

А. А. ГУСЕВ, А. В. ШЕВЧЕНКО, В. М. НИКИФОРОВ, М. Л. СИМАКОВ  
АО «НПЦАП», Москва

## **ВЫБОР И ОБУЧЕНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ КЛАССИФИКАЦИИ НЕИСПРАВНОСТЕЙ МНОГОКАНАЛЬНОЙ СИСТЕМЫ ЭЛЕКТРОПИТАНИЯ ПОСТОЯННОГО ТОКА**

*В настоящей статье рассматривается определение неисправностей выходных каналов многоканальной системы электропитания, исходя из временных последовательной напряжений и токов, используя различные способы классификации временных рядов. Рассмотрены классификаторы на основе нейронных сетей. Проведен сравнительный анализ полученных классификаторов на экспериментальных данных. Сформулированы рекомендации по применению классификаторов для предсказания возможных неисправностей системы.*

**Введение.** К современным системам электропитания промышленных объектов повышенной опасности предъявляются высокие требования к надежности и безотказной работе. Своевременное диагностирование неисправностей и предсказание возникновения неисправностей являются актуальными задачами и позволяют принять меры по минимизации затрат на устранение последствий неисправностей.

Объектом исследования является многоканальная система электропитания постоянного тока с номинальным выходным напряжением 24 В на каждом независимом канале и суммарной мощностью до 1 кВт.

Целью данной работы является бинарный классификатор, позволяющий диагностировать наличие неисправности каналов электропитания по временным последовательностям напряжений и токов.

**Постановка задачи.** В общем виде задачу данной работы можно сформулировать следующим образом:

Для многоканальной системы электропитания постоянным током необходимо построить бинарный классификатор неисправности каналов, обеспечивающий определение состояния канала электропитания с вероятностью более 90 %, основываясь на временных последовательностях токов и напряжений длительностью не более 30 с.

**Классификаторы неисправностей.** Для классификации временных рядов возможно использование как классических классификаторов (дерева решений, метод опорных векторов и т. д.), так и классификаторов на основе нейронных сетей (рекуррентные нейронные сети, сверточные нейронные сети и т. д.). Основным преимуществом классификаторов на основе нейронных сетей является то, что они не требуют информации о вероятностном распределении данных и не используют меры расстояний, то есть являются универсальными классификаторами. К тому же нейронные сети не чувствительны к шумам в данных.

Входом классификатора являются временные последовательности токов  $I$  и напряжений  $U$  по каждому из выходных каналов электропитания. Выходом классификатора является переменная, определяющая текущее состояние канала – исправное или неисправное. Примеры временных последовательностей напряжений исправного канала и неисправного канала представлены на рис. 1 и 2 соответственно.

В работе рассмотрены классификаторы на основе нейронных сетей [1]:

- рекуррентная нейронная сеть (SimpleRNN);
- управляемые рекуррентные блоки (GRU);
- долгая краткосрочная память (LSTM);
- глубокая нейронная сеть (DNN);
- сверточная нейронная сеть (CNN);
- комбинация сверточной нейронной сети и долгой краткосрочной памяти.

Каждая из нейронных сетей имеет входной слой, на который поступает временные последовательности, и выходной слой, определяющий состояние выходного канала системы электропитания, размерностью 2 с функцией активации «softmax».

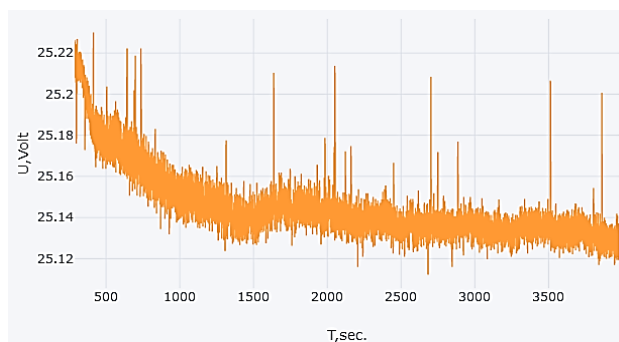


Рис. 1. Напряжение исправного канала

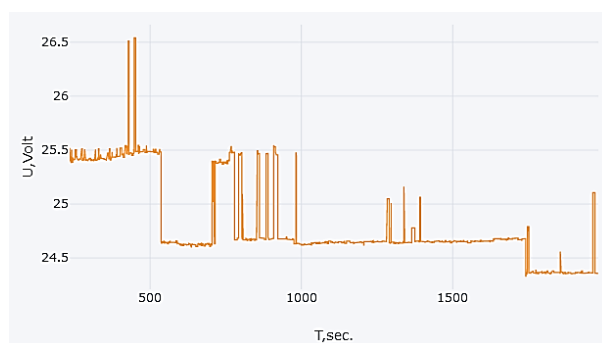


Рис. 2. Напряжение неисправного канала

**Обучение классификаторов.** Классификаторы, рассмотренные в данной статье, реализованы на языке программирования Python с использованием библиотек машинного обучения. Обучение и валидация классификаторов проведены на экспериментальных данных, полученных с исправной и неисправной систем. При этом из общей выборки 33 % составляют данные для валидации, остальные являются данными для обучения классификаторов. Обучение классификаторов представляет собой итеративный процесс на основе алгоритма обратного распространения ошибки, свойственного обучению нейронных сетей.

Процесс обучения любого из классификаторов включает в себя:

1. Подготовку данных [2]:

- нормализация данных, заключающаяся в приведении значений в диапазон  $[0,1]$ ;
- разбиение данных на обучающую и выборку валидации.

2. Итеративный процесс обучения по эпохам [3]:

- полный прогон выборки на основе пакетного режима обучения (расчет ошибки обучения и коррекция весов нейронных сетей на небольшом фрагменте выборки);
- валидация классификатора на данных, не задействованных в обучении.

В качестве функции ошибки при обучении использована функция кросс-энтропии.

Для оценки качества классификаторов использованы следующие метрики:

1) достоверность (accuracy) – отношение правильно классифицированных состояний к общему числу состояний, рассчитанное по формуле:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

где  $TP$  – истинно положительные результаты классификации;  $TN$  – истинно отрицательные результаты классификации;  $FP$  – ложноположительные результаты классификации;  $FN$  – ложноотрицательные результаты классификации.

2) точность (precision) – отношение действительно принадлежащих классу (исправные и неисправные) состояний, определенных классификатором, к общему числу состояний, отнесенных классификатором к этому классу. Результирующая точность классификатора рассчитывается как арифметическое среднее его точности по всем классам. В идеальном случае точность должна быть близка к 1.

$$precision = \frac{TP}{TP + FP}; \quad (2)$$

3) полнота (recall) – отношение действительно принадлежащих классу (исправные и неисправные) состояний, определенных классификатором, к общему числу состояний этого класса содержащихся в выборке. Результирующая полнота классификатора рассчитывается как арифметическое среднее его полноты по всем классам. В идеальном случае полнота должна быть близка к 1.

$$recall = \frac{TP}{TP + FN} \quad (3)$$

4) F-мера (F1) – комплексная оценка качества классификатора, позволяющая одновременно учесть и точность, и полноту. В идеальном случае F-мера близка к 1.

$$F1 = 2 * \frac{precision * recall}{precision + recall} \quad (4)$$

Использование такого количество метрик позволяет в полной мере оценить качество работы классификаторов и сделать правильные рекомендации по применению классификаторов.

На рис. 3 представлены графики изменения функции потерь и точности классификатора при обучении и валидации.

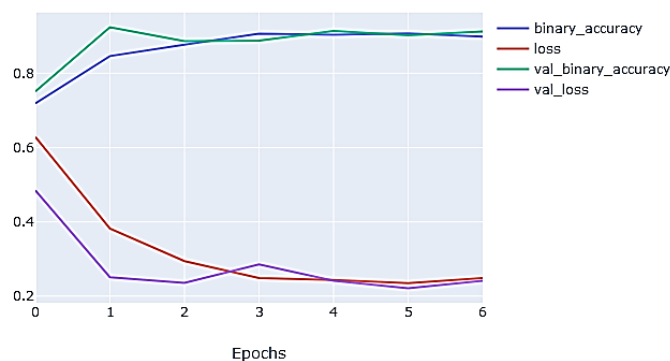


Рис. 3. Изменения функции потерь и точности классификатора при обучении и валидации

Результаты обучения классификаторов. Из-за стохастической природы обучения классификаторов на основе нейронных сетей проведено обучение каждого из классификаторов 10 раз. Классификаторы обучены на выборке, состоящей из 8000 последовательностей длительностью 11,7 сек. Валидация классификаторов проведена на выборке, состоящей из 4000 последовательностей длительностью 11,7 сек. Определены среднеарифметические значения метрик на данных валидации, которые представлены в таблице 1.

Т а б л и ц а 1

Среднеарифметические значения метрик на данных валидации

<i>Классификатор</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1 score</i>
Рекуррентная нейронная сеть (SimpleRNN)	0,81	0,80	0,96	0,86
Управляемые рекуррентные блоки (GRU)	0,83	0,85	0,90	0,86
Долгая краткосрочная память (LSTM)	0,81	0,79	0,97	0,86
Глубокая нейронная сеть (DNN)	0,93	0,92	0,96	0,94
Сверточная нейронная сеть (CNN)	0,96	0,97	0,96	0,97
Комбинация сверточной нейронной сети и долгой краткосрочной памяти	0,93	0,93	0,96	0,94

Исходя из таблицы 1 можно сделать вывод о том, что 3 последних классификатора являются решением поставленной задачи. Наилучшее качество обеспечивает классификатор на основе сверточной нейронной сети.

#### **Выводы.**

1. Лучшее качество обеспечивает классификатор на основе сверточной нейронной сети.
2. Классификатор на основе сверточной нейронной сети может быть использован при выявлении неисправностей системы питания практически в режиме реального времени.
3. Классификаторы, рассмотренные в данной работе, могут быть использованы в системе предсказания неисправностей.

#### ЛИТЕРАТУРА

1. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А. А. Слинкина. 2-е изд., испр. М.: ДМК Пресс, 2018. 652 с.: цв. ил.
2. Плас Дж. Вандер Python для сложных задач: наука о данных и машинное обучение. СПб.: Питер, 2018. 576 с.: ил.
3. Maxim Lapan Deep Reinforcement Learning Hands-On Second Edition. BIRMINGHAM – MUMBAI, 2020. 827 с.
4. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. М.: Финансы и статистика, 202. 344 с.: ил.

A.A.Gusev, A.V.Shevchenko, V.M. Nikiforov, M.L.Simakov (Academician N.A. Pilyugin Scientific-Production Center of Autimatics and Instrument Making, Moscow)

#### **Selection and training of a neural network for fault classification of a multichannel DC power supply system.**

This article discusses the definition of faults in the output channels of a multi-channel power supply system based on temporary series voltages and currents, using various methods of time series classification. Considered classifiers based on neural networks. The comparative analysis of the received classifiers on experimental data is carried out. Recommendations on the use of classifiers to predict possible system failures are formulated.

Авторы готовы представить текст на английском языке для сборника материалов мультиконференции, который будет подан для индексирования в Scopus