

УСКОРИТЕЛИ ЗАРЯЖЕННЫХ ЧАСТИЦ ДЛЯ ЯДЕРНЫХ ТЕХНОЛОГИЙ

УДК 004.93'1

ПРИМЕНЕНИЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ И НЕЙРОСЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ ПАРАЗИТНЫХ ПАРАМЕТРОВ ПО ВЫХОДНОМУ СИГНАЛУ В МОЩНЫХ ИМПУЛЬСНЫХ УСТРОЙСТВАХ ЭЛЕКТРОФИЗИКИ

© 2024 г. Г. П. Аверьянов^а, *, В. В. Дмитриева^а, **

^аНациональный исследовательский ядерный университет МИФИ, Москва, 115409 Россия

*E-mail: GPAveryanovi@mephi.ru

**E-mail: VVDmitriyeva@mephi.ru

Поступила в редакцию 21.06.2023 г.

После доработки 16.08.2023 г.

Принята к публикации 17.08.2023 г.

Рассмотрена проблема распознавания и классификации нагрузок на выходе формирующих и передающих линий с распределенными параметрами (ЛРП) в устройствах мощной импульсной техники (МИТ) по амплитуде и форме выходного сигнала с применением математических моделей на основе методов машинного обучения и нейросетей. Разработано веб-приложение, распознающее паразитные параметры, возникающие в устройствах на основе ЛРП.

Ключевые слова: электрофизика, мощные импульсные устройства, формирующие и передающие линии с распределенными параметрами, алгоритмы машинного обучения, сверточные нейронные сети

DOI: 10.56304/S2079562923030041

1. ВВЕДЕНИЕ

В практике физического эксперимента [1] и промышленной эксплуатации мощных импульсных устройств на основе линий с распределенными параметрами (ЛРП) [2] часто возникает необходимость учета паразитных параметров, возникающих вследствие наличия последовательных индуктивностей и параллельно включенных емкостей между землей и отрезками используемых соединительных проводников [3]. Мощное импульсное устройство, содержащее в своей схеме ЛРП, моделируется системой дифференциальных уравнений, описывающих топологию схемы устройства, и значениями параметров элементов моделируемой схемы [4]. Результатом моделирования является осциллограмма сигнала (тока или напряжения) на выходе схемы, характеризующая зависимость формы и амплитуды сигнала от времени.

Наличие паразитных параметров проявляется через характерное искажение формы выходного сигнала [5]. Для детектирования паразитных параметров в формирующих и передающих ЛРП мощного импульсного устройства необходимо восстановить топологию схемы и значения параметров ее элементов по осциллограмме выходного сигнала. То есть, если процесс получения осцил-

лограммы на выходе схемы по данным ее топологии и значениям параметров рассматривается как прямая задача, то процесс восстановления топологии схемы и значений параметров ее элементов по осциллограмме выходного сигнала будет по отношению к ней обратной задачей.

Осциллограмма сигнала на выходе схемы (например, выходного напряжения) представляется вектором $(U_i, t_i, i = 1 \dots N)$, описывающим функцию зависимости напряжения от времени $U(t)$, где N – количество точек осциллограммы [6]. При этом осциллограмма выходного сигнала может представлять собой достаточно сложную кусочно-гладкую функцию, которую трудно описать аналитически, поэтому для решения обратной задачи используется подход, связанный со сложными нелинейными структурами и использованием методов машинного обучения на основе нейронных сетей [9].

В данной работе рассмотрено применение таких алгоритмов машинного обучения как K-ближайших соседей (KNN), рекуррентные нейронные сети (RNN), “Случайный лес” (Random Forest) и Сверточные нейронные сети (CNN). Сравняются производительность перечисленных подхо-

дов, а также варианты их совместного использования. Для измерения точности результатов используется функционал качества, характеризующий среднюю ошибку (эмпирический риск) алгоритма на произвольной выборке [11].

2. МАТЕМАТИЧЕСКИЕ МОДЕЛИ МОЩНЫХ ИМПУЛЬСНЫХ УСТРОЙСТВ НА ОСНОВЕ ЛРП (ПРЯМАЯ ЗАДАЧА)

Для решения нестационарных задач, связанных с описанием процессов в устройствах формирования мощных высоковольтных импульсов малой длительности на основе ЛРП используются различные варианты метода характеристик решения телеграфных уравнений

$$\begin{cases} -\frac{\partial}{\partial x} u = \left(R + \rho\tau \frac{\partial}{\partial t} \right) i \\ -\rho \frac{\partial}{\partial x} i = \left(\rho G + \tau \frac{\partial}{\partial t} \right) u. \end{cases} \quad (1)$$

Здесь $u = u(x, t)$ и $i = i(x, t)$ – функции напряжения и тока в линии с распределенными электрическими параметрами: L – индуктивность, C – емкость, R – сопротивление, G – проводимость, τ – задержка (или электрической длиной), ρ – волновое сопротивление [7].

Для моделирования ЛРП с малыми потерями в проводниках и диэлектрике целесообразно использовать прямые вычислительные модели на основе преобразования Лапласа. Выражения для функций-изображений для прямых и обратных волн напряжения $\vec{V}_x(p)$ и $\bar{V}_x(p)$, представленные в операторной форме являются стандартными решениями одномерных систем телеграфных уравнений для отрезков линий:

$$\begin{cases} \vec{V}_x(p) = \frac{Z_0}{Z_0 + Z_s} + V_s(p) \Gamma_0 \sum_{k=0}^{\infty} \Gamma_l^k e^{-\gamma(2kl+x)} \\ \bar{V}_x(p) = \frac{Z_0}{Z_0 + Z_s} + V_s(p) \Gamma_0 \sum_{k=0}^{\infty} \Gamma_l^{k+1} e^{-\gamma(2(k+1)l-x)}, \end{cases} \quad (2)$$

где p – оператор Лапласа, $Z_0 = \text{const}$ – характеристический импеданс линии, V_s – функция источника (генератора напряжения), Z_s – внутренне сопротивление генератора напряжения, $\Gamma_0 = \text{const}$ – коэффициент отражения на входе линии, k – номер отраженной волны, $\Gamma_l = \Gamma_l(p)$ – коэффициент отражения нагрузки линии [8].

При необходимости учета потерь в диэлектрике для решения системы (1) использована рекуррентная конечно-разностная схема для функций напряжения и тока: $u = u(x, t)$ и $i = i(x, t)$

$$\begin{cases} u_{k+1}(t + T_k) + \rho_k i_{k+1}(t + T_k) = \\ = (1 - \rho_k g_k) u_k(t) + (\rho_k - r_k) i_k(t) \\ u_k(t + T_k) - \rho_k i_k(t + T_k) = \\ = (1 - \rho_k g_k) u_{k+1}(t) + (\rho_k - r_k) i_{k+1}(t) \end{cases}, \quad (3)$$

где величина тока $-i_{k+1}$ и напряжения $-u_{k+1}$ в секции с номером $(k + 1)$ определяются через величину тока $-i_k$ и напряжения $-u_k$, электрическую длину $-T_k$, сопротивление $-r_k$ и проводимость $-g_k$, вычисленные для предыдущего сегмента линии (с номером k).

3. МОДЕЛЬ ДАННЫХ ДЛЯ МАШИННОГО ОБУЧЕНИЯ

Важным этапом разработки модели служит понимание с какими данными предстоит работать. От этого зависит скорость работы и точность полученной в будущем модели, а также трудоемкость процесса отладки модели и оценки ее работоспособности [16].

В нашем случае входные данные формируются в результате моделирования переходных процессов в ЛРП на основе метода характеристик и операторного метода и представлены осциллограммой напряжения на нагрузке (рис. 1), параметрами входного сигнала и параметрами линии. Для формирования обучающей выборки для нейросетей был использован симулятор Longline (рис. 2). Параметры входного сигнала могут быть представлены как идеальный геометрический сигнал, который описывается дискретными параметрами, как в исследуемом случае прямоугольный импульс с параметрами амплитуды импульса и длительность импульса, так и произвольной формы, в виде дискретно-непрерывного временного ряда. Параметры линии представляют собой геометрическую длину, волновое сопротивление и задержка на единицу длины [8].

Выходные данные, которые необходимо получить, состоят из категориальной переменной, отвечающей за определение типа нагрузки. Основные данные, представленные осциллограммой, для простоты исследования, рассматриваются в виде дискретно-непрерывного временного ряда, полученный с помощью осциллографа путем

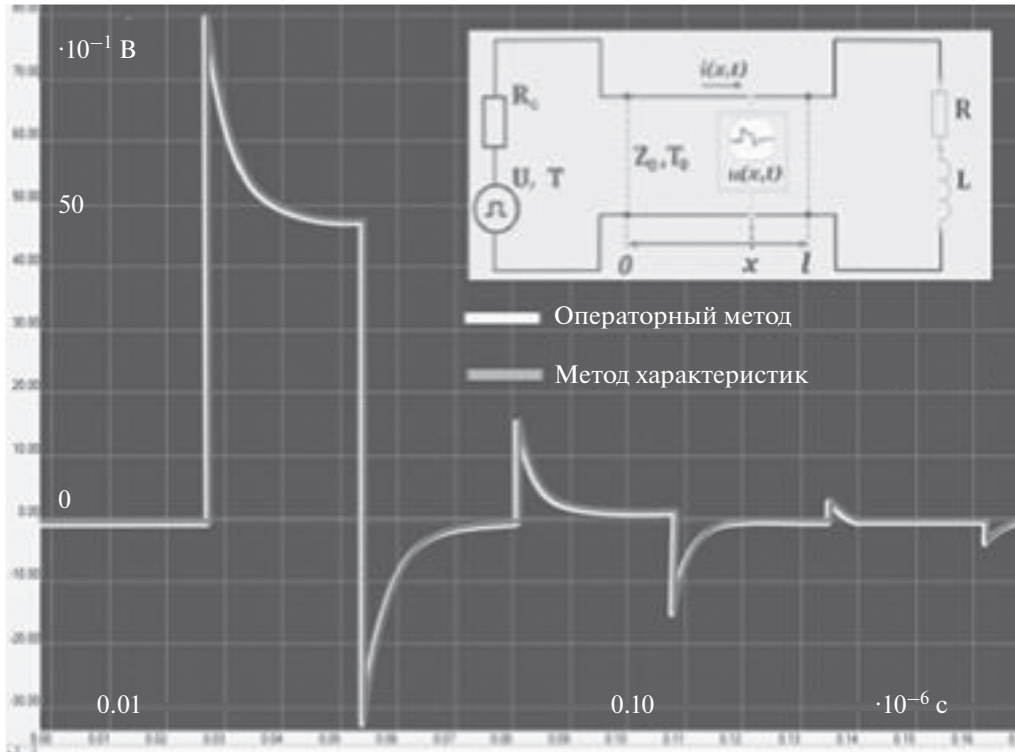


Рис. 1. Переходный процесс в ЛРП: операторного метод и метод характеристик.

преобразования графика осциллограммы и параметра развертки.

Дискретные данные не требуют особой необходимости в преобразовании, за исключением нормировки по максимальному значению выборки. Данная нормировка необходима для улучшения скорости работы модели алгоритмов. Также необходимо заранее выбрать единицы измерения, в которых изначальные данные будут использованы в виде исходных данных при моделировании [13].

В случае с импульсом входного сигнала произвольной формы, представленный (по аналогии со входной осциллограммой) в виде дискретно-непрерывного временного ряда, необходимо определить границы сигнала и преобразовать в вектор заранее заданного размера [12].

4. ВЫБОР АРХИТЕКТУРЫ НЕЙРОСЕТИ Я ДЛЯ ДЕТЕКТОРА ПАЗАРИТНЫХ ПАРАМЕТРОВ

Решение прямой задачи – моделирование формирующих и передающих ЛРП позволяет получить вектор признаков $(x_i, i = 1, N)$, описывающий исходные данные для решения обратной задачи и вектор результатов $(y_i, i = 1, N)$. При этом

получается конечная совокупность из N прецедентов (соответствий) пар (x_i, y_i) . В вектор признаков x_i входят параметры схемы и осциллограммы (ее оцифрованное изображение) на выходе ЛРП, а в вектор результата y_i входит тип топологии и значения параметров схемы и признаков классификации паразитного параметра (наличие или отсутствие паразитного параметра в схеме и тип паразитного параметра) паразитная емкость или паразитная индуктивность, и величина паразитного параметра. Таким образом строится выборка для обучения нейросетей [10].

На основе обучающей выборки разрабатывается алгоритм, который для любого вектора признаков $(x_i^*, i = 1, N)$, не входящего в обучающую выборку, выдает достаточно точный ответ о наличии или отсутствии в схеме паразитного параметра, его типе и величине.

Для измерения точности результатов используется функционал качества, характеризующий среднюю ошибку (эмпирический риск) алгоритма на произвольной выборке X^m :

$$Q(a, X^m) = \frac{1}{m} \sum_{i=1}^m \mathcal{L}(a(x_i), y^*(x_i)).$$

Функция по-

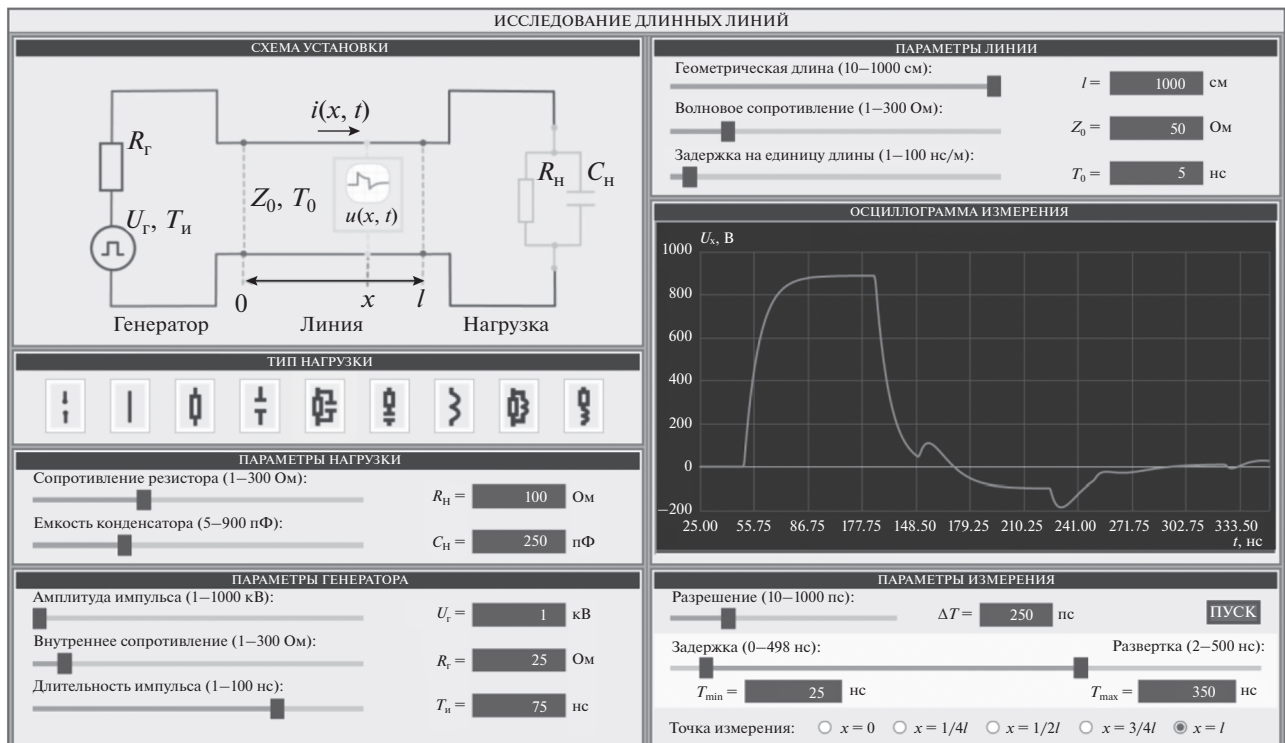


Рис. 2. Интерфейс симулятора Longline.

ть $\mathcal{L}(y, y')$, характеризует величину отклонения результата $y = a(x)$ для произвольного значения $x \in X$.

Для успешной реализации модели в инженерном подходе необходимо определить необходимую точность работы заранее [16], и сформировать соответствующий набор данных. Для выбора оптимального алгоритма и настройки его параметров были рассмотрены основные методы решения задачи “обучения с учителем” (табл. 1). При оценке точности исследованных алгоритмов использована метрика среднего абсолютного отклонения – Mean Absolute Error (MAE).

“Случайный лес”, наравне со сверточной нейронной сетью (CNN), показывает довольно высокий результат работы. Успех сверточной нейронной сети можно объяснить тем, что данный подход учитывает не только значения напряжений, взятые с нагрузки в каждой точке осциллограммы, но и значения производных за счет сверточного слоя. Таким образом CNN представляет наибольший интерес для рассмотрения [12].

Сверточная нейронная сеть (рис. 3) хорошо показала себя при работе с фиксированными данными, но в нашей задаче параметры линии и ге-

нератора импульса могут изменяться в зависимости от исходных условий. Входной сигнал был представлен прямоугольным импульсом, что значительно упрощает модель, но на практике данный сигнал имеет неидеальную форму. В таком случае, вместо параметров, описывающих сигнал, можно также, как и с осциллограммой, использовать одномерный вектор, но тогда для него стоит подготовить алгоритм преобразования, основанный, например на нескольких слоях сверточной нейронной сети [9].

Важным этапом в формировании модели служит оптимизация выбранного алгоритма работы

Таблица 1. Оценка точности алгоритмов машинного обучения

Исследуемая модель	MAE
К-ближайших соседей (KNN)	21.2
Рекуррентные нейронные сети (RNN)	12.2
“Случайный лес” (Random Forest)	8.9
Сверточные нейронные сети (CNN)	5.1

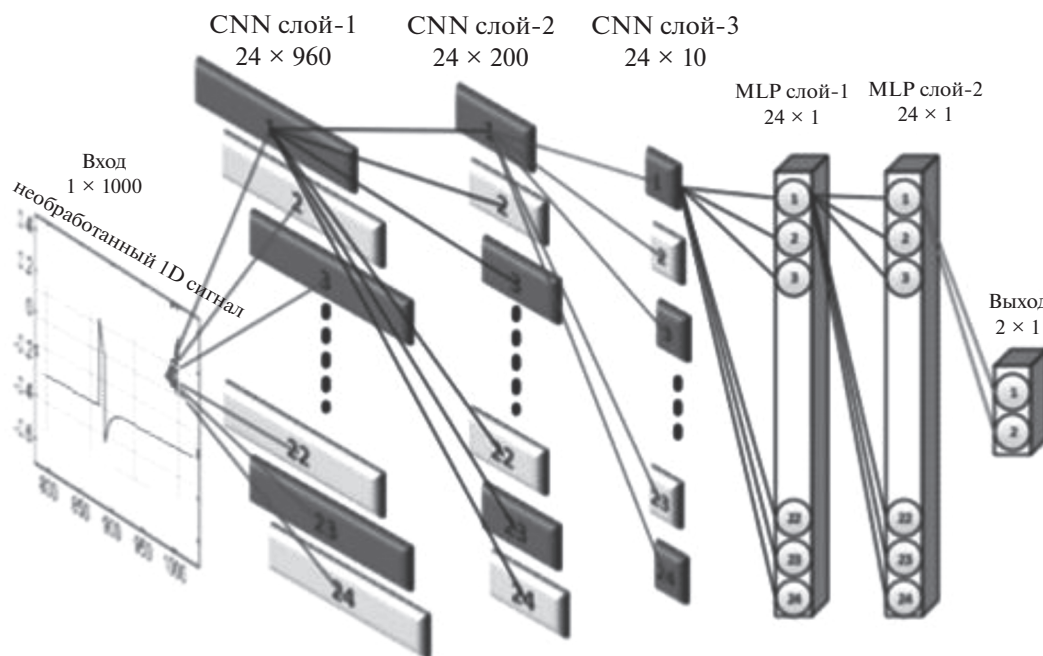


Рис. 3. Схема сверточной нейронной сети.




Рис. 4. Среднее абсолютное отклонение от количества эпох.

сверточной нейронной сети. Для этого необходимо изменить количество слоев, размерность фильтров, а также позицию, в которой добавляется дополнительная информация. Для оптимизации количества слоев будем ориентироваться на четкость и плавность фильтров, отсутствие помехов или явных признаков переобучения [10].

5. РЕАЛИЗАЦИЯ АЛГОРТМА ДЕТЕКТОРОВАНИЯ ПАРАЗИТНЫХ ПАРАМЕТРОВ НА ОСНОВЕ CNN

Получив оптимальный размер модели, можно добавить в нее параметры линии и генератора. Циклично подставив параметры в разные разрезы модели, выберем оптимальное положение [10].




Рис. 5. Среднее квадратическое отклонение от количества эпох.

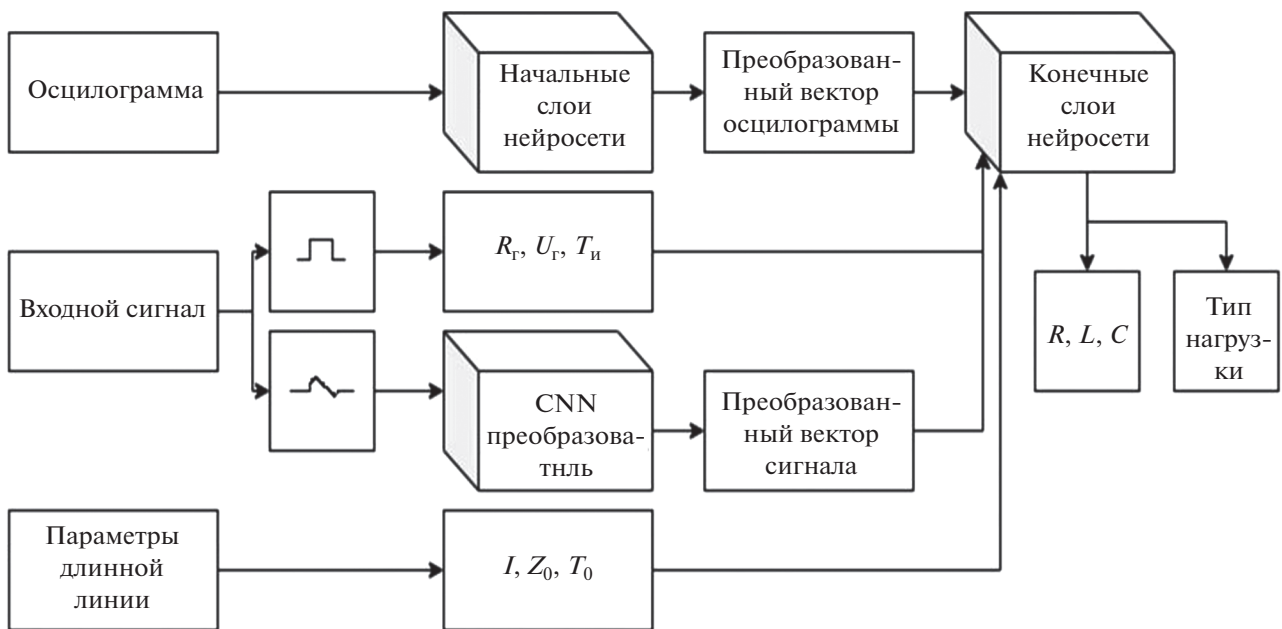


Рис. 6. Модель детектора паразитных параметров.

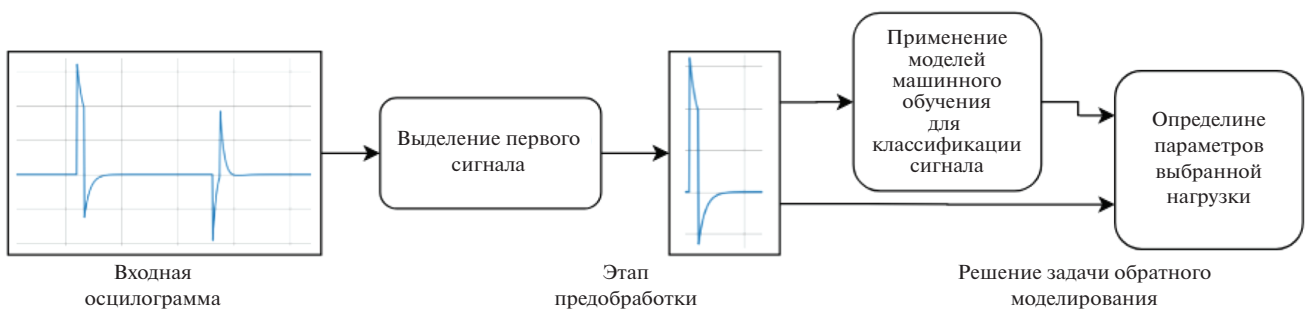


Рис. 7. Этапы оценки паразитных параметров в детекторе.

На рис. 4 и 5 представлены результаты обучения модели на основе CNN, в зависимости от количества эпох на примере среднего квадратического и среднего абсолютного отклонения обученной модели. Исходя из данных зависимостей можно сделать вывод, что для получения максимально положительного результата необходимо провести около 650 эпох обучения. Можно предположить, что для повышения точности результатов на границах параметров, нужно увеличить разброс данных для обучения [9].

Первичное тестирование модели сверточной нейронной сети показало хорошие результаты при работе с фиксированными параметрами ЛРП (волновое сопротивление и задержка на единицу длины) и генератора (внутреннее сопротивление и амплитуда, и длительность генерируемого импульса). Фиксация этих параметров позволила исключить их из набора входных данных. При этом входной сигнал представлен прямоугольным импульсом, что на первоначальном этапе значительно упрощает модель. Для моделирования сигнала произвольной формы, его, как и осциллограмму, можно представить в виде одномерного вектора [11].

Общая схема работы детектора паразитных параметров схемы при произвольном входном сигнале представлена на рис. 6. Для учета варьирования параметров ЛРП и входного сигнала произвольной формы необходима оптимизация количества слоев и размерностей фильтров сверточной нейросети [10].

Процесс оценки паразитных параметров включает несколько этапов, представленных на рис. 7. Осциллограмма, полученная с использованием модели симулятора Longline, проходит первичную обработку для получения достоверных результатов. Далее производится классификация выходного импеданса по типу паразитного параметра с нахождением значения параметров элементов выходного импеданса методом регрессии.

5. ЗАКЛЮЧЕНИЕ

Разработанная модель детектора позволяет оценить качество конструкции формирующих и передающих ЛРП в мощных импульсных устройствах. Детектирование паразитных параметров может быть весьма актуальным при монтаже и наладке оборудования для физических экспериментов. Помимо этого, данный алгоритм может оказаться эффективным в составе специализированных САПР, позволяя значительно расширить круг решаемых задач, связанных с проектированием, в приложениях по моделированию аналоговых цепей [9].

Программное обеспечение разработано в соответствии с международным стандартом ISO/IEC 12207 [13] с применением общих принципов построения интегрированных экспертных систем [14]. Организация хранения и обработки данных в реляционных БД детектора паразитных параметров соответствует стандартам современных промышленных систем управления БД [15].

СПИСОК ЛИТЕРАТУРЫ/REFERENCES

1. *Загребяев А.М., Саманчук В.Н.* // Современные научные исследования и инновации. 2015. № 2. Ч. 1. <https://web.snauka.ru/issues/2015/02/48496>.
2. *Юдин Л.И.* Генераторы импульсов больших напряжений и токов. 1983. Москва: МИФИ.
3. *Пономаренко А.Г.* Мощная импульсная техника. Ч. 1: Элементы схем и источники питания. 2007. Москва: МИФИ.
4. *Zagrebayev A.M., Ten S.V.* // Euras. J. Math. Comput. Appl. 2021 V. 9 (2). P. 101.
5. *Юдин Л.И.* Мощная импульсная техника. Ч. 2. Коммутирующие устройства. 1977. Москва: МИФИ.
6. *Юдин Л.И.* Мощная импульсная техника. Ч. 3. Импульсные схемы широкого применения. 1979. Москва: МИФИ.
7. *Аверьянов Г.П. и др.* САПР в электрофизике. Ч. 1. Основы автоматизации проектирования. 2011. Москва: НИЯУ МИФИ.
8. *Аверьянов Г.П., Гусаров В.Н., Юдин Л.И.* Лабораторный практикум по курсу “САПР УЗЧ”: Мощная импульсная техника. 1990. Москва: МИФИ.
9. *Zhang Q.J., Feng F., Na W.* // Proc. 52nd European Microwave Conf. (EuMC). 2022. P. 16.
10. *Kahng A.B.* // IEEE Design Test. 2022. V. 40. (1). P. 8.
11. *Jogin M. et al.* // Proc. 3rd IEEE Intl. Conf. Recent Trends in Electronics, Information & Communication Technology (RTEICT). 2018. P. 2319.
12. *Нгуен Т.К., Сырямкин В.И., Нгуен Ч.Х.Т.* // Современные наукоемкие технологии. 2020. № 12. С. 269.
13. *Рыбина Г.В., Смирнов В.В.* // Изв. РАН. Теория и системы управления. 2007. № 4. С. 91.
14. *Рыбина Г.В., Пышагин С.В., Смирнов В.В., Чабанев А.В.* // Программные продукты и системы. 1997. № 4. С. 37.
15. *Кузовкин А.В., Цыганов А.А., Шукин Б.А.* Управление данными. 2010. Москва: Издательский центр “Академия”.
16. *Хетагуров Я.А.* Проектирование автоматизированных систем обработки информации и управления (АСОИУ). 2015. Москва: БИНОМ. Лаборатория знаний.

Application of Machine Learning Algorithms and Neural Networks for Recognition of Parasitic Parameters by the Output Signal in High-Power Pulsed Electrophysics Devices

G. P. Averyanov^{1, *} and V. V. Dmitrieva^{1, **}

¹*National Research Nuclear University MEPHI (Moscow Engineering Physics Institute), Moscow, 115409 Russia*

**e-mail: GPAveryanovi@mephi.ru*

***e-mail: VVDmitriyeva@mephi.ru*

Received June 21, 2023; revised August 16, 2023; accepted August 17, 2023

Abstract—The problem of recognition and classification of loads at the output of generating and transmitting distributed parameter lines (DPL) in devices of high-power pulse technology (HPPT) by the amplitude and shape of the output signal using mathematical models based on machine learning methods and neural networks has been considered. A web application that recognizes parasitic parameters occurring in the devices based on DPL has been developed.

Keywords: electrophysics, high-power pulsed devices, forming and transmitting distributed parameter lines, machine learning algorithms, convolutional neural networks