

Recurrent Neural Network-Based Autoencoder for Problems of Automatic Time Series Analysis at Power Facilities

Matrenin P.V.¹, Khalyasmaa A.I.¹, Potachits Y.V.²

¹Ural Federal University, Ekaterinburg, Russia

²Belarusian National Technical University, Minsk, Belarus

Abstract. Digitalization of the energy sector leads to an increase in the volume and rate of data collection. A primary barrier to the proper management of the technological data is the lack of data labeling corresponding to emergency modes, power equipment technical state, etc. Thus, despite the large amount of data, there is a shortage of labeled data suitable for training, validating and testing the machine learning models. Labeling by an expert takes too much time, so there is an actual task to automatically identify data fragments that are potentially of interest. The aim of the work is to develop an algorithm for prioritizing the fragments of the time series using the compact recurrent autoencoder. To achieve the goal, a neural network architecture was developed based on recurrent encoding and decoding cells, capable of unsupervised learning. The model was tested on two data sets: a synthetic sinusoidal signal with missing values and electric current measurements with thermal limit deviations. The substantial results of the work are the compact architecture of the autocoding model and the high interpretability of the output. The most significant achievements of the study are both the autocoding neural network model, which does not require initial assumption about the type of deviations, and the proposed algorithm for prioritizing the data fragments. The significance of the results is proved by the reduction of the time for analyzing and labeling large data arrays with technological parameters of the electrical networks, which allows using these data for training, validating and testing.

Keywords: autoencoder, time series processing, recurrent neural networks, operating parameters of electrical networks.

DOI: <https://doi.org/10.52254/1857-0070.2023.2-58-06>

UDC: 004.896

Autocodarea rețelei neuronale recurente pentru probleme de procesare automată a seriilor de timp la instalațiile energetice

Matrenin P.V.¹, Haliasmaa A.I.¹, Potaciț Ia.V.²

¹Universitatea Federală Ural, Ekaterinburg, Federația Rusă

²Universitatea Națională Tehnică din Belarus, Minsk, Republica Belarus

Rezumat. Digitalizarea complexului de combustibil și energie duce la creșterea volumului de date colectate de la instalațiile de energie electrică și a vitezei de acumulare a acestora, dar un obstacol în calea utilizării datelor mari care conțin măsurători de putere, curent și tensiune este lipsa marcajului în datele care conțin informații despre modurile de funcționare de urgență, starea tehnică a echipamentului, anomalii. Scopul lucrării este de a elabora o metodă pentru îmbunătățirea eficienței marcajului seriilor de timp în problemele industriei energetice prin prioritizarea fragmentelor de serii temporale folosind modelul propus de autoencoder compact recurent. Pentru a atinge scopul, a fost elaborată o arhitectură de rețea neuronală bazată pe celule de codificare și decodare recurente, capabile să învețe fără profesor (fără date marcate) și testată pe două seturi de date: un semnal sinusoidal sintetic cu valori lipsă și măsurători curente în o secțiune a unei rețele electrice, care conține valori de exces de curent pe termen scurt. Deosebirea lucrării este arhitectura simplificată a modelului de autocodare recurentă și interpretabilitatea ridicată a valorilor de ieșire rezultate. Cele mai semnificative rezultate sunt modelul unei rețele neuronale cu autocodare pentru detectarea automată a abaterilor în serii de timp fără a se forma o ipoteză inițială despre tipul abaterilor, algoritmul propus pentru utilizarea modelului pentru prioritizarea analizei și etichetării fragmentelor de serie de timp în probleme. a industriei energiei electrice. Semnificația rezultatelor constă în faptul că metoda propusă face posibilă reducerea semnificativă a timpului de analiză și marcarea rețelelor mari de serii temporale care conțin date digitale ale parametrilor de funcționare ai rețelelor electrice.

Cuvinte-cheie: autoencoder, procesare serii de timp, rețele neuronale recurente, parametrii de regim ai rețelelor electrice.

Автокодирующая рекуррентная нейронная сеть для задач автоматизации анализа временных рядов на объектах энергетики

Матренин П.В.¹, Хальясмаа А.И.¹, Потачиц Я.В.²

¹Уральский федеральный университет, Екатеринбург, Российская Федерация

²Белорусский национальный технический университет, Минск, Республика Беларусь

Аннотация. Цифровизация топливно-энергетического комплекса приводит к увеличению объема собираемых с объектов электроэнергетики цифровых данных и скорости их накопления, но препятствием для использования больших данных, содержащих измерения мощности, тока и напряжения, является отсутствие в данных разметки, содержащих сведения об аварийных режимах работы, техническом состоянии оборудования, аномалиях. Таким образом, несмотря на большой объем данных, сохраняется дефицит размеченных данных, пригодных для обучения, валидации и тестирования моделей на базе машинного обучения. Разметка таких объемов данных экспертом занимает слишком много времени, поэтому актуальной задачей является автоматическая идентификация в данных фрагментов, которые потенциально представляют наибольший интерес. Целью работы является разработка метода приоритизации фрагментов временных рядов с помощью предложенной модели компактного рекуррентного автокодировщика для автоматизации их анализа и разметки данных на объектах электроэнергетики. Для достижения цели была разработана архитектура нейронной сети на базе рекуррентных ячеек кодирования и декодирования, способная обучаться без учителя, и апробирована на двух наборах данных: синтетическом синусоидальном сигнале с пропущенными значениями и измерениях тока на участке электрической сети, содержащих кратковременные превышения значений тока. Отличием работы является компактная архитектура рекуррентной автокодирующей модели и высокая интерпретируемость получаемых выходных значений. Наиболее существенными результатами являются модель автокодирующей нейронной сети для автоматического выявления отклонений во временных рядах без формирования изначального предположения о виде отклонений и предложенный алгоритм использования разработанной модели для приоритизации анализа и разметки фрагментов временных рядов в задачах электроэнергетики. Значимость результатов заключается в том, что предложенный метод позволяет существенно сократить время на анализ и разметку больших массивов временных рядов, содержащих данные режимных параметров электрических сетей, что позволит использовать эти данные для обучения, валидации и тестирования моделей.

Ключевые слова: автокодировщик, обработка временных рядов, рекуррентные нейронные сети, режимные параметры электрических сетей.

ВВЕДЕНИЕ

А. Использование неразмеченных измерений мощности, тока и напряжения в электроэнергетических системах

Цифровизация топливно-энергетического комплекса приводит к увеличению объема собираемых с объектов энергетики данных. Внедрение цифровых счетчиков электроэнергии, устройств синхронизированных векторных измерений, Phasor Measurement Unit (PMU) [1-3] и цифровых подстанций [4, 5] приводят к формированию больших массивов цифровых данных, как и развитие возобновляемой энергетики и распределенной генерации [6, 7].

Данные, содержащие значения потребляемой и генерируемой мощности, тока и напряжения, могут быть использованы для решения различных задач: управление энергосистемами, диагностика состояния электрооборудования, обнаружение аварий.

Большой объем данных позволил применить методы машинного обучения для высокоэффективного решения задач во многих областях [8, 9], но существенным препятствием

для использования больших данных в электроэнергетике является отсутствие в них разметки [3, 10]. Накапливается большой объем неразмеченных данных, которые не могут быть использованы для без решения проблемы анализа неразмеченных данных, поскольку для задач обнаружения неисправностей или оценки технического состояния высоковольтного оборудования наиболее эффективны алгоритмы машинного обучения с учителем, требующие размеченных данных [11].

Можно выделить следующие подходы к решению данной проблемы: методы обучения с частичным привлечением учителя (semi-supervised learning); кластерный анализ, автокодировщики и другие методы обучения без учителя (unsupervised learning); генерация синтетических данных.

Обучение с частичным привлечением учителя позволяет работать с данными, в которых размечена лишь небольшая часть. При наличии размеченной части выборки можно обучить модель на этих данных, затем использовать модель для получения авторазметки. В работе [12] такой метод используется для анализа графиков электропотребления, в работе

[13] частичное обучение применено для детектирования нетехнологических потерь электроэнергии. Применение частичного обучения для обнаружения неисправностей описано в статье [14]. Недостатком является необходимость иметь очень точную разметку для части данных. В задачах мониторинга электрооборудования и электрических сетей всегда присутствует сильный дисбаланс классов, примеров данных, относящихся к авариям, очень мало, поскольку это редкие события. Статистически они могут рассматриваться как отклонения от нормального состояния или выбросы. Поэтому формирование авторазметки для редких классов может иметь высокую погрешность, что не позволит применять полученные модели с достаточной степенью уверенности в их надежности.

Кластерный анализ относится к обучению без учителя и не требует разметки. В работах [15, 16] кластеризация применяется для обнаружения провалов напряжения. Использование кластеризации измерений тока и напряжения для анализа состояния и управления регуляторами распределенной киберфизической системы описано в статье [17]. Особенностью применения кластерного анализа является необходимость последующей интерпретации полученных результатов, так как нет гарантии, что ситуации, связанные с неисправностями, попадут в одни кластеры, а прочие ситуации в другие. В результате экономия трудозатрат за счет отказа от разметки данных частично компенсируется на этапе анализа результатов модели.

Генерация новых размеченных данных на основе имеющихся является подходом, успех которого в ряде областей обеспечен применением генеративно-сопоставительных нейронных сетей (ГСНС) [18, 19]. Подход заключается в обучении двух конкурирующих моделей, одна из которых стремится генерировать синтетические данные, статистически соответствующие заданной выборке данных, а вторая – отличать синтетические данные от реальных [20]. Применение глубоких ГСНС для заполнения пропущенных данных векторных измерений для обнаружения предварийных ситуаций в электрической сети описано в статье [21]. В статье [22] генеративно-сопоставительная модель использована для генерации большого массива данных PMU для исследовательских или образовательных целей. При этом следует

особое внимание уделять сохранению в синтетических данных физического смысла, присущего процессам в электрических сетях [23, 24].

Хотя применением генеративно-сопоставительных нейронных сетей представляется наиболее перспективным направлением решения указанной проблемы, для каждого частного объекта требуется разметка достаточного объема данных для запуска процесса генеративно-сопоставительного процесса и обучение глубоких нейронных сетей. Несмотря на развитие инструментов для работы с нейронными сетями, создание такой модели является сложной исследовательской задачей. Кроме того, нерешенным остается вопрос надежности и безопасности применения моделей, обученных не на реальных данных.

В. Автокодирующие нейронные сети

Особым направлением обучения без учителя является использование автокодирующих (autoencoder) – особой архитектуры нейронных сетей, которые обучаются так, чтобы результаты на выходе сети были как можно ближе к входным данным [25]. За счет того, что объем данных, который может быть передан между скрытыми слоями, намного меньше объема данных во входных экземплярах, автокодирующий стремится закодировать входные данные, сжимая их, чтобы затем декодировать (восстановить). Кодировщик стремится преобразовать пространство входных данных в пространство меньшей размерности с минимальной потерей информации. Если входной экземпляр является выбросом, то автокодирующий с высокой вероятностью восстановит его с высокой погрешностью [26-32].

Применению автокодирующего для выявления выбросов во временных рядах посвящено большое число работ. В настоящее время наибольшее внимание исследователей в данной области привлечено к обработке многомерных временных рядов, поэтому рассматриваются глубокие нейронные сети, в которых часть, отвечающая за автокодирование, не является наиболее важной и сложной.

Так, в статьях [26-30] используются модели на базе сверточных нейронных сетей CNN (Convolutional Neural Networks), ConvLSTM (Convolutional Long Short-Term Memory) для обнаружения выбросов в данных о работе киберфизических систем и систем на базе Интернета вещей [26, 27, 31], оптических данных [28], данных о работе промышленных роботов

[29] и показаний вибро- и акустических датчиков с вращающихся машин [32].

Применение автокодировщика для диагностики неисправностей электрооборудования по таким сигналам как вибрация, ток и углы поворота приведено в работах [30-35]. В них данные тока и напряжения используются как дополнительные или не используются, а более информативными оказываются данные, которые сильнее коррелируют с характеристиками физических процессов. Существенно меньше число исследований, направленных на анализ временных рядов тока, напряжения и мощности как основного источника данных [36-40].

В работе [36] автокодировщик применен для кластеризации потребления электроэнергии (без выделения выбросов). Автокодировщик для очищения данных от шума и последующей классификации данных, в том числе аномалий в графиках электропотребления, представлен в [37].

Векторные измерения тока и напряжения используются в работе [38] для обнаружения кибератак, связанных с подменой данных. При этом используется глубокая нейронная сеть и переход от исходных сигналов тока и напряжения в специализированное пространство статистических признаков. Глубокий автокодировщик на базе нейронной сети временной свертки для классификации возмущений в сигналах PMU предложен в работе [39]. Представленные в данных работах модели специализированы под конкретные области применения и имеют высокую сложность.

В статье [40] проводится сравнение автокодировщика с моделью на базе метода главных компонент и метода опорных векторов в задаче обнаружения опасных событий в распределительной электрической сети. Хотя использование в качестве автокодировщика лишь одного нейрона свидетельствует о том, что метод не в полной мере учитывает особенности, присущие временным рядам.

Анализ существующих исследований показывают актуальность работ, направленных на применение автокодировщиков для анализа неразмеченных данных PMU. Во-первых, использование рекуррентных нейронных сетей в качестве автокодировщиков не в полной мере изучено для обработки измерений мощности, тока и напряжения. Во-вторых, не рассматривается изначальная проблема – каким образом можно повысить безопасность применения моделей машинного обучения, построенных на неразмеченных данных.

Наиболее важным вопросом, на который обращено недостаточное внимание, является вопрос доверия к результатам, полученным на неразмеченных данных. Автокодировщики демонстрируют относительно высокую эффективность, но они обучаются для каждого частного случая, а результаты успешных применений публикуют на порядок чаще, чем неудачных. В результате точность автокодировщика невозможно протестировать без разметки. Для действительно безопасного применения машинного обучения в задачах энергетики анализ данных специалистами и разметка данных являются необходимыми этапами. Поэтому в работе предложен новый метод для применения автокодировщика на базе рекуррентной нейронной сети для разметки больших объемов неразмеченных данных.

Целью работы является разработка метода приоритизации фрагментов временных рядов с помощью предложенной модели компактного рекуррентного автокодировщика для автоматизации их анализа и разметки данных на объектах электроэнергетики. Отличием работы является упрощенная архитектура рекуррентной автокодирующей сети, универсальность за счет применения к неразмеченным данным без необходимости без формирования изначального предположения о виде отклонений и интерпретируемость результатов модели, поскольку она расставляет приоритеты фрагментам временного ряда для анализа и позволяет затем визуально и численно сравнить отобранные фрагменты с результатами их кодирования-декодирования.

II. МЕТОДЫ ИССЛЕДОВАНИЯ

A. Предложенный метод

Автокодировщик имеет следующую функцию потерь, которая используется при обучении:

$$L(\varphi, \theta) = \frac{1}{n} \sum_{i=1}^n \Delta X, \quad (1)$$

$$\Delta X = \frac{1}{l} \sum_{j=1}^l (f_{\theta}(g_{\varphi}(X_i) - X_i)_j)^2, \quad (2)$$

где L – функция потерь, φ – обучаемые параметры кодирующей части модели, θ – обучаемые параметры декодирующей части, f_{θ} – декодировщик, g_{φ} – кодировщик, X – входной экземпляр (фрагмент), l – его длина.

Минимизация функции потерь в процессе обучения приводит к тому, что пара f_{θ} , g_{φ} образуют аппроксимацию $f_{\theta}(g_{\varphi}(X_i))$, которая для

каждого X_i дает его приближенное значение X'_i . Из-за того, что размерность $g_\varphi(X_i)$ меньше размерности X_i , отклонение ΔX является случайной величиной. Таким образом, приведенная в выражении (1) функция потерь является средним значением данной величины для всей обучающей выборки данных. Схема работы автокодировщика приведена на Рисунке 1.




Рис.1. Принципиальная схема автокодировщика

X_i – входные данные, $X_{n,i}$ – нормализованные входные данные, $X'_{n,i}$ – нормализованные выходные данные, ΔX – отклонение.

Fig.1. An autoencoder schematic diagram:

X_i – input data, $X_{n,i}$ – normalized input data, $X'_{n,i}$ – normalized output data, ΔX – difference.

Использование автокодировщика для выявления выбросов в данных основано на том, что минимизация функции потерь $L(\varphi, \theta)$ выполняется на основе обработки всех фрагментов обучающей выборки с построением аппроксимации $f_\theta(g_\varphi(X))$, поэтому выбросы (редкие события во временном ряду) оказывают малое влияние на полученные параметры φ, θ . В то же время выбросы характеризуются отличным от остальных фрагментов закономерностями между элементами вектора признаков X . В результате отклонение ΔX для выбросов принимает большее значение, чем для остальных фрагментов.

В. Рекуррентный автокодировщик

В отличие от приведенные выше работ, использующих модели на базе глубокого обучения и сверточных рекуррентных нейронных сетей [26-30], в данном исследовании рассмат-

риваются намного более простые рекуррентные модели, в которых кодирование g_θ и декодирование f_φ выполняется однослойными рекуррентными блоками. Архитектура модели приведена на Рисунке 2.

Гиперпараметры модели: вид рекуррентных ячеек, число слоев кодировщика, число слоев декодировщика, число признаков скрытого состояния (hidden state size). Последний гиперпараметр равен размерности закодированной последовательности $Z = g_\theta(X)$ (скрытое состояние рекуррентной модели, которое передается от кодировщика и декодировщику), то есть числу элементов в векторе Z . В результате вычислительных экспериментов число признаков скрытого состояния было выбрано равным 16.

В настоящее время наиболее часто применяются обычные рекуррентные ячейки с одним блоком памяти, рекуррентные ячейки долговременной краткосрочной памяти LSTM [41] и управляемые рекуррентные ячейки GRU [42]. Результаты их сравнения приведены ниже.

Для обучения модели был использован алгоритм обучения Adam с шагом обучения $5 \cdot 10^{-4}$, размером мини-пакета, равным четырем, и эвристикой “Teacher forcing” [43, 44]. В качестве функции потерь при обучении используется $L(\varphi, \theta)$ из выражения (1).

Программная реализация выполнена на основе фреймворка с открытым исходным кодом Pytorch. Код для формирования модели и реализации процесса обучения создан на основе репозитория [44].

III. РЕЗУЛЬТАТЫ

А. Метод приоритезации анализа и разметки фрагментов временных рядов

Используется следующая последовательность действий.

1. Выбор длительности временного окна (фрагмента временного ряда), кратной периодичности входного сигнала. Фрагмент может длиться m периодов.

2. Формирование матрицы D , содержащей фрагменты временного ряда. Временной ряд из s отсчетов с периодичностью c отсчетов, будет преобразован в k пересекающихся фрагментов (пересечение равно длительности периода):

$$k = \frac{s}{c} - m, \tag{3}$$

$$X_i = D[i \cdot c : (i + m) \cdot c], i = 0, 1, \dots, k \tag{4}$$

3. Нормализация данных с помощью линейной Min-Max нормализации:

$$X^n = (X - \min(D)) / (\max(D) - \min(D)), \quad (5)$$

$$n = 1, 2, \dots, s$$

4. Разделение X на две равные части случайным образом. Обучение автокодировщика на первой части и применение на второй с сохранением результатов для каждого фрагмента второй части.

5. Замена частей местами и выполнение той же процедуры, что описана в шаге 4. Это необходимо, чтобы получать оценки отклонений не на той части выборки, на которой обучалась модель.

6. Ранжирование фрагментов по убыванию отклонения ΔX .

7. Визуализация, анализ и разметка первых w фрагментов в ранжированной последовательности.

Описанная выше задача обучения автокодировщика с минимизацией функции $L(\varphi, \theta)$ направлена на решение задачи следующего вида:

$$Y_{ab}(\varphi, \theta) : \Delta X_a(\varphi, \theta) > \Delta X_b(\varphi, \theta),$$

$$V_{ab} : a - \text{выброс}, b - \text{не выброс}, \quad (6)$$

$$\varphi^*, \theta^* = \arg \max(P(Y_{ab} | V_{ab})),$$

где Y_{ab}, V_{ab} – события; $P(Y_{ab}|V_{ab})$ – вероятность того, что если фрагмент a является выбросом, а фрагмент b нет, то отклонение ΔX_a окажется

больше, чем отклонение ΔX_b ; φ^*, θ^* – искомые обучаемые параметры модели.

Величину ΔX можно использовать как количественную оценку приоритета, который нужно отдать фрагменту при анализе и разметке. В результате потенциально аномальные ситуации будут проверены в первую очередь. Если они представляют собой ошибки или искажения при сборе данных, то они будут исключены из выборки. Если же это редкие ситуации, то они будут размечены, а среди прочих данных размечать можно будет лишь некоторую часть. После этого применять описанные выше подходы: обучение с частичным привлечением учителя или ГСНС.

В. Пример обнаружения пропусков

Первый рассмотренный пример представляет собой обнаружение пропусков в синтетическом сигнале, сгенерированном с помощью функции:

$$X(t) = \sin(2t) + \varepsilon(t), \quad (7)$$

где ε – шум, распределенный по нормальному закону распределения с математическим ожиданием 0 и среднеквадратическим отклонением 0,2.

Сигнал сгенерирован для 5 тысяч отсчетов с шагом 0,016л. В шести случайно выбранных интервалах длительностью 40 отсчетов внесена имитация потерь сигнала, $X(t) = 0$. Фрагмент полученного сигнала показан на Рисунке 3.




Рис.2. Архитектура рекуррентного автокодировщика

t – индекс начала фрагмента временного ряда, Z – закодированное представление данных, RNN – рекуррентный слой нейронной сети (RNN, LSTM или GRU).

Fig.2. The architecture of the recurrent autoencoder:

t – start index of the time series fragment, Z – encoded data representation, RNN – recurrent neural network layer (RNN, LSTM or GRU).

Ширина окна для анализа выбрана равной двум периодам синусоиды.

Независимо от выбора вида рекуррентных ячеек, все потери сигнала были определены – они получили наибольшие приоритеты для анализа, намного превышающие приоритеты фрагментов сигнала, не содержащих потери. Примеры выявленных фрагментов с потерями сигнала приведены на Рисунках 4 и 5, пример фрагмента сигнала без потерь – на Рисунке 6.

С. Пример обнаружения пиков тока на участке электрической сети

Во втором примере используется набор данных PMU, собранных с реальной подстанции 110/35/10 кВ. Особенность установленной системы измерения заключается в том, что она записывает в базу данных сигналы тока и напряжения с высокой частотой дискретизации по времени (128 значений за 0,02 секунды), но в течение только одного периода промышленной частоты 50 Гц каждые 3 минуты. Поэтому сигнал оказывается прерывистым, на стыках синусоид возникают искажения сигнала, препятствующие его анализу. В рассматриваемой выборке в сигнале присутствуют кратковременные превышения тока, которые и являются целевыми для детектирования. Общая длительность наблюдений составляет одни сутки.

Среднее время обучения для RNN, LSTM, GRU ячеек составило 203, 344 и 293 секунды, соответственно. В отличие от первого примера ячейкам RNN не удалось обучиться выявлению паттерна с достаточной точностью для выявления требующих анализа фрагментов данных. LSTM и GRU ячейки показали одинаковую точность, поставив наивысший приоритет фрагментам с повышенным значением тока.

В Таблице 1 приведены полученные значения ΔX для фрагментов с превышениями тока и без них. Для трех приведенных в Таблице 1 примеров фрагменты сигнала и результаты кодирования-декодирования представлены на Рисунках 7, 8 и 9. На Рисунках 7 и 8 показаны фрагменты с наибольшими отклонениями, на Рисунке 9 приведен фрагмент сигнала с низким значением приоритета, что означает что модель посчитала его типичным. Видно, что на Рисунке 9 выход модели близок к исходному сигналу.

Таблица 1
Значения ΔX для фрагментов временного ряда с превышением тока и без превышения.

Table 1
 ΔX values for fragments of the time series with and without overcurrent.

№ фрагмента Fragment's ID	Превышение тока Overcurrent	ΔX
143	да yes	2822,24
45	да yes	2443,83
215	да yes	1851,26
83	да yes	1796,35
69	нет no	276,12
13	нет no	240,35
247	нет no	206,94
209	нет no	167,62




Рис.3. Фрагмент сигнала с потерями.
Fig.3. A signal fragment with losses.




Рис.4. Пример выявленного фрагмента сигнала с потерями.

Fig.4. An example of signal fragment with losses.




Рис.5. Фрагмент сигнала с потерями.

Fig.5. Signal fragment with losses.




Рис.6. Фрагмент сигнала без потерь.

Fig.6. Signal fragment without losses.




Рис.7. Фрагмент сигнала тока № 143.

Fig.7. Signal fragment of current ID 143.




Рис.8. Фрагмент сигнала тока № 45.

Fig.8. Signal fragment of current ID 45.




Рис.9. Фрагмент сигнала тока № 247.

Fig.9. Signal fragment of current ID 247.

IV. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Проведенные вычислительные эксперименты как на реальных данных тока участка электрической сети, так и на синтетических данных с потерями показали, что предложенный метод позволяет приоритезировать фрагменты временного ряда с точки зрения необходимости их анализа экспертом для выявления отклонений, свидетельствующих об аварийных режимах, ошибках в данных, других отклонениях, представляющих интерес при анализе данных.

Метод может быть использованы для выявления выбросов различных видов: пропущенные значения, ошибки в данных, выбросы, редкие ситуации. Такое свойство достигается за счет небольшой размерности модели, что отличает ее от аналогов [26-31], и снижает риск переобучения. Кроме того, не требуется настраивать гиперпараметры модели, что повышает скорость получения результатов с ее использованием.

Исследование показано, что для решаемой задачи более точные результаты дают рекуррентные ячейки LSTM и GRU. Процесс обучения автокодировщика, использующего LSTM или GRU, занимает в 1,7 раз больше времени,

чем автокодировщика на ячейках RNN. Однако за счет простой архитектуры моделей обучение проходит за минуты без использования графических процессоров.

Необходимо подчеркнуть, что модели обучались на неразмеченных данных, то есть в процессе обучения им не ставилась задача детектировать определенные выбросы. Более того, в предложенном методе модель не стремится решить задачу классификации и отделить определенные выбросы от всего остального сигнала, как в аналогичных работах по анализу сигналов тока и напряжения. Разработанная модель расставляет приоритеты всем фрагментами временного ряда, по которым затем необходимо выполнить анализ. При этом ситуации с искажениями получают наиболее высокий приоритет.

Для анализа сигнала разработанной моделью достаточно использовать временное окно, охватывающее два периода главной частоты сигнала.

ЗАКЛЮЧЕНИЕ

Проведено исследование применимости компактных двухслойных автокодирующих рекуррентных нейросетевых моделей для задачи анализа и разметки временных рядов, содержащих значения режимных параметров электрических сетей. Разработана модель, способная обучаться без размеченных данных, ее работа проанализирована на двух наборах данных: синтетическом синусоидальном сигнале с пропущенными значениями и измерениях тока на реальном участке электрической сети, содержащих кратковременные превышения значений тока.

Метод не требует формирования изначального предположения о виде отклонений и способен существенно сократить время на анализ и разметку больших массивов временных рядов.

ACKNOWLEDGEMENTS

Работа выполнена в рамках государственного задания при финансовой поддержке Министерства науки и высшего образования Российской Федерации (тема № FEUZ-2022-0030 Разработка интеллектуальной мультиагентной системы для моделирования глубоко интегрированных технологических систем в электроэнергетике).

Литература (References)

[1] Zhang L., et al. Voltage and Current Response Characteristics of PMU Device by PCI Simulation. 2022 *IEEE International Conference on*

High Voltage Engineering and Applications (ICHVE), 2022, pp. 1-4. doi: 10.1109/ICHVE53725.2022.9961637

- [2] Kummerow A., Monsalve C., Brosinsky C., Nicolai S., Westermann D. A Novel Framework for Synchrophasor Based Online Recognition and Efficient Post-Mortem Analysis of Disturbances in Power Systems. *Applied Science*, 2020, vol. 10, 5209. doi: 10.3390/app10155209
- [3] Aligholian A., Shahsavari A., Stewart E. M., Cortez E., Mohsenian-Rad H. Unsupervised Event Detection, Clustering, and Use Case Exposition in Micro-PMU Measurements. *IEEE Transactions on Smart Grid*, 2021, vol. 12, no. 4, pp. 3624-3636. doi: 10.1109/TSG.2021.3063088
- [4] Mathebula V. C., Saha A. K. Impact of Quality of Repairs and Common Cause Failures on the Reliability Performance of Intra-Bay IEC 61850 Substation Communication Network Architecture Based on Markov and Linear Dynamical Systems. *IEEE Access*, 2021, vol. 9, pp. 112805-112820. doi: 10.1109/ACCESS.2021.3104020
- [5] Mathebula V. C., Saha A. K. Mission critical safety functions in IEC-61850 based substation automation system—A reliability review. *International Journal of Energy Research in Africa*, 2020, vol. 48, pp. 149-161. doi: 10.4028/www.scientific.net/JERA.48.149
- [6] Li Z., Chen Z., Gao X., Wang S., Di F., Ye R. The Fast Simulation Architecture Construction for Integrated Electric Transmission and Distribution Power Grid Based On Big Data Platform. 2021 *China International Conference on Electricity Distribution (CICED)*, 2021, pp. 484-489. doi: 10.1109/CICED50259.2021.9556785
- [7] Ambia M.N., Al-Durra A., Caruana C., Muyeen S.M. Power management of hybrid micro-grid system by a generic centralized supervisory control scheme. *Sustainable Energy Technologies and Assessments*, 2014, vol. 8, pp. 57-65.
- [8] Lv Z., Song H., Basanta-Val P., Steed A., Jo M. Next-Generation Big Data Analytics: State of the Art, Challenges, and Future Research Topics. *IEEE Transactions on Industrial Informatics*, 2017, vol. 13, no. 4, pp. 1891-1899. doi: 10.1109/TII.2017.2650204
- [9] Singh N., Lai K.-H., Vejvar M., Cheng T.C.E. Big Data Technology: Challenges, Prospects, and Realities. *IEEE Engineering Management Review*, 2019, vol. 47, no. 1, pp. 58-66. doi: 10.1109/EMR.2019.2900208
- [10] Zhao J., Ding Y., Zhai Y., Jiang Y., Zhai Y., Hu M. Explore unlabeled big data learning to online failure prediction in safety-aware cloud environment. *Journal of Parallel and Distributed Computing*, 2012, vol. 153, pp. 53-63. doi: 10.1016/j.jpdc.2021.02.025
- [11] Mantach S., Lutfi A., Moradi Tavasani H., Ashraf A., El-Hag, A., Kordi B. Deep Learning in High

- Voltage Engineering: A Literature Review. *Energies*, 2022, vol. 15, 5005. doi: 10.3390/en15145005
- [12] Han Y., Li K., Feng H., Zhao Q. Non-intrusive load monitoring based on semi-supervised smooth teacher graph learning with voltage-current trajectory. *Neural Computing and Application*, 2022, vol. 34, pp. 19147–19160. doi: 10.1007/s00521-022-07508-7
- [13] Lu X., Zhou Y., Wang Z., Yi Y., Feng L., Wang F. Knowledge Embedded Semi-Supervised Deep Learning for Detecting Non-Technical Losses in the Smart Grid. *Energies*, 2019, vol. 12, 3452. doi: 10.3390/en12183452
- [14] Zhao Y., Ball R., Mosesian J., de Palma J. -F., Lehman B. Graph-Based Semi-supervised Learning for Fault Detection and Classification in Solar Photovoltaic Arrays. *IEEE Transactions on Power Electronics*, 2015, vol. 30, no. 5, pp. 2848-2858. doi: 10.1109/TPEL.2014.2364203
- [15] Hao C., Jin J. Clustering Analysis of Voltage Sag Events Based on Waveform Matching. *Processes* 2022, vol. 10, 1337. doi: 10.3390/pr10071337
- [16] Garcia-Sánchez T., Gómez-Lázaro E., Muljadi E., Kessler M., Muñoz-Benavente I., Molina-García A. Identification of linearised RMS-voltage dip patterns based on clustering in renewable plants. *IET Generation Transmission Distribution*, 2018, vol. 12, pp. 1256-1262.
- [17] Abegaz B., Kueber J. Smart Control of Automatic Voltage Regulators using K-means Clustering. *2019 14th Annual Conference System of Systems Engineering (SoSE)*, 2019, pp. 328-333. doi: 10.1109/SYSE.2019.8753873
- [18] Creswell A., White T., Dumoulin V., Arulkumaran K., Sengupta B., Bharath A.A. Generative Adversarial Networks: An Overview. *IEEE Signal Processing Magazine*, 2018, vol. 35, no. 1, pp. 53-65. doi: 10.1109/MSP.2017.2765202
- [19] Wang K., Gou C., Duan Y., Lin Y., Zheng X., Wang F. -Y. Generative adversarial networks: introduction and outlook. *IEEE/CAA Journal of Automatica Sinica*, 2017, vol. 4, no. 4, pp. 588-598, doi: 10.1109/JAS.2017.7510583
- [20] Goodfellow I., et al., Generative Adversarial Nets. *Advances in Neural Information Processing Systems 27 (NIPS 2014)*, 2014, pp. 2672-2680.
- [21] Ren C., Xu Y. A Fully Data-Driven Method Based on Generative Adversarial Networks for Power System Dynamic Security Assessment With Missing Data. *IEEE Transactions on Power Systems*, 2019, vol. 34, no. 6, pp. 5044-5052. doi: 10.1109/TPWRS.2019.2922671
- [22] Zheng X., Wang B., Xie L. Synthetic Dynamic PMU Data Generation: A Generative Adversarial Network Approach. *2019 International Conference on Smart Grid Synchronized Measurements and Analytics (SGSMA)*, 2019, pp. 1-6, doi: 10.1109/SGSMA.2019.8784681
- [23] Zheng X., Wang B., Kalathil D., Xie L., Generative Adversarial Networks-Based Synthetic PMU Data Creation for Improved Event Classification. *IEEE Open Access Journal of Power and Energy*, 2012, vol. 8, pp. 68-76. doi: 10.1109/OAJPE.2021.3061648
- [24] Yang Y., McLaughlin K., Gao L., Sezer S., Yuan Y., Gong Y. Intrusion detection system for IEC 61850 based smart substations. *2016 IEEE Power and Energy Society General Meeting (PESGM)*, 2016, pp. 1-5. doi: 10.1109/PESGM.2016.7741668
- [25] Kingma D.P., Welling M. Auto-Encoding Variational Bayes. Available at: <https://arxiv.org/abs/1312.6114> (accessed 02.01.2023).
- [26] Meng C. Jiang X.S., Wei X.M., Wei T. A Time Convolutional Network Based Outlier Detection for Multidimensional Time Series in Cyber-Physical-Social Systems. *IEEE Access*, 2020, vol. 8, pp. 74933-74942. doi: 10.1109/ACCESS.2020.2988797
- [27] Nizam H., Zafar S., Lv Z., Wang F., Hu X. Real-Time Deep Anomaly Detection Framework for Multivariate Time-Series Data in Industrial IoT. *IEEE Sensors Journal*, 2022, vol. 22, no. 23, pp. 22836-22849. doi: 10.1109/JSEN.2022.3211874
- [28] Yokkampon U., Mowshowitz A., Chumkamon S., Hayashi E. Robust Unsupervised Anomaly Detection with Variational Autoencoder in Multivariate Time Series Data. *IEEE Access*, 2022, vol. 10, pp. 57835-57849. doi: 10.1109/ACCESS.2022.3178592.
- [29] Yu J., Liu X., Ye L. Convolutional Long Short-Term Memory Autoencoder-Based Feature Learning for Fault Detection in Industrial Processes. *IEEE Transactions on Instrumentation and Measurement*, 2012, vol. 70, 3505615. doi: 10.1109/TIM.2020.3039614
- [30] Dewangan G., Maurya S. Fault Diagnosis of Machines Using Deep Convolutional Beta-Variational Autoencoder. *IEEE Transactions on Artificial Intelligence*, 2022, vol. 3, no. 2, pp. 287-296. doi: 10.1109/TAI.2021.3110835
- [31] Yin C., Zhang S., Wang J., Xiong N.N. Anomaly Detection Based on Convolutional Recurrent Autoencoder for IoT Time Series. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2022, vol. 52, no. 1, pp. 112-122. doi: 10.1109/TSMC.2020.2968516
- [32] Chen T., Liu X., Xia B., Wang W., Lai Y. Unsupervised Anomaly Detection of Industrial Robots Using Sliding-Window Convolutional Variational Autoencoder. *IEEE Access*, 2020, vol. 8, pp. 47072-47081. doi: 10.1109/ACCESS.2020.2977892
- [33] Shimizu M., Perinpanayagam S., Namoano B. A Real-Time Fault Detection Framework Based on Unsupervised Deep Learning for Prognostics and

- Health Management of Railway Assets. *IEEE Access*, 2022, vol. 10, pp. 96442-96458. doi: 10.1109/ACCESS.2022.3205352
- [34] Huang Y., Chen C. -H., Huang C. -J. Motor Fault Detection and Feature Extraction Using RNN-Based Variational Autoencoder. *IEEE Access*, 2019, vol. 7, pp. 139086-139096. doi: 10.1109/ACCESS.2019.2940769
- [35] Chadha G.S., Islam I., Schwung A., Ding S.X. Deep Convolutional Clustering-Based Time Series Anomaly Detection. *Sensors*, 2021, vol. 21, 5488. doi: 10.3390/s21165488
- [36] Zheng K., Yang J., Gong Q., Zhou S., Zeng L., Li S. Multivariate Extreme Learning Machine Based AutoEncoder for Electricity Consumption Series Clustering. *IEEE Access*, 2021, vol. 9, pp. 148665-148675. doi: 10.1109/ACCESS.2021.3124009
- [37] Zhao Q., Chang Z., Min G. Anomaly Detection and Classification of Household Electricity Data: A Time Window and Multilayer Hierarchical Network Approach. *IEEE Internet of Things Journal*, 2022, vol. 9, no. 5, pp. 3704-3716. doi: 10.1109/IJOT.2021.3098735
- [38] Wang J., Shi D., Li Y., Chen J., Ding H., Duan X. Distributed Framework for Detecting PMU Data Manipulation Attacks With Deep Autoencoders. *IEEE Transactions on Smart Grid*, 2019, vol. 10, no. 4, pp. 4401-4410. doi: 10.1109/TSG.2018.2859339
- [39] Niazazari I., Livani H. Disruptive Event Classification using PMU Data in Distribution Networks. Available at: <https://arxiv.org/abs/1703.09800> (accessed 05.01.2023)
- [40] Mishra A., de Callafon R.A. Voltage State Estimation using a Power Network Model driven Auto-Encoder Neural Network. *IFAC-PapersOnLine*, 2021, vol. 54, no. 7, pp. 517-522. doi: 10.1016/j.ifacol.2021.08.412
- [41] Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Computing*, 1997, vol. 9, pp. 1735-1780.
- [42] Cho K., van Merriënboer B., Gulcehre C., Bahdanau D., Bougares F., Schwenk H., Bengio Y. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. Available at: <https://arxiv.org/abs/1406.1078> (accessed 04.01.2023)
- [43] Lamb A., Goyal A., Zhang Y., Zhang S., Courville A., Bengio Y. Professor Forcing: A New Algorithm for Training Recurrent Networks. Available at: <https://arxiv.org/abs/1610.09038> (accessed 04.01.2023)
- [44] Kulowski L. Building a LSTM Encoder-Decoder using PyTorch to make Sequence-to-Sequence Predictions. Available at: https://github.com/lkulowski/LSTM_encoder_decoder (accessed 02.01.2023)

Сведения об авторах.



Матренин Павел Викторович, к.т.н., ведущий научный сотрудник научной лаборатории цифровых двойников Уральского федерального университета.

Область научных интересов: системный анализ, методы машинного обучения в электроэнергетике, обработка временных рядов.

E-mail: p.v.matrenin@urfu.ru



Потахиц Ярослав Владимирович, к.т.н., старший преподаватель кафедры электрических станций Белорусского национального технического университета.

Область научных интересов: электродинамическая стойкость, обработка временных рядов.

E-mail: potachits@bntu.by



Хальясмаа Александра Ильмаровна, к.т.н., доцент, заведующий научной лаборатории цифровых двойников в электроэнергетике Уральского федерального университета.

Область научных интересов: диагностика состояния электрооборудования, системы поддержки принятия решений.

E-mail: a.i.khaliyasmaa@urfu.ru