

DOI: <https://doi.org/10.17816/gc623425>

Разработка архитектуры импульсной нейронной сети с применением принципов дендритных вычислений

И.А. Маврин*, Е.А. Рындин, Н.В. Андреева, В.В. Лучинин

Санкт-Петербургский государственный электротехнический университет (ЛЭТИ) имени В.И. Ульянова (Ленина), Санкт-Петербург, Российская Федерация

АННОТАЦИЯ

В работе представлены результаты проектирования и разработки аппаратной архитектуры импульсной нейронной сети (ИНС) на основе дендритных вычислений. Основной целью интеграции активных свойств дендритов в структуру нейронов ИНС является необходимость минимизации количества функциональных блоков (синаптических связей и нейронов), обусловленная существующими ограничениями доступного объёма встроенной памяти при аппаратной реализации нейроморфных архитектур.

В качестве тестовой задачи для ИНС на основе дендритных вычислений была выбрана задача классификации изображений восьми символов (цифр от 1 до 8), представляемых как пиксельные однобитные изображения с разрешением 3×7 .

Учёт активных свойств дендритов осуществлялся дополнением модели импульсного нейрона сети механизмом настройки задержки поступления сигнала на отдельные входы, так называемым механизмом пластичности по задержке [1]. С этой целью была разработана модель ИНС с дополнительными к основным входам задержки (далее — ИНС с активными дендритами). Сигнал на основных входах ИНС дублировался через настраиваемый промежуток времени (время задержки) на входах задержки. Для простоты реализации время задержки устанавливалось одинаковым для всех дополнительных входов сети.

Входной сигнал подавался на входы ИНС построчно. Информация о трёх пикселях каждой строки (паттерн) поступала на шесть основных входов нейросети: три прямых и три инверсных, при этом «включённый» пиксель кодировался одним импульсом, поступающим на прямой вход, а «выключенный» пиксель — импульсом на соответствующий инверсный вход. Время сканирования строки составляло 10 мкс, длительность входных импульсов — 1 мкс, время задержки — 5 мкс.

Поиск оптимальных значений параметров нейронов ИНС осуществляли с помощью стохастического алгоритма, основанного на алгоритме имитации отжига. Для нейронов типа «интегратор с утечкой» оптимизировали значения постоянной времени утечки (22,8 мкс), порога срабатывания нейрона (1150 у.е.) и времени рефрактерности (1 мкс). Для обучения ИНС с активными дендритами использовали правило темпотрона [2]. В процессе обучения оптимизировались значения следующих параметров: максимальное значение изменения веса синаптической связи при обучении, различное для её укрепления и ослабления (0,7 и -3 у.е. соответственно), а также максимальный вес нейрона сети (195 у.е.).

Введение дополнительных входов задержки обеспечило возможность настройки восприимчивости нейронов ИНС к последовательности поступления входных паттернов в процессе обучения.

Представленную в работе архитектуру ИНС на основе дендритных вычислений сравнивали с разработанной нами ранее архитектурой двухслойной ИНС со скрытым перцептронным слоем и выходным слоем нейронов типа «интегратор с утечкой» [3].

Показано, что при одинаковой конструкции импульсных нейронов, методе кодирования входных изображений и способе организации импульсного слоя в обеих разработанных архитектурах двухслойная ИНС со скрытым перцептронным слоем и выходным слоем нейронов типа «интегратор с утечкой» выполняла классификацию изображений трёх символов (с разрешением 3×5), используя 10 нейронов и 63 синаптических веса, в то время как ИНС с активными дендритами осуществляла классификацию восьми символов (с разрешением 3×7) с использованием четырёх импульсных нейронов и 48 синаптических весов.

Таким образом, интеграция активных свойств дендритов в структуру ИНС для распознавания изображений позволила сократить количество функциональных блоков нейронов на 60%, синапсов — на 24%.

Ключевые слова: импульсная нейронная сеть; дендритные вычисления; пластичность по задержке; темпотрон.

Рукопись получена: 15.05.2023

Рукопись одобрена: 26.11.2023

Опубликована online: 20.01.2024

Как цитировать:

Маврин И.А., Рындин Е.А., Андреева Н.В., Лучинин В.В. Разработка архитектуры импульсной нейронной сети с применением принципов дендритных вычислений // Гены и клетки. 2023. Т. 18, № 4. С. 821–824. DOI: <https://doi.org/10.17816/gc623425>

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).

Источник финансирования. Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации (государственное задание в области научной деятельности FSEE-2020-0013).

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

СПИСОК ЛИТЕРАТУРЫ

1. Acharya J., Basu A., Legenstein R., et al. Dendritic computing: branching deeper into machine learning // *Neuroscience*. 2022. Vol. 489. P. 275–289. doi: 10.1016/j.neuroscience.2021.10.001
2. Güttig R., Sompolinsky H. The tempotron: a neuron that learns spike timing-based decisions // *Nat Neurosci*. 2006. Vol. 9, N 3. P. 420–428. doi: 10.1038/nn1643
3. Рындин Е.А., Маврин И.А., Андреева Н.В., Лучинин В.В. Нейроморфный электронный модуль, ориентированный на использование мемристорной ЭКБ, для распознавания изображений // *Нано- и микросистемная техника*. 2022. Т. 24, № 6. С. 293–303. doi: 10.17587/nmst.24.293-303

КОНТАКТНАЯ ИНФОРМАЦИЯ

* И.А. Маврин; адрес: Российская Федерация, 197022, Санкт-Петербург, ул. Профессора Попова, д. 5, литера Ф;
e-mail: iamavrin@etu.ru

DOI: <https://doi.org/10.17816/gc623425>

Design of spiking neural network architecture based on dendritic computation principles

I.A. Mavrin*, E.A. Ryndin, N.V. Andreeva, V.V. Luchinin

Saint Petersburg Electrotechnical University "LETI", Saint Petersburg, Russian Federation

ABSTRACT

The paper presents the hardware architecture design of a spiking neural network (SNN) based on dendritic computation principles. The integration of active dendritic properties into the neuronal structure of SNN aims to minimize the number of functional blocks required for hardware implementation, including synaptic connections and neurons. The available memory on the neuromorphic architecture imposes limitations on implementation, hence the need to reduce the number of functional blocks.

As a test task for the SNN based on dendritic computations, we selected the image classification of eight symbols, consisting of digits one through eight. These symbols are depicted as 3×7 pixel, 1-bit images.

Active dendritic properties were analyzed using the "delay plasticity" [1] principle, which introduces the mechanism of adjusting input signal delays in spiking neuron inputs. We designed an SNN model with complementary delay inputs, referred to as the active dendrite SNN, as a principle implementation. Input spikes arriving at the primary inputs are duplicated to the delay inputs after a modifiable time delay. For convenience, each delay input was set at a single value.

The input images were scanned sequentially. The neural network received three direct and three inverse inputs from the six main inputs that were coded with spikes corresponding to three pixels of a string. An "on" pixel was coded with a spike arriving at a direct input, while an "off" pixel was coded with a spike arriving at the corresponding inverse input. The line scanning time was 10 μs, input width was 1 μs, and delay time was 5 μs.

The optimization of spiking neuron parameters was performed through a stochastic search algorithm based on simulated annealing. The parameters optimized for the Leaky-Integrate-and-Fire (LIF) neurons included the leakage time constant (22.8 μs), firing threshold (1150 arbitrary units), and refractory period (1 μs).

The active dendrite SNN training employed the tempotron learning rule [2]. The training optimized the following parameters: the maximum change in synaptic weight on potentiation and depression (0.7 and −3 arbitrary units, respectively) and the synaptic weight's upper bound (195 arbitrary units).

Complementary delayed inputs facilitated the learning of the order in which input patterns arrived for SNN neurons during training.

The paper compares an SNN architecture based on dendritic computations to our previously designed two-layer SNN with a hidden perceptron layer and an output layer consisting of LIF neurons [3].

Using the same LIF neuron design, input image coding, and LIF neuron layer structure as in the proposed architecture, our two-layer SNN with a hidden perceptron layer and output layer of LIF neurons successfully recognized 3×5 images of three symbols with only 10 neurons and 63 synapses. Alternatively, the active dendrite SNN was able to recognize 3×7 images of eight symbols with four neurons and 48 synaptic weights.

In conclusion, incorporating active dendrite properties into the SNN architecture for image recognition resulted in optimized functional block usage, lowering the number of neurons and synapses used by 60 and 24%, respectively.

Keywords: SNN; dendritic computation; delay plasticity; tempotron.

To cite this article:

Mavrin IA, Ryndin EA, Andreeva NV, Luchinin VV. Design of spiking neural network architecture based on dendritic computation principles. *Genes & cells*. 2023;18(4):821–824. DOI: <https://doi.org/10.17816/gc623425>

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. This work was supported by the Ministry of Science and Higher Education of Russian Federation, grant No. FSEE-2020-0013.

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

Received: 15.05.2023

Accepted: 26.11.2023

Published online: 20.01.2024

REFERENCES

1. Acharya J, Basu A, Legenstein R, et al. Dendritic computing: branching deeper into machine learning. *Neuroscience*. 2022;489:275–289. doi: 10.1016/j.neuroscience.2021.10.001
2. Güttig R, Sompolinsky H. The tempotron: a neuron that learns spike timing–based decisions. *Nat Neurosci*. 2006;9(3):420–428. doi: 10.1038/nn1643
3. Ryndin EA, Mavrin IA, Andreeva NV, Luchinin VV. Neuromorphic electronic module, focused on the use of memristor ecb, for image recognition. *Nano- and microsystems technology*. 2022;24(6):293–303. doi: 10.17587/nmst.24.293-303

AUTHORS' CONTACT INFO

* I.A. Mavrin; address: 5F Professora Popova street, 197022 Saint Petersburg, Russian Federation; e-mail: iamavrin@etu.ru