

Моделирование мемристора Бернулли

Е. Б. Соловьева[✉], А. П. Сердюк

Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

[✉] selenab1@yandex.ru

Аннотация. Рассмотрено применение метода расщепления сигналов для поведенческого моделирования электрического нелинейного элемента – мемристора. Поведенческие модели построены на классе гармонических сигналов для передаточной характеристики, которая описывает соотношение вход-выход мемристора Бернулли. Расщепитель реализован в виде линии задержки. Математическими формами моделей выбраны кусочная нейронная и кусочная полиномиальная. Кусочное представление моделей обусловлено существенной нелинейностью передаточной характеристики мемристора Бернулли. Погрешность моделирования оценивалась в равномерной и среднеквадратичной метриках. В результате сравнительного анализа установлено, что кусочная нейронная модель дает более высокую точность аппроксимации по сравнению с кусочной многомерной полиномиальной моделью передаточной характеристики мемристора Бернулли.

Ключевые слова: мемристор, моделирование, математическая модель, полином, нейронная сеть

Для цитирования: Соловьева Е. Б., Сердюк А. П. Моделирование мемристора Бернулли // Изв. СПбГЭТУ «ЛЭТИ». 2026. Т. 19, № 3. С. 84–90. doi: 10.32603/2071-8985-2026-19-3-84-90.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Original article

Bernoulli Memristor Modeling

Е. В. Solovyeva[✉], A. P. Serdyuk

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia

selenab1@yandex.ru

Abstract. Application of the signal splitting method for behavioral modeling of electrical nonlinear element – a memristor is considered. Behavioral models based on a harmonic signal class are built for the transfer characteristic, which describes the input-output relationship of the Bernoulli memristor. A splitter is implemented as a delay line. A piecewise neural network and a piecewise polynomial are specified as the mathematical forms of models. The piecewise representation of models is driven by the severely nonlinear transfer characteristic of the Bernoulli memristor. The modeling error is estimated on the basis of the uniform and root-mean-square norms. Comparative analysis shows that the piecewise neural model of the transfer characteristic for the Bernoulli memristor gives higher approximation accuracy in comparison with the piecewise multidimensional polynomial model.

Keywords: memristor, modelling, mathematical model, polynomial, neural network

For citation: Solovyeva E. B., Serdyuk A. P. Bernoulli Memristor Modeling // LETI Transactions on Electrical Engineering & Computer Science. 2026. Vol. 19, no. 3. P. 84–90. doi: 10.32603/2071-8985-2026-19-3-84-90.

Conflict of interests. The authors declare no conflicts of interests.

Введение. Поведенческое моделирование физических объектов предполагает построение математических моделей с использованием множеств

входных и выходных сигналов [1], [2]. Такой подход весьма эффективен, когда моделирование на компонентном уровне невозможно (недостаточно инфор-

мации) или слишком сложное. Принцип «черного ящика», как иногда называют указанный подход, универсален, поскольку не зависит от физических процессов, протекающих в объектах моделирования. В результате область его применения обширна: от аналоговой и цифровой техники до систем искусственного интеллекта [3]–[5].

К универсальным поведенческим моделям относятся: функциональный ряд и полином Вольтерры [1], [2], [4], многочлены расщепленных сигналов [3], [6], регрессионные модели (по большей части рекуррентные) [5], нейронные сети разной архитектуры [7]. Каждый из указанных классов моделей обладает своими достоинствами и недостатками и используется для решения конкретных задач, поскольку общего универсального метода моделирования нелинейных динамических объектов не существует.

В статье рассматривается поведенческое моделирование мемристоров на основе многомерных многочленов и полносвязных нейронных сетей с расщепленными сигналами. Мемристор – четвертый пассивный нелинейный электрический элемент. Мемристор обладает следующими основными достоинствами: наноразмерность, высокая скорость переключения, надежное и долговременное хранение установленного сопротивления, малое потребление энергии, совместимость с КМОП-элементами [8]–[10]. Разнообразие материалов и технологий производства привело к созданию разных математических моделей этого элемента [11]–[13] и затруднило практическое моделирование устройств на его основе (мемристивных устройств). Универсальный подход к моделированию мемристоров, изложенный в этой статье, позволяет решить указанную проблему в рамках принципа «черного ящика».

Поведенческая модель на базе расщепленных сигналов. Построение поведенческой модели включает расщепление входных сигналов и их последующее нелинейное преобразование. Расщепление обеспечивает свойство однозначности для модели устройства [3], [6]. Согласно методу расщепления, математический оператор устройства реализует два действия, показанные на рис. 1: расщепление (оператор S) и нелинейное преобразование (оператор N). Операторы S и N описывают динамические и нелинейные процессы соответственно.

В результате расщепления входного скалярного сигнала формируется векторный сигнал, фазовые портреты элементов (расщепленных сигналов) которого не равны нулю, не касаются друг друга и не

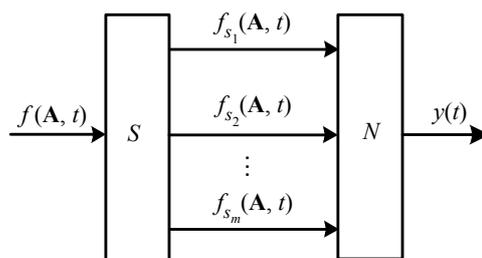


Рис. 1. Структура оператора нелинейного устройства

Fig. 1. The structure of nonlinear device operator

пересекаются [3], [6]. Вектор расщепленных сигналов на рис. 1 записывается в виде

$$S[f(\mathbf{A}, t)] = \begin{bmatrix} f_{s_1}(\mathbf{A}, t) \\ f_{s_2}(\mathbf{A}, t) \\ \vdots \\ f_{s_m}(\mathbf{A}, t) \end{bmatrix}, \quad (1)$$

где S – оператор, который расщепляет входной скалярный сигнал $f(\mathbf{A}, t)$ в пространстве воздействия; \mathbf{A} – вектор параметров входного сигнала в пространстве их определения; $f_{s_m}(\mathbf{A}, t)$ – m -й элемент вектора расщепленных сигналов.

Далее векторный сигнал $S[f(\mathbf{A}, t)]$ подвергается нелинейному преобразованию (оператор N на рис. 1). Длину этого вектора (1) желательно выбирать минимальной. Действительно, при выполненном расщеплении сигналов дальнейший рост длины вектора ведет лишь к увеличению мерности (сложности) нелинейной модели без существенного повышения получаемой точности.

Входной скалярный сигнал $f(\mathbf{A}, t)$ можно расщепить с помощью линейных и нелинейных, стационарных и нестационарных преобразователей [3], [6]. Расщепители выбираются на основе двух факторов: минимальности длины вектора расщепленных сигналов в выражении (1) и простоты реализации преобразователя. Например, для гармонического сигнала, применяемого для частотного и спектрального анализов, эффективным расщепителем во времени по параметрам сигнала служит линия задержки, дающая малое число каналов расщепления (два канала на рис. 2) при простой физической реализации в аналоговой и цифровой областях [3], [6]. На рис. 2 показана структура линии задержки для расщепления гармонического сигнала $A \sin(\bar{t})$, где A – амплитуда, параметр входного сигнала в пространстве его задания; $\bar{t} = \omega_0 t$, $\bar{t} \in [0, 2\pi)$ – нормированное время; ω_0 – угловая частота; \bar{t}_0 – время задержки, S – оператор-расщепитель.

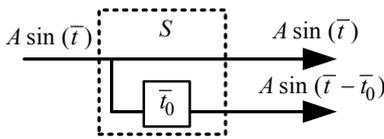


Рис. 2. Структура расщепителя в виде линии задержки
Fig. 2. The splitter structure as the delay line

Нелинейный оператор N формирует скалярный выходной сигнал $y(t)$ устройства на базе вектора расщепленных сигналов (рис. 1). В качестве математических форм этого оператора применяются многомерные полиномы, различные архитектуры нейронных сетей, регрессионные структуры [3], [6].

Кусочные нейронная и полиномиальная модели с расщепителем для мемристора Бернулли. Построим нейронную и полиномиальные модели с расщепителем для описания передаточной (ампер-вольтной) характеристики мемристора Бернулли и сравним полученные модели с точки зрения их сложности и точности преобразований. Мемристор с электрическими сигналами изображен на рис. 3. Входной и выходной сигналы мемристора – напряжение $v(\bar{t})$ и ток $i(\bar{t})$ соответственно.

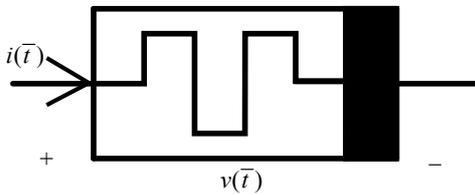


Рис. 3. Представление мемристора в принципиальных схемах
Fig. 3. The memristor representation in principle diagrams

Напряжение $v(\bar{t})$ опишем как гармонический сигнал

$$v(\bar{t}) = A \sin(\bar{t}), \quad (2)$$

где A – амплитуда сигнала на множестве $A \in (-0.5; 1]$.

Ток мемристора находится в результате решения дифференциального уравнения Бернулли [14], [15]:

$$\frac{di(\bar{t})}{d\bar{t}} - \frac{dv(\bar{t})}{d\bar{t}} \frac{1}{v(\bar{t})} i(\bar{t}) = -\frac{c_2}{v(\bar{t})} [i(\bar{t})]^{\gamma+2}, \quad (3)$$

где $\gamma = -1, -2$ – положительная целая константа;

$c_2 = \frac{dM(q(\bar{t}))}{dq(\bar{t})}$ – переменная, зависящая от физической структуры мемристора; $q(\bar{t})$ – заряд;

$M(q(\bar{t}))$ – мемристанс. Скорость изменения мемристанса описывается уравнением:

$$\frac{dM(q(\bar{t}))}{d\bar{t}} = d_2 i^\gamma(\bar{t}) = \frac{dM(q(\bar{t}))}{dq(\bar{t})} i^\gamma(\bar{t}).$$

В результате аналитического решения уравнения (3) получим [14], [15]:

$$i(\bar{t}) = \frac{v(\bar{t})}{M_0 \left[1 + \beta_2 \int_0^{\bar{t}} v^\gamma(\tau) d\tau \right]^{1/\gamma+1}}, \quad (4)$$

где $M_0 = v(0)/i(0)$; $\beta_2 = (\gamma + 1)c_2 A / M_0^{\gamma+1}$; τ – переменная интегрирования. Пусть $\gamma = 1$, $M_0 = 2$, $c_2 = 2$ при гармоническом воздействии (2), тогда переменная $\beta_2 = A$, а выражение (4) запишем как

$$i(\bar{t}) = \frac{A \sin(\bar{t})}{M_0 [1 + \beta_2 (1 - \cos(\bar{t}))]^{1/2}}, \quad (5)$$

$$i(\bar{t}) = \frac{A \sin(\bar{t})}{2 [1 + A(1 - \cos(\bar{t}))]^{1/2}}.$$

Поведенческие модели мемристора Бернулли аппроксимируют отображение пространства $A \times \bar{t} = (-0.5; 1] \times [0, 2\pi)$ входных сигналов (2) на пространство выходных сигналов, которые вычисляются по выражению (5). Отображение вход-выход существенно нелинейно, как следует из (5). Для повышения точности моделирования используем совокупность кусочных моделей на подпространствах. Для этого множество амплитуд воздействия $A \in (-0.5; 1]$ разделим на пять подмножеств: $(-0.5; -0.45]$, $(-0.45; -0.4]$, $(-0.4; 0)$, $(0; 0.5)$, $[0.5; 1]$. Внутри каждого подмножества выберем значения амплитуд для построения кусочных моделей. Эти значения показаны на рис. 4.

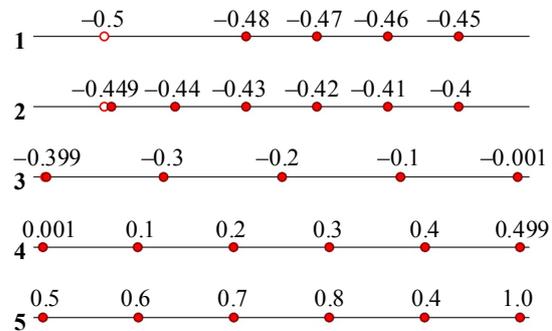


Рис. 4. Значения амплитуд входного сигнала для построения кусочных моделей
Fig. 4. Amplitudes of the input signal on building the piecewise models

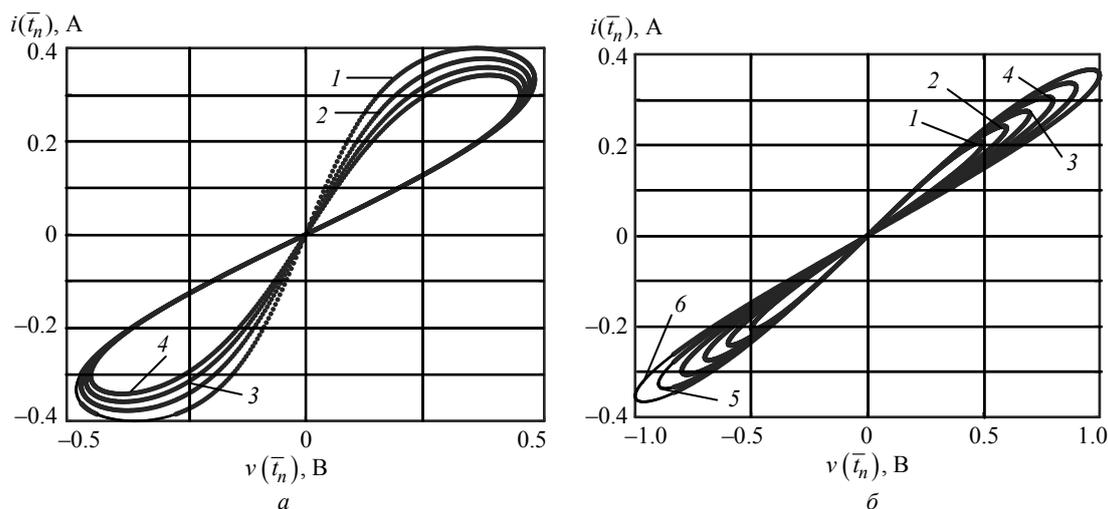


Рис. 5. Передаточные характеристики мемристора Бернулли, полученные на подмножествах 1 (а) и 5 (б) амплитуды входного сигнала

Fig. 5. Transfer characteristics of the Bernoulli memristor obtained for subsets 1 (a) and 5 (б) of the input signal amplitude

Передаточные характеристики мемристора Бернулли получены из выражения (5) на подмножествах 1 и 5 амплитуды воздействия (рис. 5). Эти характеристики в виде гистерезисных кривых, сжатых в начале координат, изображены на рис. 5, увеличение номера кривых соответствует росту амплитуд в подмножествах 1 и 5 на рис. 5.

Как видно из рис. 5, ампер-вольтные характеристики мемристора Бернулли существенно нелинейны, следовательно, кусочный подход для поведенческого моделирования мемристора Бернулли целесообразен. При таком подходе общая задача аппроксимации передаточных характеристик, имеющая высокую размерность, разбивается на несколько задач аппроксимации с меньшими размерностями, и совокупность кусочных моделей обеспечивает более высокую точность моделирования по сравнению с общей сложной моделью [16].

Для кусочной аппроксимации передаточной характеристики мемристора Бернулли используем нейронную и полиномиальную модели. Кусочная нейронная модель содержит пять полносвязных нейронных сетей (по числу подмножеств амплитуды входного сигнала). Входной сигнал каждой нейронной сети – вектор с двумя расщепленными сигналами, показанными на рис. 2. Каждая нейронная сеть имеет размер $3 \times 2 \times 1$ (20 параметров), т. е. три слоя, два из которых скрытые. Функции активации в скрытых слоях – гиперболические тангенсы. Общее число параметров кусочной нейронной модели равно 100. Отметим, что увеличение числа скрытых слоев до двух повышает точность моделирования, поскольку в

первом слое описываются локальные признаки преобразования сигналов в выделяемых областях, а во втором скрытом слое – глобальные признаки – результат обобщения признаков предыдущего слоя [17]. Обучение нейронной модели выполнено на основе алгоритма обратного распространения ошибки с оптимизацией Маркварда–Левенберга [17].

Кусочная полиномиальная модель содержит пять (по числу подмножеств амплитуды воздействия) двумерных полиномов, базовые функции в них – расщепленные сигналы, представленные на рис. 2. Каждый двумерный полином имеет вид

$$y_k(\bar{t}) = \sum_{j_1=0}^{J_1} \sum_{j_2=0}^{J_2} C_{k,j_1j_2} [A \sin(\bar{t})]^{j_1} \times [A \sin(\bar{t} - \bar{t}_0)]^{j_2}, \quad k = 1, 2, \dots, 5, \quad (6)$$

где k – номер подмножества амплитуды входного сигнала; $J = J_1 + J_2$ – порядок полинома.

Порядки полиномов в (6) выбраны следующие: $J = 6$ (число параметров 27) для первого подмножества амплитуды воздействия, $J = 5$ (число параметров 20) – на каждом из четырех остальных подмножеств. Таким образом, общее число параметров кусочной полиномиальной модели равно 107 ($107 = 27 + 20 \cdot 4$, получено из расчета параметров всех полиномов).

Для оценки точности построенных моделей внутри каждого подмножества амплитуды входного сигнала (2) использованы три ($\theta = 1, 2, 3$) значения, которые не совпадают со значениями, показанными на рис. 4. Выбранные амплитуды из каждого подмножества образуют векторы:

$$\begin{aligned} \mathbf{A}_{t1} &= [-0.475; -0.465; -0.455], \\ \mathbf{A}_{t2} &= [-0.445; -0.425; -0.405], \\ \mathbf{A}_{t3} &= [-0.35; -0.25; -0.05], \\ \mathbf{A}_{t4} &= [0.05; 0.25; 0.45], \\ \mathbf{A}_{t5} &= [0.55; 0.75; 0.95], \end{aligned}$$

где числовой индекс (1, 2, ..., 5) каждого вектора обозначает номер подмножества на рис. 4.

Погрешности моделирования на подмножествах амплитуды входного сигнала вычислялись по формулам:

– максимальная нормированная погрешность

$$\bar{\Delta}_{\max}(k) = \max_{\theta=1,2,3} \left(\max_{\bar{t}_n \in (0, 2\pi)} (|\bar{\Delta}_{k,\theta}(\bar{t}_n)|) \right), \quad (7)$$

$$n = 1, 2, \dots, 628, \quad k = 1, 2, \dots, 5, \quad \theta = 1, 2, 3,$$

где

$$\bar{\Delta}_{k,\theta}(\bar{t}_n) = \frac{(i(\bar{t}_n) - y_{k,\theta}(\bar{t}_n))}{\max_{\bar{t}_n \in (0, 2\pi)} (|i(\bar{t}_n)|)},$$

$$n = 1, 2, \dots, 628, \quad k = 1, 2, \dots, 5, \quad \theta = 1, 2, 3$$

– нормированная (приведенная) погрешность; \bar{t}_n – отсчеты нормированного времени в интервале $y_1(\bar{t}_n)$; $i(\bar{t}_n)$ – выходной сигнал мемристора Бернулли из выражения (5); $y_{k,\theta}(\bar{t}_n)$ – выходной сигнал кусочной модели; k – номер подмножества амплитуды входного сигнала (2); θ – номер элемента в векторе \mathbf{A}_{tk} .

– среднеквадратичная погрешность

$$\varepsilon_{k,\theta} = \sqrt{\frac{1}{Q} \sum_{q=1}^Q \left(\frac{i(\bar{t}_q) - y_{k,\theta}(\bar{t}_q)}{\max_{\bar{t}_n \in (0, 2\pi)} (|i(\bar{t}_n)|)} \right)^2},$$

$$Q = 628, \quad k = 1, 2, \dots, 5, \quad \theta = 1, 2, 3,$$

\bar{t}_q – отсчет q нормированного времени,

$$\varepsilon(k) = (\varepsilon_{k,1} + \varepsilon_{k,2} + \varepsilon_{k,3})/3. \quad (8)$$

Графики погрешностей $\bar{\Delta}_{\max}(k)$ (7) и $\varepsilon(k)$ (8), вычисленных на подмножествах $k = 1, 2, \dots, 5$, показаны на рис. 6. Кривые 1 и 2 получены, соответственно, при кусочно-полиномиальном и кусочно-нейронном моделировании мемристора Бернулли.

Из рис. 6 следует, что на всех подмножествах амплитуды входного сигнала (2) кусочная нейронная модель превосходит по точности кусочную полиномиальную модель передаточной характеристики мемристора Бернулли в среднеквадратичной и равномерной метриках. При этом сложности нейронной (100 параметров) и полиномиальной (107 параметров) моделей практически одинаковы.

Заключение. Среди способов поведенческого моделирования устройств выделен метод расщепленных сигналов как наиболее перспективный в силу адаптивности математической модели к классу входных сигналов и возможности изменения математической формы модели (от полиномиальной до нейронной). Моделирование существенно нелинейных устройств целесообразно

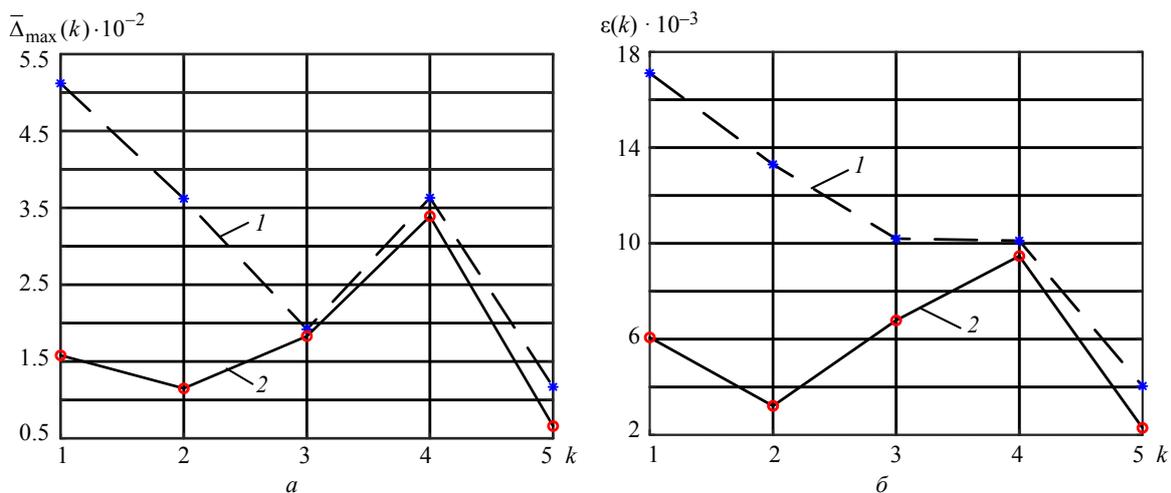


Рис. 6. Погрешности $\bar{\Delta}_{\max}(k)$ (а) и $\varepsilon(k)$ (б) при кусочно-полиномиальном (кривая 1) и кусочно-нейронном (кривая 2) моделировании мемристора Бернулли
Fig. 6. Errors $\bar{\Delta}_{\max}(k)$ (a) and $\varepsilon(k)$ (b) of the piecewise polynomial (curve 1) and piecewise neural (curve 2) modeling of the Bernoulli memristor

на основе кусочных моделей, которые строятся на подмножествах областей определения входных и выходных сигналов. В этом случае общая задача аппроксимации высокой размерности разбивается на несколько подзадач меньших размерностей и, следовательно, точность поведенческого моделирования повышается.

Математическое моделирование выполнено для мемристора Бернулли. Оценены погрешности

моделирования в равномерной и среднеквадратичной метриках в результате аппроксимации передаточной характеристики с помощью кусочной нейронной и кусочной полиномиальной моделей, построенных на базе расщепленных сигналов. Анализ погрешностей показал преимущество кусочной нейронной модели над кусочной полиномиальной моделью при практически одинаковой их сложности.

Список литературы

1. Данилов Л. В., Соловьева Е. Б. Макромоделирование существенно нелинейных электрических цепей на основе функциональных полиномов // Изв. вузов. Радиоэлектроника. 1990. Т. 33, № 6. С. 3–7.
2. Wu P., Zhao Ya., Xu X. Power spectral density analysis for nonlinear systems based on Volterra series // Appl. Math. and Mechan. (English Ed.). 2021. Vol. 42. P. 1743–1758. doi: 10.1007/s10483-021-2794-7.
3. Соловьева Е. Б. Компенсация нелинейных искажений сигналов в каналах связи методом расщепления // Цифровая обработка сигналов. 2005. № 4. С. 2–8.
4. Solovyeva E. B. Dynamic deviation Volterra pre-distorter designed for linearizing power amplifiers // Radioelectronics and Communications Syst. 2011. Vol. 54, no. 10. P. 546–553. doi: 10.3103/S073527271100049.
5. Separable nonlinear least squares for estimating nonlinear regression model / M. Jaber, M. Muftah, Y. Hamad, F. Hamad // Intern. J. of Appl. Research. 2024. Vol. 10, no. 5. Part C. P. 184–188. doi: 10.22271/allresearch.2024.v10.i5c.11750.
6. Solovyeva E. A split signal polynomial as a model of an impulse noise filter for speech signal recovery // J. of Phys.: Conf. Ser. 2016. Vol. 803. P. 012156. doi: 10.1088/1742-6596/803/1/012156.
7. Hussain H., Tamizharasan P. S., Rahul C. S. Design possibilities and challenges of DNN models: a review on the perspective of end devices // Artificial Intelligence Rev. 2022. Vol. 55, no. 13. P. 5109–5167. doi: 10.1007/s10462-022-10138-z.
8. The growing memristor industry / M. Lanza, S. Pazos, F. Aguirre, A. Sebastian, M. Le Gallo, S. M. Alam, S. Ikegawa, J. Joshua Yang, E. Vianello, M.-F. Chang, G. Molas, I. Naveh, D. Ielmini, M. Liu, J. B. Roldan // Nature. 2025. Vol. 640. Art. 8059. P. 613–622. doi: 10.1038/s41586-025-08733-5.
9. Kim Y., Jang H. W. Designing memristive materials for artificial dynamic intelligence // Advanced Intelligent Discovery. 2025. Art. 2500020. P. 1–35. doi: 10.1002/aidi.202500020.
10. Memristor-based neural networks: A bridge from device to artificial intelligence / Z. Cao, B. Sun, G. Zhou, Sh. Mao, Sh. Zhu, J. Zhang, Ch. Ke, Y. Zhao, J. Shao // Nanoscale Horizons. 2023. Vol. 8, no. 6. P. 716–745. doi: 10.1039/d2nh00536k.
11. From fundamentals to frontiers: a review of memristor mechanisms, modeling and emerging applications / P. Thakkar, J. Gosai, H. J. Gogoid, A. Solanki // J. of Materials Chem. C. 2024. Vol. 12, no. 5. P. 1583–1608. doi: 10.1039/D3TC03692H.
12. Mladenov V. Unified and Open LTSPICE Memristor Model Library // Electronics. 2021. Vol. 10, no. 13. Art. 1594. P. 1–27. doi: 10.3390/electronics10131594.
13. Mladenov V. Application and analysis of modified metal-oxide memristor models in electronic devices // Technol. 2023. Vol. 11, no. 1. P. 1–20. doi: 10.3390/technologies11010020.
14. Device properties of Bernoulli memristors / P. S. Georgiou, M. Barahona, S. N. Yaliraki, E. M. Drakakis // Proc. of the IEEE. 2012. Vol. 100, no. 6. P. 1938–1950. doi: 10.1109/JPROC.2011.2164889.
15. Drakakis E. M., Yaliraki S. N., Barahona M. Memristors and Bernoulli dynamics // 12th Intern. Workshop on Cellular Nanoscale Networks and their Appl. (CNNA 2010). Berkeley, CA, USA: IEEE, 2010. P. 1–6. doi: 10.1109/CNNA.2010.5430324.
16. Voloshinov V. V., Sokolov A. Piecewise linear approximations in the balanced identification of models with differential equations // Optimization and Applications (OPTIMA 2024). Lecture Notes in Comp. Sci. (LNCS). 2025. Vol. 15218. P. 69–82. doi: 10.1007/978-3-031-79119-2_6.
17. Setoodeh P., Habibi S., Haykin S. Nonlinear filters: Theory and applications. NJ, USA: John Wiley & Sons, 2022. 304 p.

Информация об авторах

Соловьева Елена Борисовна – д-р техн. наук, зав. кафедрой теоретических основ электротехники СПбГЭТУ «ЛЭТИ». Почетный работник сферы образования РФ.

E-mail: selenabl@yandex.ru

<https://orcid.org/0000-0001-8204-6632>

Сердюк Артем Петрович – аспирант гр. 3943, ассистент кафедры теоретических основ электротехники СПбГЭТУ «ЛЭТИ».

E-mail: serduk_artem_99@mail.ru

References

1. Danilov L. V., Soloveva E. B. Makromodelirovanie sushhestvenno nelinejnyh elektricheskikh tsepej na osnove funkcionalnyh polinomov // *Izv. vuzov. Radioelektronika*. 1990. T. 33, № 6. S. 3–7. (In Russ.).
2. Wu P., Zhao Ya., Xu X. Power spectral density analysis for nonlinear systems based on Volterra series // *Appl. Math. and Mechan.* (English Ed.). 2021. Vol. 42. P. 1743–1758. doi: 10.1007/s10483-021-2794-7.
3. Solovyeva E. B. Kompensatsija nelinejnyh iskazhenij signalov v kanalah svjazi metodom rassheplenija // *Tsifrovaja obrabotka signalov*. 2005. № 4. S. 2–8. (In Russ.).
4. Solovyeva E. B. Dynamic deviation Volterra predistorter designed for linearizing power amplifiers // *Radioelectronics and Communications Syst.* 2011. Vol. 54, no. 10. P. 546–553. doi: 10.3103/S073527271100049.
5. Separable nonlinear least squares for estimating nonlinear regression model / M. Jaber, M. Muftah, Y. Hamad, F. Hamad // *Intern. J. of Appl. Research*. 2024. Vol. 10, no. 5. Part C. P. 184–188. doi: 10.22271/allresearch.2024.v10.i5c.11750.
6. Solovyeva E. A split signal polynomial as a model of an impulse noise filter for speech signal recovery // *J. of Physics: Conf. Series*. 2016. Vol. 803. P. 012156. doi: 10.1088/1742-6596/803/1/012156.
7. Hussain H., Tamizharasan P. S., Rahul C. S. Design possibilities and challenges of DNN models: a review on the perspective of end devices // *Artificial Intelligence Rev.* 2022. Vol. 55, no. 13. P. 5109–5167. doi: 10.1007/s10462-022-10138-z.
8. The growing memristor industry / M. Lanza, S. Pazos, F. Aguirre, A. Sebastian, M. Le Gallo, S. M. Alam, S. Ikegawa, J. Joshua Yang, E. Vianello, M.-F. Chang, G. Molas, I. Naveh, D. Ielmini, M. Liu, J. B. Roldan // *Nature*. 2025. Vol. 640. Art. 8059. P. 613–622. doi: 10.1038/s41586-025-08733-5.
9. Kim Y., Jang H. W. Designing memristive materials for artificial dynamic intelligence // *Advanced Intelligent Discovery*. 2025. Art. 2500020. P. 1–35. doi: 10.1002/aidi.202500020.
10. Memristor-based neural networks: A bridge from device to artificial intelligence / Z. Cao, B. Sun, G. Zhou, Sh. Mao, Sh. Zhu, J. Zhang, Ch. Ke, Y. Zhao, J. Shao // *Nanoscale Horizons*. 2023. Vol. 8, no. 6. P. 716–745. doi: 10.1039/d2nh00536k.
11. From fundamentals to frontiers: a review of memristor mechanisms, modeling and emerging applications / P. Thakkar, J. Gosai, H. J. Gogoid, A. Solanki // *J. of Materials Chem. C*. 2024. Vol. 12, no. 5. P. 1583–1608. doi: 10.1039/D3TC03692H.
12. Mladenov V. Unified and Open LTSPICE Memristor Model Library // *Electronics*. 2021. Vol. 10, no. 13. Art. 1594. P. 1–27. doi: 10.3390/electronics10131594.
13. Mladenov V. Application and analysis of modified metal-oxide memristor models in electronic devices // *Technol.* 2023. Vol. 11, no. 1. P. 1–20. doi: 10.3390/technologies11010020.
14. Device properties of Bernoulli memristors / P. S. Georgiou, M. Barahona, S. N. Yaliraki, E. M. Drakakis // *Proc. of the IEEE*. 2012. Vol. 100, no. 6. P. 1938–1950. doi: 10.1109/JPROC.2011.2164889.
15. Drakakis E. M., Yaliraki S. N., Barahona M. Memristors and Bernoulli dynamics // *12th Intern. Workshop on Cellular Nanoscale Networks and their Appl.* (CNNA 2010). Berkeley, CA, USA: IEEE, 2010. P. 1–6. doi: 10.1109/CNNA.2010.5430324.
16. Voloshinov V. V., Sokolov A. Piecewise linear approximations in the balanced identification of models with differential equations // *Optimization and Applications (OPTIMA 2024). Lecture Notes in Comp. Sci. (LNCS)*. 2025. Vol. 15218. P. 69–82. doi: 10.1007/978-3-031-79119-2_6.
17. Setoodeh P., Habibi S., Haykin S. *Nonlinear filters: Theory and applications*. NJ, USA: John Wiley & Sons, 2022. 304 p.

Information about the authors

Elena B. Solovyeva – Dr Sci. (Eng.), Head of Department of Theoretical Fundamentals of Electrical Engineering, Saint Petersburg Electrotechnical University. Honorary Worker of the Education Sphere of the Russian Federation.

E-mail: selenabl@yandex.ru

<https://orcid.org/0000-0001-8204-6632>

Artyom P. Serdyuk – postgraduate student gr. 3943, Assistant of Department of Theoretical Fundamentals of Electrical Engineering, Saint Petersburg Electrotechnical University.

E-mail: serduk_artem_99@mail.ru

Статья поступила в редакцию 30.11.2025; принята к публикации после рецензирования 03.02.2026; опубликована онлайн 30.03.2026.

Submitted 30.11.2025; accepted 03.02.2026; published online 30.03.2026.
