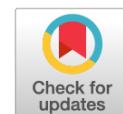


DOI: <https://doi.org/10.17816/gc623345>

Принципы аналоговых нейроморфных вычислений: от компонент до систем и алгоритмов

В.А. Демин^{1*}, А.В. Емельянов^{1, 2}, К.Е. Никируй¹, И.А. Суражевский¹, А.В. Ситников^{1, 3},
В.В. Рыльков¹, П.К. Кашкаров^{1, 2}, М.В. Ковальчук^{1, 2, 4}

¹ Национальный исследовательский центр «Курчатовский институт», Москва, Российская Федерация;

² Московский физико-технический институт, Московская область, Долгопрудный, Российская Федерация;

³ Воронежский государственный технический университет, Воронеж, Российская Федерация;

⁴ Московский государственный университет имени М.В. Ломоносова, Москва, Российская Федерация

АННОТАЦИЯ

В настоящем докладе представлено текущее состояние дел в реализации аппаратных ускорителей искусственного интеллекта на базе практически успешных нейросетевых алгоритмов первого и второго поколений на основе формальных нейронных сетей (ФНС), отмечаются недостатки существующих решений и намечаются пути их преодоления с использованием аналоговых нейроморфных архитектур.

Последние создаются на принципах строения и функционирования живой нервной системы, с использованием искусственных нейронов и моделей синаптических контактов — так называемых мемристоров, электрически перезаписываемых наноразмерных элементов энергонезависимой памяти [1–3]. С применением этих элементов возможно как существенное увеличение производительности и энергоэффективности ускорителей алгоритмов на базе ФНС [4–6], так и формирование перспективных вычислительных систем на основе биоподобных нейросетевых алгоритмов 3-го поколения — импульсных, или спайковых, нейронных сетей (СНС) [7–9].

Обсуждаются оригинальный способ обоснования оптимальных правил локальной настройки синаптических связей СНС с частотным кодированием информации и возможность их реализации в виде правил ассоциативного обучения типа динамической пластичности, зависящей от временных интервалов между импульсами (STDP) [10]. Продемонстрированы результаты по исследованию устойчивости обучения СНС к вариабельности характеристик мемристоров как аналоговых элементов, а также к использованию шума в качестве конструктивного фактора при обучении и удержании мемристивных весов импульсной сети [7, 11].

Обсуждаются также подходы к реализации локальных правил дофаминоподобного обучения с подкреплением в СНС, которые необходимы для формирования аналога системы «потребностей» интеллектуального агента в процессе его автономного функционирования [12–14]. Рассмотрены первые результаты по созданию прототипа мемристивного имплантируемого устройства, нейропротезирующего двигательную активность животного [15, 16].

Наконец, демонстрируются возможные аппаратные решения как для нейрональных элементов, так и для синаптических связей на базе перспективных мемристивных устройств, подходящих для указанных типов локального обучения, представлены концепция и первые результаты по созданию аналогового нейроморфного процессора на базе вышеуказанных компонент.

Таким образом, даётся попытка систематизации существующих и авторских оригинальных способов реализации энергоэффективных компактных аналоговых нейроморфных вычислительных систем искусственного интеллекта, функционирующих в режиме реального времени и (само-)обучаемых в течение всего срока службы устройства.

Ключевые слова: нейроморфные вычисления; мемристор; спайковые нейронные сети; STDP; обучение без учителя; дофаминоподобное обучение с подкреплением; нейрогибридные системы.

Как цитировать:

Демин В.А., Емельянов А.В., Никируй К.Е., Суражевский И.А., Ситников А.В., Рыльков В.В., Кашкаров П.К., Ковальчук М.В. Принципы аналоговых нейроморфных вычислений: от компонент до систем и алгоритмов // Гены и клетки. 2023. Т. 18, № 4. С. 794–797. DOI: <https://doi.org/10.17816/gc623345>

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией).

Рукопись получена: 13.06.2023

Рукопись одобрена: 26.11.2023

Опубликована online: 20.01.2024

Источник финансирования. Работа выполнена при финансовой поддержке соглашения с Министерством науки и высшего образования № 075-15-2023-324.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

СПИСОК ЛИТЕРАТУРЫ

1. Strukov D., Snider G., Stewart D., Williams R. The missing memristor found // Nature. 2008. Vol. 453, N 7191. P. 80–83. doi: 10.1038/nature06932
2. Martyshov M.N., Emelyanov A.V., Demin V.A., et al. Multifilamentary character of anticorrelated capacitive and resistive switching in memristive structures based on (Co-Fe-B)x(LiNbO₃)100-x nanocomposite // Phys Rev Applied. 2020. Vol. 14. P. 034016.
3. Minnekhanov A.A., Emelyanov A.V., Lapkin D.A., et al. Parylene-based memristive devices with multilevel resistive switching for neuromorphic applications // Sci Rep. 2019. Vol. 9, N 1. P. 10800. doi: 10.1038/s41598-019-47263-9
4. Prezioso M., Merrikh-Bayat F., Hoskins B.D., et al. Training and operation of an integrated neuromorphic network based on metal-oxide memristors // Nature. 2015. Vol. 521, N 7550. P. 61–64. doi: 10.1038/nature14441
5. Emelyanov A.V., Lapkin D.A., Demin V.A., Erokhin V.V. First steps towards the realization of a double layer perceptron based on organic memristive devices // AIP Advances. 2016. Vol. 6, N 11. P. 111301. doi: 10.1063/1.4966257
6. Yao P., Wu H., Gao B., et al. Fully hardware-implemented memristor convolutional neural network // Nature. 2020. Vol. 577, N 7792. P. 641–646. doi: 10.1038/s41586-020-1942-4
7. Emelyanov A.V., Nikiruy K.E., Serenko A.V., et al. Self-adaptive STDP-based learning of a spiking neuron with nanocomposite memristive weights // Nanotechnology. 2020. Vol. 31, N 4. P. 045201. doi: 10.1088/1361-6528/ab4a6d
8. Wang W., Pedretti G., Milo V., et al. Learning of spatiotemporal patterns in a spiking neural network with resistive switching synapses // Sci Adv. 2018. Vol. 4, N 9. P. eaat4752. doi: 10.1126/sciadv.aat4752
9. Gerasimova S.A., Mikhaylov A.N., Belov A.I., et al. Design of memristive interface between electronic neurons // AIP Conf Proc. 2018. Vol. 1959, N 1. P. 090005. doi: 10.1063/1.5034744
10. Demin V.A., Nekhaev D.V., Surazhevsky I.A., et al. Necessary conditions for STDP-based pattern recognition learning in a memristive spiking neural network // Neural Netw. 2021. Vol. 134. P. 64–75. doi: 10.1016/j.neunet.2020.11.005
11. Surazhevsky I.A., Demin V.A., Ilyasov A.I., et al. Noise-assisted persistence and recovery of memory state in a memristive spiking neuromorphic network // Chaos, Solitons and Fractals. 2021. Vol. 146. P. 110890. doi: 10.1016/j.chaos.2021.110890
12. Nikiruy K.E., Emelyanov A.V., Demin V.A., et al. Dopamine-like STDP modulation in nanocomposite memristors // AIP Advances. 2019. Vol. 9, N 6. P. 065116. doi: 10.1063/1.5111083
13. Minnekhanov A.A., Shvetsov B.S., Emelyanov A.V. Parylene-based memristive synapses for hardware neural networks capable of dopamine-modulated STDP learning // J Phys D: Appl Phys. 2021. Vol. 54, N 48. P. 484002. doi: 10.1088/1361-6463/ac203c
14. Vlasov D., Rybka R., Sboev A. Reinforcement learning in a spiking neural network with memristive plasticity // Reinforcement learning in a spiking neural network with memristive plasticity. 6th Scientific School Dynamics of Complex Networks and their Applications (DCNA). 2022. Kaliningrad, Russian Federation. P. 300–302. doi: 10.1109/DCNA56428.2022.9923314
15. Mikhaylov A., Pimashkin A., Pigareva Y., et al. Neurohybrid memristive CMOS-integrated systems for biosensors and neuroprosthetics // Front Neurosci. 2020. Vol. 14. P. 358. doi: 10.3389/fnins.2020.00358
16. Masaev D.N., Suleimanova A.A., Prudnikov N.V., et al. Memristive circuit-based model of central pattern generator to reproduce spinal neuronal activity in walking pattern // Front Neurosci. 2023. Vol. 17. P. 1124950. doi: 10.3389/fnins.2023.1124950

КОНТАКТНАЯ ИНФОРМАЦИЯ

* В.А. Демин; адрес: Российская Федерация, 123182, Москва, пл. Академика Курчатова, д. 1; e-mail: demin.vyacheslav@mail.ru

DOI: <https://doi.org/10.17816/gc623345>

Principles of analog neuromorphic computing: from components to systems and algorithms

V.A. Demin^{1 *}, A.V. Emelyanov^{1, 2}, K.E. Nikiruy¹, I.A. Surazhevsky¹, A.V. Sitnikov^{1, 3}, V.V. Rylkov¹, P.K. Kashkarov^{1, 2}, M.V. Kovalchuk^{1, 2, 4}

¹ National Research Centre "Kurchatov Institute", Moscow, Russian Federation;

² The Moscow Institute of Physics and Technology, Moscow region, Dolgoprudny, Russian Federation;

³ Voronezh State Technical University, Voronezh, Russian Federation;

⁴ Lomonosov Moscow State University, Moscow, Russian Federation

ABSTRACT

This report outlines the current implementation status of hardware accelerators for artificial intelligence, focusing on successful neural network algorithms of the first and second generations that use formal artificial neural networks (ANNs). Identified shortcomings of current solutions are addressed, with proposed solutions using analog neuromorphic architectures.

The latter are designed based on the structural and functional principles of a living nervous system, using artificial neurons and models of synaptic connections, commonly referred to as memristors. These are electrically rewritable nanoscale components of non-volatile memory [1–3]. By using these components, it is feasible to significantly enhance the effectiveness and energy efficiency of algorithm accelerators which are based on ANNs [4–6]. Additionally, it enables the development of promising computing systems relying on biologically plausible third-generation neural network algorithms, namely Spiking Neural Networks (SNNs) [7–9].

The paper discusses the original approach to establishing optimal rules for tuning local SNNs with frequency encoding. It also explores the potential implementation of said rules using Spike-Timing-Dependent Plasticity (STDP) [10]. The study demonstrates the stability of SNN learning when subjected to analogue memristors' variance, and it highlights noise as an effective tool for fine-tuning and sustaining SNN memristive weights [7, 11].

Approaches to implementing local plasticity rules with dopamine-like modulation are discussed as a type of SNN reinforcement learning. This approach is necessary for forming imitative "needs" of an agent during autonomous functioning [12–14]. In addition, the first results of the creation of a prototype of a memristive implantable neuroprosthesis for motor activity are examined [15, 16].

Finally, potential hardware solutions for both neuronal components and synaptic connections using suitable memristive devices are demonstrated. The concept and initial findings of an analog neuromorphic computing system created with the aforementioned components are presented.

Thus, this paper aims to organize current and novel approaches for implementing energy-efficient and compact analog neuromorphic computing systems that can enable real-time processing and lifelong learning in artificial intelligence.

Keywords: neuromorphic computing; memristor; spiking neural networks; STDP; unsupervised learning; dopamine-like reinforcement learning; neurohybrid systems.

To cite this article:

Demin VA, Emelyanov AV, Nikiruy KE, Surazhevsky IA, Sitnikov AV, Rylkov VV, Kashkarov PK, Kovalchuk MV. Principles of analog neuromorphic computing: from components to systems and algorithms. *Genes & cells*. 2023;18(4):794–797. DOI: <https://doi.org/10.17816/gc623345>

ADDITIONAL INFORMATION

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work.

Funding sources. The work was carried out with the financial support of the Ministry of Science and Higher Education, agreement No. 075-15-2023-324.

Competing interests. The authors declare that they have no competing interests.

Received: 13.06.2023

Accepted: 26.11.2023

Published online: 20.01.2024

REFERENCES

1. Strukov D, Snider G, Stewart D, Williams R. The missing memristor found. *Nature*. 2008;453(7191):80–83. Corrected and republished from: *Nature*. 2009;459(7250):1154. doi: 10.1038/nature06932
2. Martyshov MN, Emelyanov AV, Demin VA, et al. Multifilamentary character of anticorrelated capacitive and resistive switching in memristive structures based on (Co-Fe-B)_x(LiNbO₃)_{100-x} nanocomposite. *Phys Rev Applied*. 2020;14:034016.
3. Minnekhanov AA, Emelyanov AV, Lapkin DA, et al. Parylene-based memristive devices with multilevel resistive switching for neuromorphic applications. *Sci Rep*. 2019;9(1):10800. doi: 10.1038/s41598-019-47263-9
4. Prezioso M, Merrikh-Bayat F, Hoskins BD, et al. Training and operation of an integrated neuromorphic network based on metal-oxide memristors. *Nature*. 2015;521(7550):61–64. doi: 10.1038/nature14441
5. Emelyanov AV, Lapkin DA, Demin VA, Erokhin VV. First steps towards the realization of a double layer perceptron based on organic memristive devices. *AIP Advances*. 2016;6(11):111301. doi: 10.1063/1.4966257
6. Yao P, Wu H, Gao B, et al. Fully hardware-implemented memristor convolutional neural network. *Nature*. 2020;577(7792):641–646. doi: 10.1038/s41586-020-1942-4
7. Emelyanov AV, Nikiruy KE, Serenko AV, et al. Self-adaptive STDP-based learning of a spiking neuron with nanocomposite memristive weights. *Nanotechnology*. 2020;31(4):045201. doi: 10.1088/1361-6528/ab4a6d
8. Wang W, Pedretti G, Milo V, et al. Learning of spatiotemporal patterns in a spiking neural network with resistive switching synapses. *Sci Adv*. 2018;4(9):eaat4752. doi: 10.1126/sciadv.aat4752
9. Gerasimova SA, Mikhaylov AN, Belov AI, et al. Design of memristive interface between electronic neurons. *AIP Conf Proc*. 2018;1959(1):090005. doi: 10.1063/1.5034744
10. Demin VA, Nekhaev DV, Surazhevsky IA, et al. Necessary conditions for STDP-based pattern recognition learning in a memristive spiking neural network. *Neural Netw*. 2021;134:64–75. doi: 10.1016/j.neunet.2020.11.005
11. Surazhevsky IA, Demin VA, Ilyasov AI, et al. Noise-assisted persistence and recovery of memory state in a memristive spiking neuromorphic network. *Chaos, Solitons and Fractals*. 2021;146:110890. doi: 10.1016/j.chaos.2021.110890
12. Nikiruy KE, Emelyanov AV, Demin VA, et al. Dopamine-like STDP modulation in nanocomposite memristor. *AIP Advances*. 2019;9(6):065116. doi: 10.1063/1.5111083
13. Minnekhanov AA, Shvetsov BS, Emelyanov AV. Parylene-based memristive synapses for hardware neural networks capable of dopamine-modulated STDP learning. *J Phys D: Appl Phys*. 2021;54(48):484002. doi: 10.1088/1361-6463/ac203c
14. Vlasov D, Rybka R, Sboev A. Reinforcement learning in a spiking neural network with memristive plasticity. In: *Reinforcement learning in a spiking neural network with memristive plasticity. 6th Scientific School Dynamics of Complex Networks and their Applications (DCNA)*; 2022; Kaliningrad, Russian Federation. P. 300–302. doi: 10.1109/DCNA56428.2022.9923314
15. Mikhaylov A, Pimashkin A, Pigareva Y, et al. Neurohybrid memristive CMOS-integrated systems for biosensors and neuroprosthetics. *Front Neurosci*. 2020;14:358. doi: 10.3389/fnins.2020.00358
16. Masaev DN, Suleimanova AA, Prudnikov NV, et al. Memristive circuit-based model of central pattern generator to reproduce spinal neuronal activity in walking pattern. *Front Neurosci*. 2023;17:1124950. doi: 10.3389/fnins.2023.1124950

AUTHORS' CONTACT INFO

* V.A. Demin; address: 1 Akademika Kurchatova square, 123182 Moscow, Russian Federation; e-mail: demin.vyacheslav@mail.ru