.И. Ульянова (Ленина)
ezedennis9@gmail.com*

Аннотация. Современные электросети в значительной степени зависят от своевременного и точного обнаружения неисправностей для обеспечения стабильной и надежной работы. В этой статье предлагается управляемая данными структура, которая использует глубокое обучение для обнаружения и классификации различных типов неисправностей в сетях передачи данных с использованием данных высокоточного фазового измерительного блока (PMU). Наш подход использует автоэнкодер на основе LSTM, обученный на нормальных рабочих условиях для изучения типичных схем напряжения и потоков мощности. Отклонения от этих изученных схем идентифицируются как аномалии, а кластеризация в скрытом пространстве используется для дифференциации типов неисправностей, таких как вынужденные колебания, отключения шины и отключения генератора. Метод предназначен для бесшовной интеграции с системами управления сетью, предоставляя операторам информацию в режиме, близком к реальному времени. Эта работа способствует развитию методов обработки информации в управлении энергосистемами путем объединения моделирования временной последовательности с методами неконтролируемой классификации, направленными на расширение возможностей диагностики неисправностей в сложных технических системах.

Ключевые слова: блоки измерения фаз (PMU), кластеризация скрытого пространства, обнаружение неисправностей электросети, обнаружение аномалий

I. ВВЕДЕНИЕ

Растущая сложность и масштаб современных электросетей в сочетании с интеграцией возобновляемых

источников энергии сделали мониторинг и обнаружение неисправностей в режиме реального времени критически важными для обеспечения стабильности и надежности сети. Устройства векторных измерений (PMU) теперь обеспечивают потоки данных высокого разрешения, синхронизированные по времени со всех сетей электропередачи, открывая новые возможности для раннего обнаружения и диагностики неисправностей. Однако высокая размерность, уровень шума и неоднородность данных PMU создают значительные трудности для традиционных методов обнаружения неисправностей, основанных на пороговых значениях или моделях.

Недавние достижения в области искусственного интеллекта (ИИ) и машинного обучения (МО) продемонстрировали многообещающие возможности решения этих проблем за счет внедрения подходов, основанных на данных, которые могут изучать сложные временные и пространственные закономерности на основе данных датчиков большого объема [2]. В частности, модели глубокого обучения, такие как автокодировщики с долговременной краткосрочной памятью (LSTM), продемонстрировали высокую производительность для неконтролируемого обнаружения аномалий в данных временных рядов, изучения нормальных рабочих схем и маркировки отклонений как потенциальных неисправностей [1]. Тем не менее, различие нескольких типов неисправностей, таких как вынужденные колебания, отключения генератора и неисправности линии, остается сложной

задачей, особенно когда сигнатуры неисправностей незначительны или перекрываются.

В данной статье предлагается комплексная, основанная на данных структура, использующая автоэнкодеры LSTM, анализ скрытого пространства и контролируемое обучение для обнаружения и классификации нескольких типов неисправностей в данных PMU на уровне передачи. Основываясь на последних исследованиях в области обнаружения промышленных аномалий и энергетических систем, предлагаемый подход объединяет расширенную предварительную обработку, временное моделирование и проектирование признаков для предоставления операторам сетей практически актуальной аналитической информации в режиме, близком к реальному времени.

II. ЛИТЕРАТУРНЫЙ ОБЗОР

Применение ИИ и МО в энергетических системах быстро расширилось в последние годы, что обусловлено потребностью в более интеллектуальных, более устойчивых операциях с сетями и распространением данных датчиков. Ранние подходы к обнаружению неисправностей в энергосистемах основывались на экспертных системах на основе правил и статистических методах, которые часто испытывали трудности с высокоразмерными, зашумленными и нестационарными данными. Внедрение машинного обучения, особенно неконтролируемых и полуконтролируемых методов, позволило более надежно обнаруживать аномалии без необходимости использования исчерпывающих маркированных наборов данных. Недавние исследования показали, что машинное обучение, особенно глубокое обучение, все чаще применяется для защиты и управления энергосистемами, обеспечивая более надежное и быстрое обнаружение неисправностей даже в сложных, насыщенных данными средах [4]. Было показано, что неконтролируемая кластеризация в латентном пространстве, такая как метод K-средних, применяемый к признакам в частотной области, эффективно классифицирует неисправности энергосистемы без необходимости использования маркированных обучающих данных, поддерживая масштабируемый и управляемый данными анализ неисправностей [5].

Автоэнкодеры LSTM стали ведущим методом обнаружения аномалий во временных рядах благодаря своей способности фиксировать долгосрочные зависимости и восстанавливать нормальные закономерности. Их фреймворки доказали свою высокую эффективность в обнаружении аномальных закономерностей во временных рядах данных датчиков, обеспечивая повышенную точность и полноту по сравнению с традиционными автоэнкодерами, а также позволяя на ранней стадии обнаруживать неисправности в сложных системах [6]. Эффективность автокодировщиков LSTM для неконтролируемого обнаружения выбросов в данных вибрации ветряных турбин, сочетающих вейвлет-пакетное преобразование, высокочастотную фильтрацию и анализ главных компонент (PCA) в качестве этапов предварительной обработки, была продемонстрирована в значительном повышении точности обнаружения аномалий [1]. Их подход — обучение автокодировщика LSTM только на нормальных данных с последующим использованием ошибки реконструкции в качестве оценки аномалии —

позволил достичь эффективности обнаружения выбросов 97%, превзойдя методы без расширенной предварительной обработки.

В более широком энергетическом секторе машинное обучение применяется для мониторинга в режиме реального времени, предиктивного обслуживания и оптимизации, в том числе в жилых солнечных электростанциях и интеллектуальных сетях. В своей работе Аннапаредди и Рани [2] рассматривают ряд алгоритмов машинного обучения, от регрессионных моделей и опорных векторных машин до ансамблевых методов, таких как XGBoost, для прогнозирования энергопотребления и обнаружения неисправностей в распределённых энергетических системах. Также исследовалось использование неконтролируемого обучения и кластеризации, такой как метод k-средних или спектральная кластеризация, для выявления скрытых закономерностей и типов неисправностей в данных датчиков большого объёма.

Несмотря на эти достижения, сохраняются проблемы с различием различных типов неисправностей и интеграцией обнаружения аномалий с действующей классификацией в работу сетей в режиме реального времени. В последнее время начаты работы по решению этой проблемы путем сочетания глубокого обнаружения аномалий на основе автоэнкодеров с кластеризацией в скрытом пространстве или контролируемой классификацией, что обеспечивает как надежное обнаружение выбросов, так и многоклассовую диагностику неисправностей.

III. МЕТОДОЛОГИЯ

Наша методология разработана для обеспечения надёжности и практичности обнаружения неисправностей в электросетях при реальном развертывании. Вдохновлённый последними достижениями в области обнаружения промышленных аномалий и энергетической аналитики, процесс состоит из четырёх основных этапов: предварительная обработка, временное моделирование, проектирование признаков в скрытом пространстве и многоклассовая классификация.

A. Предварительная обработка данных

Мы начинаем с сегментации необработанных данных PMU — измерений напряжения и потока мощности — на короткие перекрывающиеся временные окна. Каждое окно нормализуется с использованием масштабирования MinMax, чтобы все признаки вносили одинаковый вклад в процесс обучения. Чтобы снизить уровень шума и сосредоточиться на наиболее информативных аспектах данных, мы применяем метод главных компонент (PCA), сохраняя 95% исходной дисперсии согласно уравнению (1). Это не только сжимает данные, но и выделяет базовые закономерности, наиболее важные для различения нормального и неисправного поведения сети. Наш этап шумоподавления вдохновлён работой Ли и др. (2024), которые обнаружили, что такая предварительная обработка значительно повышает точность обнаружения аномалий в промышленных временных рядах.

Трансформация PCA

$$X_{PCA} = (X - \mu)W \quad (1)$$

где X — нормализованное окно, μ — среднее значение, а W содержит главные компоненты.

В. Предварительная подготовка шумоподавляющего автоэнкодера

Для дальнейшей очистки сигнала мы используем автоэнкодер прямого распространения, обученный восстанавливать окна, уменьшенные с помощью PCA. Этот шаг помогает модели изучить основную структуру нормального поведения сетки, отфильтровывая остаточный шум, который в противном случае мог бы скрыть едва заметные сигнатуры разломов. Выходные данные с шумоподавлением затем используются в качестве входных данных для нашей основной временной модели.

Потеря автоэнкодера

$$\mathcal{L}_{AE} = \frac{1}{N} \sum_{i=1}^N \|x_i - \hat{x}_i\| \quad (2)$$

где x_i это входное окно и $\hat{x}_i$ является его реконструкция.

С. Автоэнкодер LSTM для изучения временных закономерностей

Сердце нашего конвейера — автоэнкодер на основе LSTM, обучаемый исключительно на окнах, помеченных как «нормальные». Ячейки памяти LSTM позволяют ему фиксировать сложные временные зависимости, присутствующие в операциях с сеткой, определяя, как выглядит «нормальное» состояние с течением времени. Во время тестирования модель пытается реконструировать каждое входное окно. Если ошибка реконструкции для окна превышает пороговое значение (установленное на основе распределения ошибок в нормальных обучающих данных), окно помечается как аномальное.

Потеря автоэнкодера LSTM

$$\mathcal{L}_{LSTM-AE} = \frac{1}{N} \sum_{i=1}^N \|x_i - \hat{x}_i\|^2 \quad (3)$$

Этот неконтролируемый подход устойчив к непредвиденным типам неисправностей и не требует обширных маркированных наборов данных, что является ключевым преимуществом при мониторинге реальных сетей.

Д. Проектирование признаков скрытого пространства и многоклассовая классификация

Хотя автоэнкодер LSTM превосходно обнаруживает аномалии, он не указывает тип неисправности напрямую. Для решения этой проблемы мы извлекаем из энкодера скрытые векторы для всех окон — эти векторы служат сжатыми сводками временной модели каждого окна. Мы обогащаем эти скрытые векторы статистическими характеристиками (среднее значение, стандартное отклонение, асимметрия и эксцесс), вычисленными для каждого окна:

Объединение функций

$$z_i = [h_i | \text{mean}(x_i), \text{std}(x_i), \text{skew}(x_i), \text{kurt}(x_i)] \quad (4)$$

где h_i — скрытый вектор для окна i .

Для многоклассовой классификации неисправностей мы обучаем классификатор XGBoost на основе этих комбинированных признаков. XGBoost выбран благодаря своей способности обрабатывать многомерные табличные данные и подтвержденной

эффективности в задачах энергетической аналитики и диагностики неисправностей. Этот последний этап позволяет системе не только обнаружить неисправность, но и определить конкретный тип неисправности, например, вынужденные колебания, отключение генератора или повреждение линии, что позволяет операторам реагировать более эффективно.

IV. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

В этом разделе представлена эффективность предлагаемой платформы для обнаружения аномалий и многоклассовой классификации неисправностей с использованием данных PMU уровня передачи. Все эксперименты проводились на репрезентативном подмножестве набора данных PSML, при этом результаты были представлены как для бинарных, так и для многоклассовых настроек.

А. Эффективность обнаружения аномалий

Автоэнкодер LSTM, обученный исключительно на данных нормальной работы, был оценен на предмет его способности различать нормальные и аварийные окна на основе ошибки реконструкции. На рис. 1 показано распределение среднеквадратичной ошибки реконструкции (MSE) как для нормальных, так и для аварийных окон. Как и ожидалось, большинство нормальных окон имеют низкую ошибку реконструкции, в то время как аварийные окна, как правило, имеют более высокую ошибку, что подтверждает использование MSE реконструкции в качестве эффективного показателя аномалии.

Для выявления аномалий использовался порог, установленный на уровне 75-го перцентиля нормального распределения ошибок обучения. В таблице 1 представлены результаты бинарной классификации.

Общая точность модели составляет 72%, при этом точность и полнота сбалансированы как для нормальных, так и для неисправных классов. Разделение значений среднеквадратической ошибки (СКО) между нормальными и неисправными окнами наглядно показано на рис. 1.

В. Многоклассовая классификация

Чтобы различать различные типы неисправностей, латентные векторы из LSTM-кодера были объединены со статистическими признаками (среднее значение, стандартное отклонение, асимметрия, эксцесс) для каждого окна. Затем на этих признаках был обучен классификатор XGBoost для прогнозирования конкретного типа неисправности.

Матрица неточностей на рис. 2 иллюстрирует эффективность классификации по всем категориям неисправностей. Большинство классов хорошо разделены, хотя между некоторыми типами неисправностей сохраняется некоторая неточность, особенно для редких классов.

Визуализация латентного пространства с помощью t-SNE (рис. 3) показывает, что окна, относящиеся к одному типу неисправности, имеют тенденцию группироваться вместе, что указывает на информативность полученных представлений для классификации. Подробная информация о точности, полноте и F1-оценке для каждого класса представлена в табл. 2.




Рис. 1. Гистограмма средноквадратичной ошибки реконструкции для нормальных и разломных окон

ТАБЛИЦА I. РЕЗУЛЬТАТЫ ОБНАРУЖЕНИЯ ДВОИЧНЫХ АНОМАЛИЙ (НОРМАЛЬНЫЕ И НЕИСПРАВНЫЕ)

Сорт	Точность	Отзывать	Оценка F1
Нормальный	0,66	0,73	0,69
Вина	0,78	0,72	0,75
Точность			0,72




Рис. 2. Матрица путаницы для многоклассовой классификации неисправностей

С. Обсуждение

Эти результаты демонстрируют, что предлагаемый конвейер эффективно обнаруживает и классифицирует различные типы неисправностей в данных PMU. Сочетание PCA, шумоподавления с помощью автоэнкодера и временного моделирования на основе LSTM обеспечивает надежное обнаружение аномалий, а объединение латентных и статистических признаков способствует точной диагностике неисправностей в нескольких классах. Визуализация t-SNE дополнительно подтверждает дискриминационную способность полученных представлений.




Рис. 3. Визуализация t-SNE скрытого пространства, окрашенного в зависимости от типа неисправности

ТАБЛИЦА II. МНОГОКЛАССОВАЯ КЛАССИФИКАЦИЯ (XGBOOST НА СКРЫТЫХ И СКОНСТРУИРОВАННЫХ ФУНКЦИЯХ)

Сорт	Точность	Отзывать	Оценка F1
ФО	0,72	0,79	0,75
Branch_fault	0,97	0,8	0,88
Branch_trip	0,79	0,52	0,63
Bus_fault	1,00	0,28	0,43
Автобусная_поездка	0,79	0,48	0,60
Gen_trip	0,70	0,43	0,53
Нормальный	0,64	0,76	0,70
Точность			0,70

Несмотря на обнадеживающие результаты, некоторые типы неисправностей, для которых характерно очень мало примеров (например, bus_fault), остаются сложными, что отражается в более низких оценках полноты. Увеличение размера набора данных и изучение дополнительных возможностей проектирования признаков или настройки модели могут дополнительно повысить производительность.

V. ЗАКЛЮЧЕНИЕ

В данной статье представлена комплексная, основанная на данных платформа для обнаружения и диагностики неисправностей в режиме реального времени в системах управления электросетями с использованием данных PMU на уровне передачи. Благодаря сочетанию расширенной предварительной обработки, автоматического кодирования на основе LSTM и контролируемой классификации предлагаемый подход эффективно обнаруживает аномалии и различает различные типы неисправностей, включая вынужденные колебания, отключения генератора и неисправности линии.

Наши результаты показывают, что интеграция PCA и шумоподавления на основе автоэнкодера с моделированием временных последовательностей обеспечивает надежное обнаружение аномалий, а сочетание латентных и статистических признаков способствует точной многоклассовой классификации неисправностей. Система достигает высокой производительности даже при ограниченном наборе данных, что подтверждает ее потенциал для практического внедрения в средах мониторинга энергосистем.

Хотя текущая разработка обеспечивает прочную основу, дальнейшая работа будет сосредоточена на расширении набора данных, изучении дополнительных возможностей проектирования функций и исследовании передовых архитектур глубокого обучения для дальнейшего повышения точности диагностики неисправностей. Предлагаемая методология способствует развитию интеллектуальной обработки информации в режиме реального времени в современных системах управления энергосистемами.

СПИСОК ЛИТЕРАТУРЫ

- [1] Ли, Ю., Парк, К., Ким, Н., Ан, Дж. и Чонг, Дж. (2024). Обнаружение аномалий на основе LSTM-автоэнкодера с использованием данных о вибрации ветряных турбин // Датчики, 24(9), 2833.
- [2] Аннапаредди В.Н. и Рани, Приложения искусственного интеллекта и машинного обучения (ИИ) PRS для мониторинга и оптимизации энергопотребления в реальном времени для жилых солнечных энергосистем // Международный журнал по науке, математике и технологическому обучению, 32(2), 2024, стр. 305–323.
- [3] С. Джейкобс и К. П. Бин, «Мелкие частицы, тонкие пленки и анизотропия обмена», в книге «Магнетизм», т. III /под ред. Г.Т. Радо и Х. Сула. Нью-Йорк: Academic, 1963, стр. 271–350.
- [4] 18-я Международная конференция IEEE по машинному обучению и приложениям (ICMLA 2019), специальная сессия: Машинное обучение в энергетике. Бока-Ратон, Флорида, США, 2019 г.
- [5] Поравагамаге Г., Калана Д., Себастьян К.Дж., Дэниел В. и Атула Р. «Обзор приложений машинного обучения для защиты энергосистем и управления в аварийных ситуациях: возможности, проблемы и направления развития». *Frontiers in Smart Grids*, 2024.
- [6] Оэлхф, Й., Георг К., Андреас М., Йоханн Й. и Симинг Б. «Неконтролируемая кластеризация для анализа неисправностей в высоковольтных системах электроснабжения с использованием сигналов напряжения и тока». Препринт arXiv arXiv:2505.17763, 2025.
- [7] Давари Н., Сепиде П., Бруно В., Славомир Н., Юантао Ф., Педро М., Рита П. и Жоао Г. «Среда обнаружения неисправностей на основе автоэнкодера LSTM: пример использования набора данных автобусов Volvo». Портал ДиВА, 2022 г.