

## ДВУХЭТАПНЫЙ ПОДХОД К ОБРАБОТКЕ ДАННЫХ В ПРОЦЕССЕ ДЕТЕКТИРОВАНИЯ ИМПУЛЬСОВ МИКРОРАЗРЯДОВ С ПОМОЩЬЮ МАШИННОГО ОБУЧЕНИЯ<sup>1</sup>

Низамов Данил Юрьевич<sup>1</sup>,  
e-mail: [daniel.nizamov@codesignal.ru](mailto:daniel.nizamov@codesignal.ru),

Лазукин Александр Вадимович<sup>2</sup>,  
e-mail: [lazukin\\_av@mail.ru](mailto:lazukin_av@mail.ru),

Зайцев Сергей Александрович<sup>1</sup>,  
канд. техн. наук, доцент,  
e-mail: [szaytsev@muiv.ru](mailto:szaytsev@muiv.ru),

<sup>1</sup>Московский университет имени С.Ю. Витте, г. Москва, Россия

<sup>2</sup>Национальный Исследовательский университет «Московский энергетический институт»,  
г. Москва, Россия

В статье рассматривается подход к решению задачи детектирования токовых импульсов поверхностного барьерного разряда атмосферного давления в условиях большого объема данных, полученных с большой частотой дискретизации. Представлен краткий обзор собранного датасета, проведен анализ типового алгоритма детектирования и выделены его недостатки. Предложен новый двухэтапный подход к обработке данных: классификация временного ряда для предобработки данных и детектирование начала и окончания импульсов с помощью регрессионной модели глубокого обучения. В работе рассмотрены актуальные архитектуры нейронных сетей и приведено сравнение эффективности рассмотренных подходов в решении задач классификации временных рядов. Применение машинного обучения позволяет уменьшить погрешности детектирования. Данный метод показывает лучшие результаты, чем существующие подходы за счет повышения точности и устойчивости к шумам. Теоретические и практические результаты исследования направлены на развитие методов технической диагностики и машинного обучения.

**Ключевые слова:** машинное обучение, рекуррентные нейронные сети, классификация временных рядов, частичные разряды, глубокое обучение, детектирование событий, математическая модель импульса тока

## A TWO-STEP METHOD FOR DATA PROCESSING IN THE PROCESS OF DETECTING MICRO-DISCHARGE PULSES USING DEEP MACHINE LEARNING

Nizamov D.Yu.<sup>1</sup>,  
e-mail: [daniel.nizamov@codesignal.ru](mailto:daniel.nizamov@codesignal.ru),

Lazukin A.V.<sup>2</sup>,  
e-mail: [lazukin\\_av@mail.ru](mailto:lazukin_av@mail.ru),

Zaitsev S.A.<sup>1</sup>,  
e-mail: [szaytsev@muiv.ru](mailto:szaytsev@muiv.ru),  
candidate of technical sciences, associate professor  
<sup>1</sup>Moscow Witte University, Moscow, Russia

<sup>2</sup>National Research University “Moscow Power Engineering Institute”, Moscow, Russia

The article describes an approach to solving the problem of detecting current pulses of a surface barrier discharge at atmospheric pressure under conditions of large volumes of data obtained at a high sampling rate. A brief overview

---

<sup>1</sup> Работа выполнена при поддержке Российского научного фонда (проект 23-29-00265).

*of the collected dataset is presented, an analysis of a typical detection algorithm is carried out, and its shortcomings are identified. A new two-step approach to data processing is proposed: classification of the time series for data pre-processing and detection of the start and end of pulses using a deep learning regression model. The article describes relevant neural network architectures and provides a comparison of the effectiveness of the considered approaches in solving time series classification tasks. The use of machine learning makes it possible to reduce detection errors. This method shows better results than existing approaches due to improved accuracy and noise resistance. The theoretical and practical results of the study are aimed at the development of technical diagnostics and machine learning methods.*

**Keywords:** machine learning, recurrent neural networks, time series classification, partial discharges, deep learning, event detection, mathematical model of current pulse

### Введение

Временные ряды как объект анализа прочно заняли место в научном восприятии мира. Анализ этих временных зависимостей и выявление в них скрытых закономерностей оказывается крайне ценным для оценки будущих событий.

С развитием техники измерений, повышения скорости записи, сохранения и обработки данных возникла возможность прогнозировать поведение и состояние систем, в которых протекают групповые процессы. Одним из примеров такого процесса является развитие поверхностного диэлектрического барьерного разряда (SDBD – Surface Dielectric Barrier Discharge). SDBD – это вид высоковольтного газового разряда атмосферного давления, существующий на поверхности диэлектрика у кромки электрода малого радиуса кривизны. Установки на основе SDBD применяются в аэродинамике [1], медицине [2], сельском хозяйстве [3; 4].

SDBD развивается в виде микроразрядов. Как отдельное явление, микроразряд достаточно три-виален и хорошо изучен. А как совокупная группа, развивающаяся во времени, представляет интерес, поскольку прогнозирование поведения свойств этой группы при учете длительной предыстории её развития позволяет оценить ресурс оборудования, предотвратить аварии или критические отклонения от рабочих параметров.

Протекание группового процесса может быть описано через коллективные параметры распределений характеристик отдельных микроразрядов. Наполнение таких распределений достоверной и адекватной информацией за счет минимальных технических вложений может быть достигнуто путем совершенствования методов анализа данных.

Целью исследования является разработка алгоритма, позволяющего с высокой точностью классифицировать и детектировать микроразряды, возникающие в макете электродной системы SDBD высокого напряжения.

Для достижения цели решаются следующие задачи:

- разработка алгоритма предобработки данных, максимизирующего эффективность предлагаемого детектирующего алгоритма;
- обучение регрессионной модели на основе глубокого обучения для детектирования микроразрядов с учетом особенностей исходных данных.

Основными методами исследования являются метод искусственного интеллекта – глубокое обучение, статистические методы.

### Обзор существующих подходов к решению задач классификации частичных разрядов

Известен метод математической обработки токовых сигналов поверхностного диэлектрического барьерного разряда [5]. Собран и размечен достаточный объем экспериментальных данных [6], необходимый для оценки достоверности анализа. Данные представляют собой циклы работы модельной установки, в каждом из которых регистрируется напряжение питания и ток микроразрядов (рисунок 1).

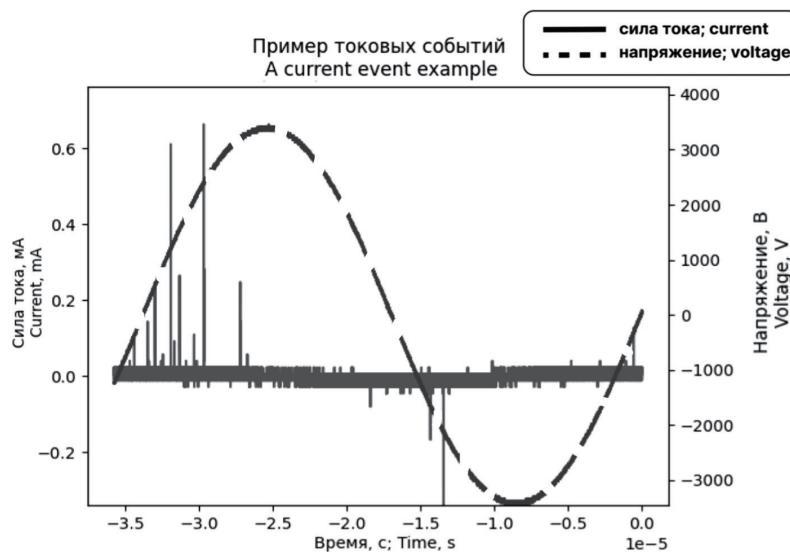


Рисунок 1 – Пример распределения импульсов микроразрядов по периоду питающего напряжения<sup>1</sup>

Индивидуальное событие (токовое событие) представляет собой кратковременное возмущение в сигнале тока нагрузки. На рисунке 2 представлено несколько индивидуальных событий. Такое событие описывается фронтом, спадом, длительностью, амплитудой, полярностью.



Рисунок 2 – Пример отдельных импульсов микроразрядов (токовых событий)<sup>2</sup>

В работе [5] описан алгоритм обнаружения токовых событий. В данной статье этот алгоритм рассматривается как наиболее релевантный конкурентный алгоритм, так как он тестиировался на аналогичном наборе данных, собранном при проведении эксперимента с тем же оборудованием и близкими параметрами. Алгоритм делится на два шага:

1. Реализуется фильтр Баттервортса для удаления частот за пределами интервала  $10^5 \div 10^7$  Герц.

2. Каждое токовое событие анализируется для обнаружения характерного ступенчатого изменения  $q(t)$ , соответствующего микроразряду.

Авторы публикации отмечают, что достоверность метода не превышает 80 % [5].

В данной работе предлагается альтернативный подход к обнаружению токовых событий на основе глубокого обучения, использующий двухэтапный алгоритм. Двухэтапный алгоритм включает реали-

<sup>1</sup> Составлено авторами.

<sup>2</sup> Составлено авторами.

зацию бинарной классификационной модели для удаления участков с шумом и регрессионной модели на основе глубокого обучения для детектирования токовых событий.

### Обзор решений для удаления шума и классификации импульсов частичных разрядов

На первом этапе предложенного нами алгоритма используется модель бинарной классификации, которая применяется для детектирования окон, вероятно содержащих токовые события. Под «окном» понимается любой последовательный срез значений данных. Далее будем называть эту модель моделью-классификатором. Такой подход позволяет существенно ускорить обучение и применение регрессионной модели для второго этапа, что открывает возможность к применению метода в реальном времени.

Существует ряд возможных решений для построения модели-классификатора.

Рекурентные нейронные сети (RNN – Recurrent Neural Network) широко используются для решения задач классификации. В [7] описывается применение RNN для решения стандартных задач классификации временных последовательностей. Отмечены хорошие способности RNN к генерализации. В [8] изучается использование классической RNN для классификации временных рядов.

В работе [9] обсуждается использование методов машинного обучения при классификации и обработке импульсов частичных разрядов. Для устранения шумов, локализации, классификации импульсов частичных разрядов, а также идентификации их источников был протестирован и применен ряд подходов, включая нейронные сети, ансамбли деревьев решений и метод опорных векторов. Были проверены пять широко используемых классификационных моделей, доступных в открытых исходных кодах, включая классификатор на основе метода опорных векторов (SVC – Support Vector Machines), ансамбль случайных лесов (RFC – Random Forest Classifier), метод ближайших соседей (KNN – K-Nearest Neighbors), классификатор с градиентным бустингом (GBC – Gradient Booster Classifier) и классификатор на основе искусственной нейронной сети (ANN – Artificial Neural Network). Для всех классификаторов величина точности детектирования не превысила 80 %. Отмечается, что дополнительные трудности связаны с адекватностью обучающих данных и объемом вычислений.

### Предлагаемое решение для обучения модели-классификатора

Для обучения модели-классификатора используется скользящее окно с регулируемой шириной. Модель машинного обучения используется для назначения каждому окну метки класса: 0, если данные представляют собой только шум; 1, если в данных фиксируется что-либо помимо шума.

Модель обучается с максимизацией метрики точность (*precision*) для максимизации точности классификации окон, содержащих только шум.

Для оценки метода использовался тестовый набор данных, содержащий 3 млн точек, сформированный путем случайной подвыборки экспериментов из общего датасета. Разметка набора произведена вручную одним экспертом. Набор данных был разделен на тестовую, валидационную и обучающую подвыборки в соотношении 15 %, 15 %, 70 % соответственно. Проведено обучение ряда моделей с использованием пакетов *scipy* и *pytorch* для языка программирования Python. Каждая модель обучалась с подбором гиперпараметров по сетке с использованием кросс-валидации, которые используются для управления процессом обучения модели. Результаты обучения моделей-классификаторов приведены в таблице 1. Сравнение эффективности рассмотренных моделей проводилось по метрикам Recall (полнота), Precision (точность), время обучения и срабатывания. Recall показывает способность модели идентифицировать все экземпляры объектов, Precision показывает, сколько обнаружений было правильным.

Таблица 1 – Сравнение эффективности рассмотренных классификационных моделей

Название модели Model name	Recall на наборе тестовых данных	Precision на наборе тестовых данных	Время обучения, минут	Время срабатывания готовой модели на одном объекте (в рамках одного окна), мс
Решающее дерево	0.949	0.971	< 1	0.02

RFC	0.95	0.9884	< 1	0.15
KNN	0.949	0.971	< 1	0.04
GBC	0.949	0.982	< 1	0.03
RNN	0.929729	0.9942	56	0.7
ANN	0.9543	0.9653	< 1	0.2

Таким образом, можно заключить, что RNN показывает наилучший результат на тестовой выборке. Важно отметить, что обучение RNN занимает существенно более долгое время, чем обучение других алгоритмов. Имея это в виду, можно заменять модель-классификатор на RFC или GBC в зависимости от размера обучающей выборки.

На втором этапе предложенного нами алгоритма используется регрессионная модель глубокого обучения, описанная в [10], которую будем называть моделью-детектором. Для обучения модели-детектора использовался независимый тестовый набор из 3 млн последовательных точек. Набор размечался вручную одним экспертом, который визуально находил импульсы в общем объеме данных и отмечал время начала и время окончания каждого импульса. Таким образом, набор тестовых данных представляет из себя набор пар временных отметок, каждая пара соответствует началу и концу одного импульса. Модель обучалась предсказывать процент пересечения текущего окна и события. Важно отметить, что данная модель может работать только с фиксированной шириной окна. Если детектируемые события имеют различную длительность, то качество детектирования может существенно снизиться. Ввиду этого важно отметить следующие результаты исследования:

1. Анализ датасета показал, что средняя длительность токового события составляет 25.2 нс. Минимальная наблюдаемая длительность 13 нс, а максимальная – 53 нс. Большинство микроразрядов в тестовом наборе имеют длительность от 15 до 30 нс. Распределение длительностей токовых событий в тестовом наборе приведено на рисунке 3.

2. Такой разброс в длительности событий может повлиять на качество определения точки окончания события. Однако достоверно зная точку начала события, можно восстановить точку окончания, используя аналитическую модель. Мы раскрываем пример такой обработки и обосновываем ее эффективность в следующем разделе.

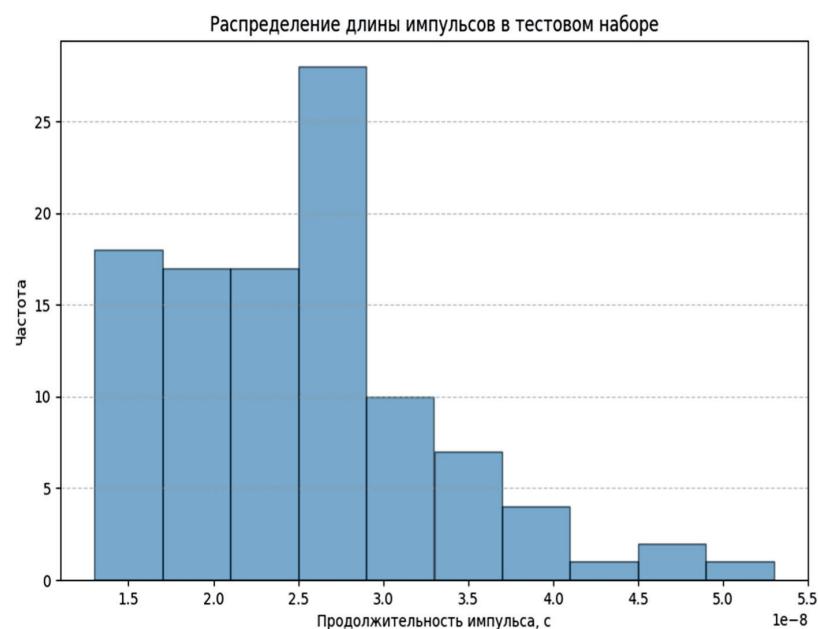


Рисунок 3 – Распределение длительностей токовых событий<sup>3</sup>

<sup>3</sup> Составлено авторами.

Приведем результаты обучения модели-детектора. Для обучения модели был использован пакет `eventdetector_ts` для языка программирования Python. Ключевой задачей при обучении данной модели является выбор ширины окна. В нашем случае оптимальной шириной окна является окно шириной 30 нс. На рисунке 4 представлен пример детектирования событий на участке тестового набора с помощью обученной модели. На данном участке хорошо видно, что модель не всегда справляется с отделением друг от друга двух пересекающихся событий. Мы обсуждаем подходы к решению этой проблемы в следующем разделе.

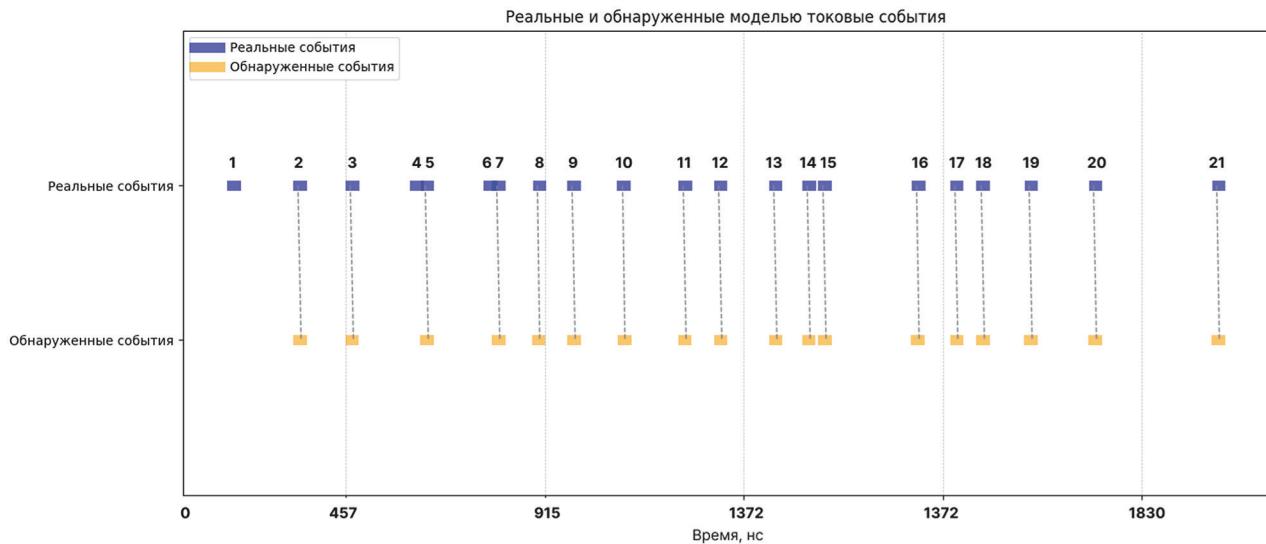


Рисунок 4 – Детектирование событий на участке тестового набора.  
Ошибка детектирования в событиях 1, 4 и 6<sup>4</sup>

Общая точность детектирования на всем тестовом наборе оценивалась по качеству детектирования начала события (событие считалось достоверно зафиксированным при совпадении начала настоящего и предсказанного импульса с точностью в пределах 1 нс) и составила 87.9 %.

### Аналитическая модель описания отдельного импульса

Рассмотрим один из вариантов обработки полученных результатов. На финальном этапе к детектированным импульсам применяется аналитическая модель описания отдельного импульса (далее – просто «аналитическая модель»), предложенная в [11]. Аналитическая модель основана на математической модели импульса микrorазряда, предложенной в [12], и описывается следующим образом:

$$\begin{aligned}
 f_1(t) &= \frac{1}{1 + e^{-(t_0 - t)}}, \\
 f_2(t) &= \{1, \quad t < t_0 \quad e^{-(t_0 - t)}, \quad t \geq t_0. \\
 f(t) &= A \cdot f_1(t) \cdot f_2(t), \\
 f_{tot}(t) &= f_{el}(t) + f_{ion}(t).
 \end{aligned}$$

Здесь  $f_{tot}(t)$  – итоговая математическая модель; функции  $f_{el}(t)$  и  $f_{ion}(t)$  имеют форму  $f(t)$  и представляют электронную и ионную составляющие импульса тока соответственно, их параметры подбираются независимо друг от друга. Приведем расшифровку всех обозначений параметров в таблице 2.

<sup>4</sup> Составлено авторами.

Таблица 2 – Описание обозначений параметров аналитической модели

Обозначение	Описание
$A$	Амплитуда импульса, мА
$t_0$	Время достижения максимального значения тока в импульсе, «пика» импульса, с
$f_1(t), f_2(t)$	Функции, составляющие $f(t)$ . Вынесены отдельно для удобства читателя
$f(t)$	Функция, описывающая одну составляющую (ионную или электронную) импульса тока
$f_{\text{tot}}$	Функция, описывающая полный импульс тока

Аналитическая модель позволяет оценить физические характеристики импульса, которые могут быть затем использованы для принятия решений. В [11] отмечено, что модель может быть использована для восстановления утерянной из-за ограничений измерительного оборудования амплитуды импульса с ошибкой в пределах 10 % от истинной амплитуды импульса. Показано, что модель можно использовать для вычисления отдельных импульсов из пересекающихся токовых событий. Это можно использовать для улучшения качества работы модели-детектора. Пример использования модели для аппроксимации токового события показан на рисунке 5.

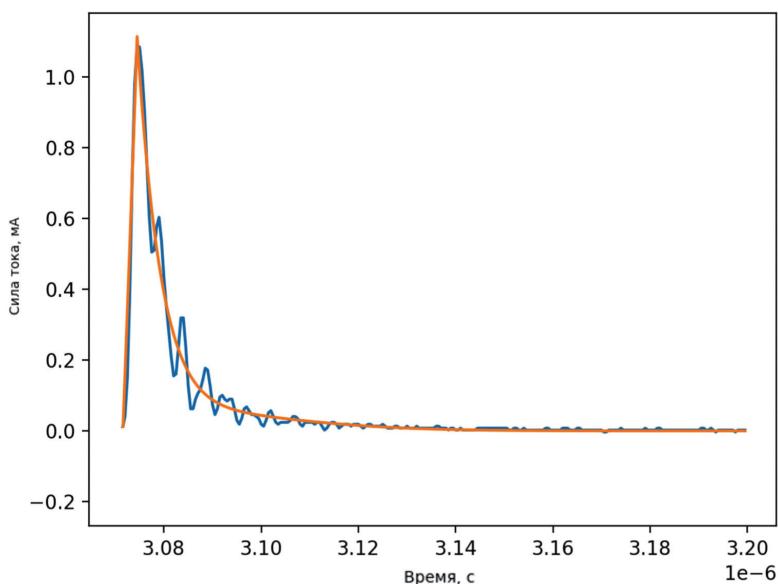


Рисунок 5 – Аппроксимация формы импульса с помощью аналитической модели<sup>5</sup>

Для обоснования применимости модели для восстановления точки окончания импульса был проведен следующий тест: было отобрано 120 случайных токовых событий, у которых была вручную удалена часть данных справа таким образом, чтобы длина каждого была равна ширине окна модели-детектора. Затем остаток импульса был аппроксимирован с помощью аналитической модели, что позволяет восстановить хвост и предсказать точку, в которой ток равняется нулю. Результаты тестирования приведены в таблице 3.

Таблица 3 – Результаты опыта по оценке способности математической модели определять конечную точку токового события

Метрика	Описание	Значение
dt	Разность между истинной точкой окончания импульса, установленной визуально, и точкой окончания импульса, предсказанной аналитической моделью, нс	4.01
RMSE (Root Mean Squared Error)	Среднее значение разности между реальным значением тока и значением, предсказанным аналитической моделью, мА	0.039

<sup>5</sup> Составлено авторами.

Таким образом, использование аналитической модели позволяет предсказать точку окончания токового события с точностью около 4 нс, при этом общее качество аппроксимации сохраняется на высоком уровне. Наилучшие результаты удалось получить при использовании изначальных параметров, соответствующих равностороннему треугольнику с вершинами в верхней точке импульса и точке начала импульса. Установлено, что оптимально применение сглаживания сигнала с помощью скользящего среднего с шириной окна в 5 точек.

### Заключение

Предложен двухэтапный алгоритм, включающий бинарную классификационную модель для удаления участков с шумом и регрессионную модель на основе глубокого обучения, для решения задачи детектирования токовых событий в барьерном диэлектрическом разряде. Приведено сравнение ряда моделей машинного обучения для первого этапа и предложены рекомендации по выбору модели и предобработке данных. Показано, что использование RNN позволяет добиться точности (precision) 99.42 %.

Приведены данные о производительности модели-детектора на собранном датасете. Предложены оптимальные параметры модели-детектора с учетом особенностей датасета, которые позволили получить точность детектирования 87.93 %. Это на 7.93 процентных пункта выше точности математического метода, описанного в [5]. Этот метод наиболее релевантен, потому что оценивалось его качество при работе с набором данных, который аналогичен набору данных, исследуемому в данной статье, так как был получен при проведении эксперимента с эквивалентными оборудованием и параметрами.

Разработан вариант аналитической модели микроразряда для сбора данных о параметрах импульса. Проведен эксперимент по оценке качества модели, показано, что аналитическая модель может быть использована для восстановления точки окончания импульса с точностью около 4 нс. Приведены рекомендации по использованию данной модели.

Таким образом, данное исследование демонстрирует возможность применения глубокого обучения для детектирования импульсов тока в диэлектрическом барьерном разряде, предлагает вариант архитектуры для решения данной задачи и создает основу для дальнейшей разработки программных комплексов для совершенствования систем управления плазменных устройств для использования в быту, сельском хозяйстве и энергетике.

### Список литературы

1. Corke T.C., Enloe C.L., Wilkinson S.P. Dielectric Barrier Discharge Plasma Actuators for Flow Control // Annual Review of Fluid Mechanics. – 2010. – Vol. 42. – P. 505–529. – DOI 10.1146/annurev-fluid-121108-145550.
2. Pemen A.J.M., Chirumamilla V.R., Beckers F.J.C.M., Hoeben W.F.L.M., Huiskamp T. An SDBD Plasma-Catalytic System for On-Demand Air Purification // IEEE Transactions on Plasma Science. – 2018. – Vol. 46, No. 12. – P. 4078–4090. – DOI 10.1109/TPS.2018.2855402.
3. Škoro N., Živković S., Jevremović S., Puac N. Treatment of Chrysanthemum Synthetic Seeds by Air SDBD Plasma // Plants. – 2022. – Vol. 11, No. 7. – P. 907. – DOI 10.3390/plants11070907.
4. Hadi H., Zakeri Khatir H., Hajiebrahimi E., Sohbatzadeh F. Degradation of diazinon and endosulfan pesticides using surface dielectric barrier discharge cold plasma employing Ar/H<sub>2</sub>O/H<sub>2</sub>O<sub>2</sub> working gas // Journal of Theoretical and Applied Physics. – 2024. – Vol. 18, No. 6.
5. Lazukin A., Chernyshev T., Krivoruchko D. The statistical data on microdischarges of the surface dielectric barrier discharge unit based on aluminum nitride barrier // Physics of Plasmas. – 2019. – Vol. 26, No. 3. – P. 033513. – DOI 10.1063/1.5083182.
6. Lazukin A., Chernyshev T., Krivoruchko D. Current wave in the Surface Dielectric Barrier Discharge unit [DS/OL] // Science Data Bank, V1. – 2023 [2024-03-19]. – CSTR:31253.11.scencedb.10528.
7. Hüskens M. Recurrent neural networks for time series classification // Neurocomputing. – 2003. – Vol. 50. – P. 223–235.

8. Smirnov D., Nguifo E.M. Time Series Classification with Recurrent Neural Networks // University Clermont Auvergne, CNRS, LIMOS, 63000 Clermont-Ferrand, France / National Research University Higher School of Economics, Faculty of Computer Science, 101000 Moscow, Russian Federation.
9. Ogliari E., Sakwa M., Wei J., Liu W., Schubert B., Palo M. General Machine Learning-Based Approach to Pulse Classification for Separation of Partial Discharges and Interference // IEEE Sensors Journal. – 2023. – P. 1-1. – DOI 10.1109/JSEN.2023.3317331.
10. Azib M., Renard B., Garnier P., Génot V., André N. Event Detection in Time Series: Universal Deep Learning Approach. ArXiv. 2023. – DOI 10.48550/arXiv.2311.15654.
11. Низамов Д.Ю., Зайцев С.А., Лазукин А.В. Предобработка данных с помощью математической модели импульса тока микроразряда для моделей машинного обучения // Лазерные, плазменные исследования и технологии – ЛаПлаз-2025: сборник научных трудов XI Международной конференции. – Москва: НИЯУ МИФИ, 2025. – С. 300.
12. Synek P., Zemánek M., Kudrle V., Hoder T. Advanced electrical current measurements of microdischarges: evidence of sub-critical pulses and ion currents in barrier discharge in air // Plasma Sources Science and Technology. – 2019. – Vol. 27, No. 4.

### References

1. Corke T.C., Enloe C.L., Wilkinson S.P. Dielectric Barrier Discharge Plasma Actuators for Flow Control // Annual Review of Fluid Mechanics. – 2010. – Vol. 42. – P. 505–529. – DOI 10.1146/annurev-fluid-121108-145550.
2. Pemen A.J.M., Chirumamilla V.R., Beckers F.J.C.M., Hoeben W.F.L.M., Huiskamp T. An SDBD Plasma-Catalytic System for On-Demand Air Purification // IEEE Transactions on Plasma Science. – 2018. – Vol. 46, No. 12. – P. 4078–4090. – DOI 10.1109/TPS.2018.2855402.
3. Škoro N., Živković S., Jevremović S., Puac N. Treatment of Chrysanthemum Synthetic Seeds by Air SDBD Plasma // Plants. – 2022. – Vol. 11, No. 7. – P. 907. – DOI 10.3390/plants11070907.
4. Hadi H., Zakeri Khatir H., Hajiebrahimi E., Sohbatzadeh F. Degradation of diazinon and endosulfan pesticides using surface dielectric barrier discharge cold plasma employing Ar/H<sub>2</sub>O/H<sub>2</sub>O<sub>2</sub> working gas // Journal of Theoretical and Applied Physics. – 2024. – Vol. 18, No. 6.
5. Lazukin A., Chernyshev T., Krivoruchko D. The statistical data on microdischarges of the surface dielectric barrier discharge unit based on aluminum nitride barrier // Physics of Plasmas. – 2019. – Vol. 26, No. 3. – P. 033513. – DOI 10.1063/1.5083182.
6. Lazukin A., Chernyshev T., Krivoruchko D. Current wave in the Surface Dielectric Barrier Discharge unit [DS/OL] // Science Data Bank, V1. – 2023 [2024-03-19]. – CSTR:31253.11.sciedb.10528.
7. Hüskens M. Recurrent neural networks for time series classification // Neurocomputing. – 2003. – Vol. 50. – P. 223–235.
8. Smirnov D., Nguifo E.M. Time Series Classification with Recurrent Neural Networks // University Clermont Auvergne, CNRS, LIMOS, 63000 Clermont-Ferrand, France / National Research University Higher School of Economics, Faculty of Computer Science, 101000 Moscow, Russian Federation.
9. Ogliari E., Sakwa M., Wei J., Liu W., Schubert B., Palo M. General Machine Learning-Based Approach to Pulse Classification for Separation of Partial Discharges and Interference // IEEE Sensors Journal. – 2023. – P. 1-1. – DOI 10.1109/JSEN.2023.3317331.
10. Azib M., Renard B., Garnier P., Génot V., André N. Event Detection in Time Series: Universal Deep Learning Approach. ArXiv. 2023. – DOI 10.48550/arXiv.2311.15654.
11. Nizamov, D.Yu., Zajcev S.A., Lazukin A.V. Predobrabortka dannyh s pomoshch'yu matematicheskoy modeli impul'sa toka mikrorazryada dlya modelej mashinnogo obucheniya // Lazernye, plazmennye issledovaniya i tekhnologii – LaPlaz-2025: sbornik nauchnyh trudov XI Mezhdunarodnoj konferencii. – Moskva: NIYAU MIFI, 2025. – S. 300.
12. Synek P., Zemánek M., Kudrle V., Hoder T. Advanced electrical current measurements of microdischarges: evidence of sub-critical pulses and ion currents in barrier discharge in air // Plasma Sources Science and Technology. – 2019. – Vol. 27, No. 4.

Статья поступила в редакцию: 13.03.2025

Статья принята к публикации: 23.05.2025

Received: 13.03.2025

Accepted: 23.05.2025