

doi: 10.17586/2226-1494-2026-26-2-428-435

УДК 004.032.26

Реализация и исследование резервуарного вычислителя на основе аппаратной модели трехэлементного импульсного нейрона

Владислав Сергеевич Холкин¹, Василий Андреевич Пчёлко²,
Владислав Леонидович Кленин³, Тимур Искадарович Каримов⁴✉,
Екатерина Евгеньевна Копец⁵

^{1,2,3,4,5} Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина); Санкт-Петербург, 197022, Российская Федерация

³ АО «НПЦ «Акварин», Санкт-Петербург, 195196, Российская Федерация

¹ super.holkin@mail.ru, <https://orcid.org/0000-0002-5010-1841>

² vapchelko@stud.etu.ru, <https://orcid.org/0009-0002-2584-1474>

³ vklenin@akvamarin-npc.ru, <https://orcid.org/0009-0009-3966-9880>

⁴ tikarimov@etu.ru✉, <https://orcid.org/0000-0002-9860-8211>

⁵ eekopets@etu.ru, <https://orcid.org/0000-0002-5953-255X>

Аннотация

Введение. Исследованы варианты поиска новых компьютерных архитектур для аппаратной реализации динамических (импульсных) нейросетей, способных заменить современные сети, построенные на нейронах со статической функцией активации. **Метод.** Впервые предложено использование разработанной компактной аналоговой модели импульсного нейрона, состоящей из трех элементов (волатильного мемристора, туннельного диода и конденсатора), в качестве базового элемента резервуарного вычислителя типа жидкостный конечный автомат (Liquid State Machine). Предложена компьютерная модель резервуара, включающая 7480 импульсных нейронов и около 254 тыс. связей, с топологией, сформированной по биологически мотивированному алгоритму. **Основные результаты.** Результаты предложенного решения продемонстрированы на задаче распознавания рукописных цифр из набора данных Modified National Institute of Standards and Technology. Достигнута точность классификации 93 %, что сопоставимо с известными реализациями жидкостных конечных автоматов. Оценки быстродействия предлагаемого резервуара при будущей аппаратной реализации превосходят показатели существующих аналогов на порядок, а по энергоэффективности — на 3–4 порядка. **Обсуждение.** Впервые показана практическая применимость трехэлементной нейронной модели для задач машинного обучения и доказана ее перспективность как базового элемента для построения масштабируемых и энергоэффективных нейроморфных вычислительных систем.

Ключевые слова

резервуарный вычислитель, импульсный нейрон, жидкостный конечный автомат, нейроморфные вычисления, классификация MNIST, классы возбудимости, аналоговая модель нейрона

Благодарности

Работа поддержана Российским научным фондом, проект № 25-71-10049 «Исследовательское проектирование перспективных нейроморфных вычислителей».

Ссылка для цитирования: Холкин В.С., Пчёлко В.А., Кленин В.Л., Каримов Т.И., Копец Е.Е. Реализация и исследование резервуарного вычислителя на основе аппаратной модели трехэлементного импульсного нейрона // Научно-технический вестник информационных технологий, механики и оптики. 2026. Т. 26, № 2. С. 428–435. doi: 10.17586/2226-1494-2026-26-2-428-435

Implementation and investigation of a reservoir computer based on a hardware model of three-element spiking neuron

Vladislav S. Kholkin¹, Vasiliy A. Pchelko², Vladislav L. Klenin³, Timur I. Karimov⁴✉, Ekaterina E. Kopets⁵

^{1,2,3,4,5} Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197022, Russian Federation

³ AO NPTS “AKVAMARIN”, Saint Petersburg, 195196, Russian Federation

¹ super.holkin@mail.ru, <https://orcid.org/0000-0002-5010-1841>

² vapchelko@stud.etu.ru, <https://orcid.org/0009-0002-2584-1474>

³ vklenin@akvamarin-npc.ru, <https://orcid.org/0009-0009-3966-9880>

⁴ tikarimov@etu.ru✉, <https://orcid.org/0000-0002-9860-8211>

⁵ eekopets@etu.ru, <https://orcid.org/0000-0002-5953-255X>

Abstract

This paper investigates new computer architectures for the hardware implementation of dynamic (spiking) neural networks capable to replace up-to-date networks built on neurons with a static activation function. We propose for the first time the use of a recently developed compact analog model of a spiking neuron, consisting of only three elements (a volatile memristor, a tunnel diode, and a capacitor), as the basic element of a reservoir computer of Liquid State Machine (LSM) type. A computer model of the reservoir is proposed, including 7,480 neurons and approximately 254,000 connections, with a topology formed using the biologically motivated LSM stochastic synapse distribution algorithm. The results of the proposed solution are demonstrated on the task of recognizing handwritten digits from the MNIST dataset. A classification accuracy of 93 % is achieved, which is comparable to known LSM implementations. Estimates for the proposed reservoir performance of the future hardware implementation exceed those of existing analogs by an order, and in terms of energy efficiency by 3-4 orders. Thus, the proposed study demonstrates for the first time the practical applicability of the three-element neuron model for machine learning tasks and confirms its potential as a basic element for constructing scalable and energy-efficient neuromorphic computing systems.

Keywords

reservoir computer, spiking neuron, liquid state machine (LSM), neuromorphic computing, MNIST classification, excitability classes, analog neuron model

Acknowledgements

The research was supported by the Russian Science Foundation, project No. 25-71-10049 “Research design of promising neuromorphic computers”.

For citation: Kholkin V.S., Pchelko V.A., Klenin V.L., Karimov T.I., Kopets E.E. Implementation and investigation of a reservoir computer based on a hardware model of three-element spiking neuron. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2026, vol. 26, no. 2, pp. 428–435 (in Russian). doi: 10.17586/2226-1494-2026-26-2-428-435

Введение

Искусственные нейронные сети сегодня применяются для решения широкого спектра задач, среди которых можно выделить классификацию, распознавание образов, генерацию данных и другие [1]. Вместе с тем для стабильного применения нейронных сетей существует ряд препятствий, к которым можно отнести сложности процесса обучения (например, затухание и взрыв градиентов) [2], катастрофическое забывание сетью старых данных при попытке дообучения [3], постоянно увеличивающиеся затраты энергии и требования к вычислительным ресурсам [4, 5], а также невозможность динамически адаптировать сеть под обновляющиеся данные без полного переобучения [6]. Указанные проблемы парадигмы глубокого обучения обуславливают актуальность разработки нейроморфных систем нового типа.

Одной из парадигм, альтернативных глубокому обучению, является резервуарный компьютеринг, под которым понимаются такие нейронные сети с рекуррентными связями [7], где обучению подвергается только выходной слой. В последние годы была показана результативность резервуаров при решении многих практических задач [8–10]. Чаще всего в резервуарах применяются динамические импульсные модели

нейронов. При этом, несмотря на большой потенциал, импульсные нейросети невозможно эффективно выполнять на стандартной аппаратуре (графическом (Graphics Processing Unit, GPU), тензорном или нейронном процессорах) из-за фундаментальных ограничений фон-неймановской архитектуры. Для спайковых сетей перспективны нейроморфные чипы (Intel Loihi, IBM TrueNorth) или аналоговые спайковые нейросети [11], еще более многообещающие по плотности размещения элементов и энергоэффективности. При этом существующие как цифровые, так и аналоговые реализации спайковых резервуаров часто основаны на упрощенных моделях нейронов, таких как модель integrate-and-fire, что снижает эффективность резервуара.

Для увеличения эффективности резервуарных вычислителей в последние годы был представлен ряд компактных моделей биологически более достоверных аналоговых нейронов: на основе тиристора [11], однопереходного транзистора [12], а также мемристоров [13, 14]. В частности, в работе [15] предложена модель нейрона на трех элементах: волатильном мемристоре (пороговом селекторе), туннельном диоде и конденсаторе. Эта модель привлекательна своей простотой и богатством динамики, охватывающей три класса возбудимости по Ходжкину [16] и хаотические режимы, в отличие от простых интеграторов (класс I по Ходжкину).

Несмотря на то, что в [15] была предложена модель с широким спектром динамических режимов, вопросы построения на ее основе вычислительных архитектур и оценки их применимости к задачам машинного обучения не рассматривались.

В настоящей работе впервые изучена применимость трехэлементной аппаратной модели импульсного нейрона в составе масштабного резервуарного вычислителя типа жидкостный конечный автомат (Liquid State Machine, LSM), используя биологически мотивированную топологию LSM со стохастическим распределением связей [17], и продемонстрирована ее работоспособность на задаче классификации Modified National Institute of Standards and Technology (MNIST), количественно оценена ее точность, быстродействие и энергоэффективность.

Цель работы — первое использование трехэлементной модели нейрона в полноценной нейросети с практической оценкой эффективности.

Трехэлементный нейрон как базовый компонент резервуара

Электрическая схема нейрона [15] концептуально основана на использовании трех элементов: конденсатора (C), элемента с S-образной вольт-амперной характеристикой (BAX) и элемента с N-образной BAX. Данную рассматриваемую модель назовем SNC-нейроном. Элементы модели используются для воссоз-

дания ряда свойств, характерных для биологических нейронов: конденсатор отражает мембранный потенциал нейрона, который позволяет накапливать заряд для генерации импульса; элемент с S-BAX (в SNC-нейроне применяется пороговый селектор на основе высокоорганизованных наноточек серебра (AND-TS) [18]) осуществляет генерацию импульсов, поочередно открываясь и закрываясь, давая конденсатору заряжаться; элемент с N-BAX (в SNC-нейроне применяется германиевый туннельный диод ГИ403 [19]) модулирует активность S-элемента, позволяя нейрону проявлять свойства резонатора. Все элементы соединены в цепи параллельно, как показано на рис. 1, а. Детальная математическая модель SNC-нейрона, а также описание динамики потенциала и прочих поведенческих особенностей представлены в работе [15].

Связи между нейронами осуществляются через синапсы возбуждающего и тормозного типов (рис. 1, b, c). Наличие связи между нейронами в матрице весов соответствует наличию проводной связи между выходным нейроном, синапсом и входным нейроном, а вес этой связи пропорционален проводимости выходного резистора.

Архитектура резервуарного вычислителя

Применим метод построения LSM по алгоритму пространственно-зависимой случайной топологии (Stochastic Organized Mapping, SOM) [17]. Алгоритм

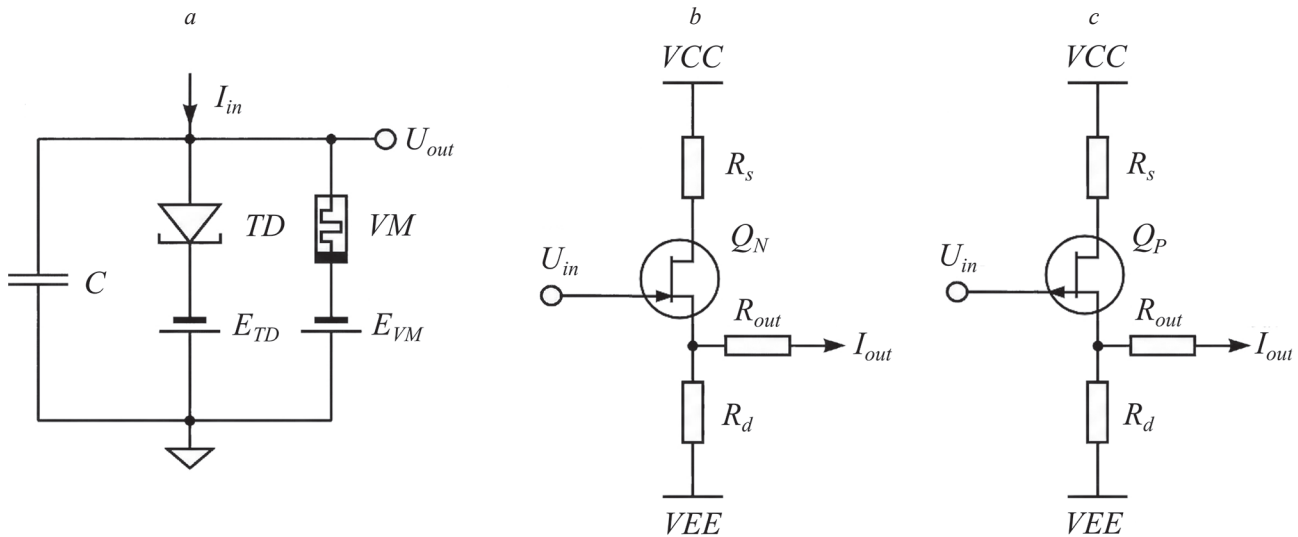


Рис. 1. Базовые компоненты резервуарного вычислителя: трехэлементный нейрон (a); возбуждающий (b) и тормозной (c) синапсы.

I_{in} — входной ток нейрона; U_{out} — входное напряжение нейрона; C — конденсатор, имитирующий емкость мембраны; TD — туннельный диод; VM — волатильный мемристор; E_{TD} — напряжение модуляции туннельного диода; E_{VM} — напряжение модуляции волатильного мемристора; U_{in} — входное напряжение синапса; VCC — положительное напряжение питания; VEE — отрицательное напряжение питания; R_s — резистор в стоке полевого транзистора; R_d — резистор в истоке полевого транзистора; Q_N — полевой транзистор n -типа; Q_P — полевой транзистор p -типа; R_{out} — выходной резистор синапса и I_{out} — выходной ток синапса

Fig. 1. Basic components of a reservoir computer: three-element neuron (a); excitatory synapse (b); inhibitory synapse (c).

Here: I_{in} is the input current of the neuron, U_{out} is the input voltage of the neuron, TD is the tunnel diode, E_{TD} is the modulation voltage of the tunnel diode, VM is the volatile memristor, E_{VM} is the modulation voltage of the volatile memristor, U_{in} is the input voltage of the synapse, VCC is the positive supply voltage, VEE is the negative supply voltage, R_s is the resistor in the drain of the field-effect transistor, R_d is the resistor in the source of the field-effect transistor, Q_N is the n -type field-effect transistor, Q_P is the p -type field-effect transistor, R_{out} is the output resistor of the synapse, and I_{out} is the output current of the synapse

работает следующим образом. Для назначения связей между нейронами весов используется трехмерное пространство размерности $k \times l \times m$ (рис. 2). Каждому нейрону присваиваются координаты $R_i = (x_i, y_i, z_i)$. Часть нейронов случайным образом обозначаются как возбуждающие (E), а оставшиеся — как тормозные (I), обычно в пропорции 80 % к 20 % (доля тормозных нейронов $f_{inh} = 0,2$). Связи между нейронами формируются по экспоненциальному закону распределения, зависящему от расстояния. Таким образом, ближние нейроны имеют больше шансов образовать связь, что отражает локальную организацию нейронных ансамблей, характерную для коры головного мозга человека.

После формирования топологии каждой связи назначается фиксированный вес в зависимости от типа взаимодействующих нейронов, возбуждающих или тормозных. Весовая матрица может быть построена как разреженная, что значительно уменьшает вычислительные затраты. Сформированная сеть представляет собой трехмерный нелинейный динамический контур, состоящий из возбуждающих и тормозных нейронов.

Пространственная структура исследованного в настоящей работе резервуара представляет собой трехмерную решетку из нейронов размером $[14 \times 16 \times 35]$ (всего 7840 нейронов), что включает 6281 возбуждающий нейрон, 1559 тормозных нейронов, а также 254 097 синаптических связей. Коэффициент передачи между нейронами был выбран равным $8 \cdot 10^{-4}$, что соответствует масштабным соотношениям, предложенным в работе [20].

Синаптические связи и их веса формировались в соответствии с вероятностным алгоритмом, описанным в [17], при следующих параметрах, согласованных с [20]:

$$w = \begin{bmatrix} 0,8 & -0,6 \\ -0,5 & 0,4 \end{bmatrix}; \quad r_0 = 3,5;$$

$$k_0 = \begin{bmatrix} 0,2 & 0,2 \\ 0,25 & 0,0 \end{bmatrix}; \quad f_{inh} = 0,2,$$




Рис. 2. Визуализация пространственного резервуара.

Возбуждающие нейроны (синие узлы); тормозные нейроны (красные узлы); нейроны входного слоя (зеленые узлы); нейроны выходного слоя могут быть заменены произвольным классификатором (фиолетовые узлы).

На вход резервуара подается рукописная цифра, на выходе выдается соответствующий индекс класса

Fig. 2. Visualization of a spatial reservoir.

Excitatory neurons (blue nodes); inhibitory neurons (red nodes); input layer neurons (green nodes); output layer neurons which can be replaced by an arbitrary classifier (purple nodes).

A handwritten digit is fed to the reservoir input, and the corresponding class index is output

где w — матрица весов направленных связей между нейронами различных типов (индекс 1 матрицы отвечает за возбуждающие нейроны, индекс 2 за тормозные); r_0 — параметр формы гамма-распределения вероятности образования связи; k_0 — матрица множителей при функции плотности вероятности появления веса между нейронами соответствующих типов.

Весовые коэффициенты нормировались по количеству входящих связей каждого нейрона, что предотвращало переизбыток возбуждения и обеспечивало стабильное функционирование сети.

Связи между входным слоем и резервуаром задаются случайным образом: каждый входной нейрон проецируется на уникальный возбуждающий нейрон в LSM, сохраняя соответствие между пикселем и возбуждаемой областью сети. Классификатор имеет доступ к выходным сигналам каждого нейрона и может как детально анализировать его спайковую активность, так и использовать обобщающую метрику. В последнем случае на вход классификатора подается 7840-мерный вектор, представляющий собой высокоразмерное отображение входных данных, сформированное динамикой резервуара.

В качестве задачи для исследования предложенной модели SNC-LSM был использован бенчмарк, популярный для первичной оценки качества работы классификаторов на основе машинного обучения — набор данных MNIST. Это набор нормализованных и центрированных написанных от руки арабских цифр от нуля до 9, который содержит 70 000 монохромных изображений. Каждое изображение имеет размер 28×28 пикселей, а градации цвета кодируются целым числом от 0 до 255. В качестве входного воздействия для подачи на входной слой резервуара используется меандр с параметрами:

$$A = 660 \cdot 10^{-7}, \quad f = \frac{I_{pixel}}{2550}, \quad I_{pixel} \in [0, 255],$$

где A — амплитуда входного тока, А; f — частота входного тока, Гц; I_{pixel} — значение яркости кодируемого пикселя.

Таким образом, чем ярче пиксель, тем выше частота возбуждающего тока, что реализует аналог частотного кодирования интенсивности входного сигнала.

Каждый нейрон резервуара был настроен на класс I возбудимости с помощью параметров: $E_{TD} = -0,1$ В; $E_{VM} = 17 \cdot 10^{-3}$ В; $C = 13 \cdot 10^{-3}$ мкФ. Данные значения соответствуют физиологически правдоподобному режиму работы модели SNC-нейрона. Моделирование резервуара проводилось с использованием схемы интегрирования Рунге–Кутты 4-го порядка при шаге интегрирования $\Delta t = 10^{-7}$ с в течение 15 000 шагов для каждого изображения. Такая длительность позволила сети достичь стационарной активности и сформировать устойчивое распределение спайков.

Результаты

Вычислительный эксперимент был поставлен на персональном компьютере со следующими характеристиками: CPU: Intel® Core™ i7-8750H @ 2,2 ГГц,

GPU: NVIDIA® RTX 2060 (6 ГБ VRAM), RAM: 16 ГБ DDR4 @ 2667 МГц. Использовались программные среды: MATLAB R2024a, C++ (MSVC 19.29.30156), CUDA 12.2 (NVCC 12.2.91). Вычисления на GPU производились в одинарной точности (float, 32 бита; 23 бита мантиссы, 7 бит экспоненты), на CPU — в двойной точности.

Для ограничения времени вычислительного эксперимента резервуару было предъявлено по 300 изображений каждого класса, всего 10 классов. В качестве обобщающей метрики активности нейрона использовалось количество спайков, произведенных за время предъявления стимула. После моделирования к матрице признаков был применен χ^2 -критерий [21] для отбора наиболее значимых нейронов по их вкладу в различение классов изображений. Полученный вектор значимостей был отранжирован по убыванию и использовался для формирования массива входных данных для следующих классификаторов: метод опорных векторов (Support Vector Machine, SVM) с квадратичным ядром; линейный SVM; метод k ближайших соседей; многослойный перцептрон с тремя слоями; многослойный

перцептрон с пятью слоями и регуляризацией методом исключения. Классификаторы SVM использовали код с коррекцией ошибок для разделения на несколько классов. Для всех классификаторов выполнено разбиение выборки на 90 % обучающих данных и 10 % тестовых.

На рис. 3 представлены графики точности классификации резервуарного вычислителя в зависимости от числа использованных нейронов. Наилучшая точность составила 91,6 % для SVM poly. $d = 2$ на данных 100 нейронов, и 92,7 % для 5-layer MLP w. dropout на данных 200 нейронов; для последнего получена матрица несоответствия (рис. 4). Разработанный резервуар был сравнен с похожими моделями, реализующими жидкостные конечные автоматы, по ключевым метрикам; результат показан в таблице.

В результате анализа таблицы видно, что резервуар на SNC-нейронах превосходит модель LSM-SOM $N(0,1)$ [17], которая была взята за основу. Резервуары 1024-1024-60 LSM [10] и 784-135-26 LSM [22] были реализованы в аппаратуре на программируемой логической интегральной схеме (ПЛИС), поэтому для них были рассчитаны дополнительно такие метрики, как

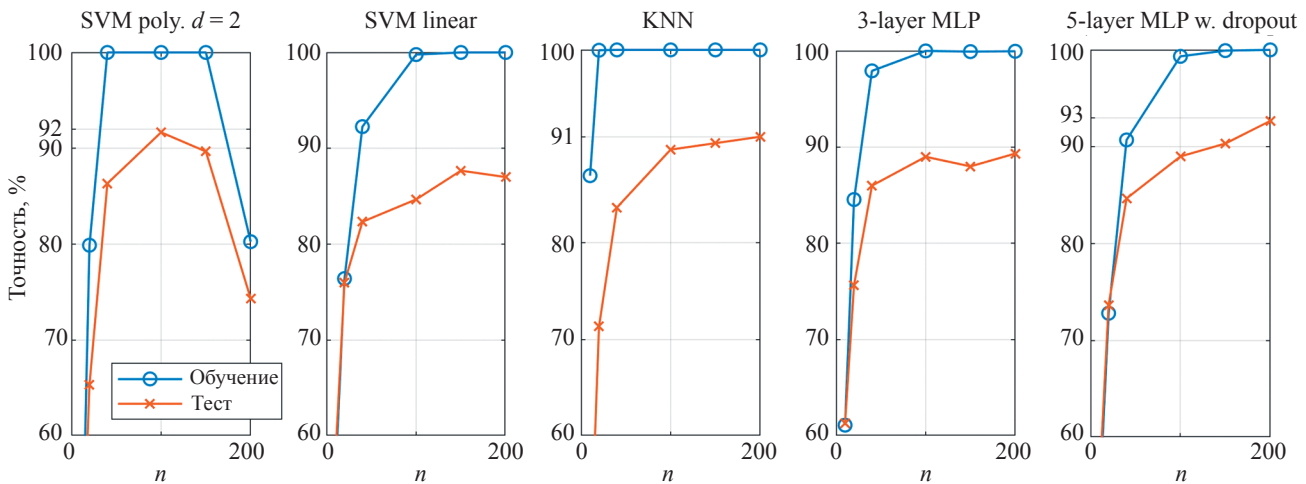


Рис. 3. Сравнение точности классификации разных моделей на различном числе нейронов, отранжированных по критерию значимости χ^2 .

SVM poly. $d = 2$ — метод Support Vector Machine (SVM) с квадратичным ядром; SVM linear — линейный SVM; KNN — метод k ближайших соседей (K -Nearest Neighbors); 3-layer MLP — Multilayer Perceptron (MLP) с тремя слоями; 5-layer MLP w. dropout — MLP с пятью слоями и регуляризацией методом исключения

Fig. 3. Comparison of classification accuracy on different numbers of neurons, sorted according to χ^2 importance criterion.

Here: SVM poly. $d = 2$ is the Support Vector Machine (SVM) method with a quadratic kernel; SVM linear is a linear SVM; KNN is the K -Nearest Neighbors method; 3-layer MLP is a Multilayer Perceptron (MLP) with three layers; 5-layer MLP w. dropout is an MLP with five layers and dropout regularization

Таблица. Сравнение точностей спайковых классификаторов

Table. Comparison of the accuracy of spike classifiers

Нейронный классификатор	Точность на наборе данных MNIST, %	Энергоэффективность вывода, Дж/кадр	Скорость вывода, кадр/с
1024-1024-60 LSM [10]	94,9	$1,25 \times 10^{-3}$	89
784-135-26 LSM [22]	96,6	$1,30 \times 10^{-1}$	12
LSM-SOM $N(0,1)$ [17]	90,0	нет данных	нет данных
Two-Level Inhibition SNN [23]	94,1	нет данных	нет данных
SNC-LSM (предложенная модель)	92,7	$8,44 \times 10^{-7}$	667




Рис. 4. Матрица несоответствия резервуара на тестовой выборке для классификатора

5-layer MLP. Вертикальный столбец справа показывает долю правильных и ошибочных предсказаний для каждого истинного класса. Горизонтальная строка снизу показывает точность предсказания для каждого предсказанного класса.

Fig. 4. Confusion matrix by the reservoir on test sample set for 5-layer MLP.

The vertical column on the right shows the proportion of correct and incorrect predictions for each true class. The horizontal row below shows the prediction accuracy for each predicted class

энергоэффективность вывода и скорость вывода. Для резервуара SNC-LSM эти метрики были рассчитаны на основе информации о длительности предъявляемого изображения, среднем числе спайков на изображение и оценке энергии на спайк, представленной в работе [15].

Заключение

В работе предложено и исследовано применение новой компактной аппаратной модели импульсного нейрона, состоящей из трех элементов: волатильного мемристора, туннельного диода и конденсатора, для создания функциональной нейросети. Отметим, что ранее предложенная модель нейрона в настоящей работе впервые интегрирована в масштабную рекуррентную сеть (7480 нейронов, 254 тыс. связей) с архитектурой типа жидкостный конечный автомат, которая была успешно использована для решения задачи класси-

фикации набора данных Modified National Institute of Standards and Technology. Достигнутая точность (около 93 %) сопоставима с результатами современных аналогов, однако оценки характеристик аппаратной реализации, а именно, скорости обработки изображений и энергоэффективности значительно превосходят известные решения — на 1–2 и 3–4 порядка, соответственно. Это подтверждает применимость трехэлементного нейрона для построения высокопроизводительных и энергоэффективных импульсных нейросетей.

В дальнейшем планируется изучение более сложных признаков, учитывающих временные корреляции и паттерны спайков, и влияния гиперпараметров резервуарного вычислителя на точность классификации. На основе полученных данных будут разработаны компоненты автоматизации проектирования оптимальных резервуарных вычислителей на нейроморфных чипах для задач машинного обучения.

Литература

1. Tavanaei A., Ghodrati M., Kheradpisheh S.R., Masquelier T., Maida A. Deep learning in spiking neural networks // *Neural Networks*. 2019. V. 111. P. 47–63. <https://doi.org/10.1016/j.neunet.2018.12.002>
2. Philipp G., Song D., Carbonell J.G. The exploding gradient problem demystified — definition, prevalence, impact, origin, tradeoffs, and solutions // *arXiv*. 2017. arXiv:1712.05577. <https://doi.org/10.48550/arXiv.1712.05577>

References

1. Tavanaei A., Ghodrati M., Kheradpisheh S.R., Masquelier T., Maida A. Deep learning in spiking neural networks. *Neural Networks*, 2019, vol. 111, pp. 47–63. <https://doi.org/10.1016/j.neunet.2018.12.002>
2. Philipp G., Song D., Carbonell J.G. The exploding gradient problem demystified — definition, prevalence, impact, origin, tradeoffs, and solutions. *arXiv*, 2017. arXiv:1712.05577. <https://doi.org/10.48550/arXiv.1712.05577>

3. Kirkpatrick J., Pascanu R., Rabinowitz N., Veness J., Desjardins G., Rusu A.A., et al. Overcoming catastrophic forgetting in neural networks // *Proc. of the National Academy of Sciences of the United States of America*. 2017. V. 114. N 13. P. 3521–3526. <https://doi.org/10.1073/pnas.1611835114>
4. Davidson S., Furber S.B. Comparison of artificial and spiking neural networks on digital hardware // *Frontiers in Neuroscience*. 2021. V. 15. P. 651141. <https://doi.org/10.3389/fnins.2021.651141>
5. Przyczyna D., Pecqueur S., Vuillaume D., Szaciłowski K. Reservoir computing for sensing: an experimental approach // *arXiv*. 2020. arXiv:2001.04342. <https://doi.org/10.48550/arXiv.2001.04342>
6. Jiang H., Anumasa S., De Masi G., Xiong H., Gu B. A unified optimization framework of ANN-SNN conversion: towards optimal mapping from activation values to firing rates // *Proc. of the 40th International Conference on Machine Learning*. 2023. P. 14945–14974.
7. Lukoševičius M., Jaeger H. Reservoir computing approaches to recurrent neural network training // *Computer Science Review*. 2009. V. 3. N 3. P. 127–149. <https://doi.org/10.1016/j.cosrev.2009.03.005>
8. Morando S., Pera M.C., Yousfi Steiner N., Jemei S., Hissel D., Larger L. Reservoir Computing optimisation for PEM fuel cell fault diagnostic // *Proc. of the IEEE Vehicle Power and Propulsion Conference (VPPC)*. 2017. P. 1–7. <https://doi.org/10.1109/vppc.2017.8330981>
9. Zhang S., Duan X., Li C., Liang M. Pre-classified reservoir computing for the fault diagnosis of 3D printers // *Mechanical Systems and Signal Processing*. 2021. V. 146. P. 106961. <https://doi.org/10.1016/j.ymsp.2020.106961>
10. Shi C., Fu X., Wang H., Lin Y., Jiang Y., Liu L., et al. Ghost reservoir: a memory-efficient low-power and real-time neuromorphic processor of liquid state machine with on-chip learning // *IEEE Transactions on Circuits and Systems II: Express Briefs*. 2024. V. 71. N 10. P. 4526–4530. <https://doi.org/10.1109/TCSII.2024.3395415>
11. Stoliar P., Schneegans O., Rozenberg M.J. Biologically relevant dynamical behaviors realized in an ultra-compact neuron model // *Frontiers in Neuroscience*. 2020. V. 14. P. 421. <https://doi.org/10.3389/fnins.2020.00421>
12. Isik I., Tagluk M.E. Analysis of the electronic integrate and fire neuron model // *Neurocomputing*. 2022. V. 488. P. 261–270. <https://doi.org/10.1016/j.neucom.2022.02.064>
13. Pickett M.D., Medeiros-Ribeiro G., Williams R.S. A scalable neuristor built with Mott memristors // *Nature Materials*. 2013. V. 12. N 2. P. 114–117. <https://doi.org/10.1038/nmat3510>
14. Li Y., Tang J., Gao B., Li X., Xi Y., Zhang W., et al. Oscillation neuron based on a low-variability threshold switching device for high-performance neuromorphic computing // *Journal of Semiconductors*. 2021. V. 42. N 6. P. 064101. <https://doi.org/10.1088/1674-4926/42/6/064101>
15. Ostrovskii V., Karimov T., Rybin V., Bobrova Y., Arlyapov V., Butusov D. Bio-inspired neuron based on threshold selector and tunnel diode capable of excitability modulation // *Neurocomputing*. 2025. V. 624. P. 129454. <https://doi.org/10.1016/j.neucom.2025.129454>
16. Hodgkin A.L. The local electric changes associated with repetitive action in a non-medullated axon // *The Journal of Physiology*. 1948. V. 107. N 2. P. 165–181. <https://doi.org/10.1113/jphysiol.1948.sp004260>
17. Zhang Y., Mo L., He X., Meng X. Unsupervised spiking neural network based on liquid state machine and self-organizing map // *Neurocomputing*. 2025. V. 620. P. 129120. <https://doi.org/10.1016/j.neucom.2024.129120>
18. Hua Q., Wu H., Gao B., Zhao M., Li Y., Li X., et al. A threshold switching selector based on highly ordered Ag nanodots for X-point memory applications // *Advanced Science*. 2019. V. 6. N 10. P. 1900024. <https://doi.org/10.1002/advs.201900024>
19. Баюков А.В., Гитцевич А.Б., Зайцев А.А., Мокряков В.В., Петухов В.М., Хрулев А.К. Полупроводниковые приборы: диоды, тиристоры, оптоэлектронные приборы. Справочник. М.: Энергоатомиздат, 1983. 744 с.
20. Wijesinghe P., Srinivasan G., Panda P., Roy K. Analysis of liquid ensembles for enhancing the performance and accuracy of liquid state machines // *Frontiers in Neuroscience*. 2019. V. 13. P. 504. <https://doi.org/10.3389/fnins.2019.00504>
21. McHugh M.L. The chi-square test of independence // *Biochimica Medica*. 2013. V. 23. N 2. P. 143–149. <https://doi.org/10.11613/bm.2013.018>
3. Kirkpatrick J., Pascanu R., Rabinowitz N., Veness J., Desjardins G., Rusu A.A., et al. Overcoming catastrophic forgetting in neural networks. *Proc. of the National Academy of Sciences of the United States of America*, 2017, vol. 114, no. 13, pp. 3521–3526. <https://doi.org/10.1073/pnas.1611835114>
4. Davidson S., Furber S.B. Comparison of artificial and spiking neural networks on digital hardware. *Frontiers in Neuroscience*, 2021, vol. 15, pp. 651141. <https://doi.org/10.3389/fnins.2021.651141>
5. Przyczyna D., Pecqueur S., Vuillaume D., Szaciłowski K. Reservoir computing for sensing: an experimental approach. *arXiv*, 2020. arXiv:2001.04342. <https://doi.org/10.48550/arXiv.2001.04342>
6. Jiang H., Anumasa S., De Masi G., Xiong H., Gu B. A unified optimization framework of ANN-SNN conversion: towards optimal mapping from activation values to firing rates. *Proc. of the 40th International Conference on Machine Learning*, 2023, pp. 14945–14974.
7. Lukoševičius M., Jaeger H. Reservoir computing approaches to recurrent neural network training. *Computer Science Review*, 2009, vol. 3, no. 3, pp. 127–149. <https://doi.org/10.1016/j.cosrev.2009.03.005>
8. Morando S., Pera M.C., Yousfi Steiner N., Jemei S., Hissel D., Larger L. Reservoir Computing optimisation for PEM fuel cell fault diagnostic. *Proc. of the IEEE Vehicle Power and Propulsion Conference (VPPC)*, 2017, pp. 1–7. <https://doi.org/10.1109/vppc.2017.8330981>
9. Zhang S., Duan X., Li C., Liang M. Pre-classified reservoir computing for the fault diagnosis of 3D printers. *Mechanical Systems and Signal Processing*, 2021, vol. 146, pp. 106961. <https://doi.org/10.1016/j.ymsp.2020.106961>
10. Shi C., Fu X., Wang H., Lin Y., Jiang Y., Liu L., et al. Ghost reservoir: a memory-efficient low-power and real-time neuromorphic processor of liquid state machine with on-chip learning. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2024, vol. 71, no. 10, pp. 4526–4530. <https://doi.org/10.1109/TCSII.2024.3395415>
11. Stoliar P., Schneegans O., Rozenberg M.J. Biologically relevant dynamical behaviors realized in an ultra-compact neuron model. *Frontiers in Neuroscience*, 2020, vol. 14, pp. 421. <https://doi.org/10.3389/fnins.2020.00421>
12. Isik I., Tagluk M.E. Analysis of the electronic integrate and fire neuron model. *Neurocomputing*, 2022, vol. 488, pp. 261–270. <https://doi.org/10.1016/j.neucom.2022.02.064>
13. Pickett M.D., Medeiros-Ribeiro G., Williams R.S. A scalable neuristor built with Mott memristors. *Nature Materials*, 2013, vol. 12, no. 2, pp. 114–117. <https://doi.org/10.1038/nmat3510>
14. Li Y., Tang J., Gao B., Li X., Xi Y., Zhang W., et al. Oscillation neuron based on a low-variability threshold switching device for high-performance neuromorphic computing. *Journal of Semiconductors*, 2021, vol. 42, no. 6, pp. 064101. <https://doi.org/10.1088/1674-4926/42/6/064101>
15. Ostrovskii V., Karimov T., Rybin V., Bobrova Y., Arlyapov V., Butusov D. Bio-inspired neuron based on threshold selector and tunnel diode capable of excitability modulation. *Neurocomputing*, 2025, vol. 624, pp. 129454. <https://doi.org/10.1016/j.neucom.2025.129454>
16. Hodgkin A.L. The local electric changes associated with repetitive action in a non-medullated axon. *The Journal of Physiology*, 1948, vol. 107, no. 2, pp. 165–181. <https://doi.org/10.1113/jphysiol.1948.sp004260>
17. Zhang Y., Mo L., He X., Meng X. Unsupervised spiking neural network based on liquid state machine and self-organizing map. *Neurocomputing*, 2025, vol. 620, pp. 129120. <https://doi.org/10.1016/j.neucom.2024.129120>
18. Hua Q., Wu H., Gao B., Zhao M., Li Y., Li X., et al. A threshold switching selector based on highly ordered Ag nanodots for X-point memory applications. *Advanced Science*, 2019, vol. 6, no. 10, pp. 1900024. <https://doi.org/10.1002/advs.201900024>
19. Bayukov A.V., Gitsevich A.B., Zaitsev A.A., Mokryakov V.V., Petukhov V.M., Khrulev A.K. *Semiconductor Devices: Diodes, Thyristors, and Optoelectronic Devices. A Handbook*. Moscow, Energoatomizdat, 1983, 744 p. (in Russian)
20. Wijesinghe P., Srinivasan G., Panda P., Roy K. Analysis of liquid ensembles for enhancing the performance and accuracy of liquid state machines. *Frontiers in Neuroscience*, 2019, vol. 13, pp. 504. <https://doi.org/10.3389/fnins.2019.00504>
21. McHugh M.L. The chi-square test of independence. *Biochimica Medica*, 2013, vol. 23, no. 2, pp. 143–149. <https://doi.org/10.11613/bm.2013.018>

22. Wang Q., Jin Y., Li P. General-purpose LSM learning processor architecture and theoretically guided design space exploration // Proc. of the IEEE Biomedical Circuits and Systems Conference (BioCAS). 2015. P. 1–4. <https://doi.org/10.1109/biocas.2015.7348397>
23. Hazan H., Saunders D.J., Sanghavi D.T., Siegelmann H., Kozma R. Lattice map spiking neural networks (LM-SNNs) for clustering and classifying image data // Annals of Mathematics and Artificial Intelligence. 2020. V. 88. N 11. P. 1237–1260. <https://doi.org/10.1007/s10472-019-09665-3>
22. Wang Q., Jin Y., Li P. General-purpose LSM learning processor architecture and theoretically guided design space exploration. *Proc. of the IEEE Biomedical Circuits and Systems Conference (BioCAS)*, 2015, pp. 1–4. <https://doi.org/10.1109/biocas.2015.7348397>
23. Hazan H., Saunders D.J., Sanghavi D.T., Siegelmann H., Kozma R. Lattice map spiking neural networks (LM-SNNs) for clustering and classifying image data. *Annals of Mathematics and Artificial Intelligence*, 2020, vol. 88, no. 11, pp. 1237–1260. <https://doi.org/10.1007/s10472-019-09665-3>

Авторы

Холкин Владислав Сергеевич — ассистент, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина); Санкт-Петербург, 197022, Российская Федерация, <https://orcid.org/0000-0002-5010-1841>, super.holkin@mail.ru

Пчёлко Василий Андреевич — аспирант, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина); Санкт-Петербург, 197022, Российская Федерация, <https://orcid.org/0009-0002-2584-1474>, vapchelko@stud.etu.ru

Кленин Владислав Леонидович — кандидат технических наук, доцент, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Санкт-Петербург, 197022, Российская Федерация; заместитель генерального директора, АО «НПЦ «Акварин», Санкт-Петербург, 195196, Российская Федерация, <https://orcid.org/0009-0009-3966-9880>, vklenin@akvamarin-npc.ru

Каримов Тимур Искандарович — кандидат технических наук, доцент, доцент, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Санкт-Петербург, 197022, Российская Федерация, <https://orcid.org/0000-0002-9860-8211>, tikarimov@etu.ru

Копец Екатерина Евгеньевна — кандидат технических наук, доцент, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Санкт-Петербург, 197022, Российская Федерация, <https://orcid.org/0000-0002-5953-255X>, EEKopets@etu.ru

Authors

Vladislav S. Kholkin — Assistant, Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197022, Russian Federation, <https://orcid.org/0000-0002-5010-1841>, super.holkin@mail.ru

Vasily A. Pchelko — PhD Student, Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197022, Russian Federation, <https://orcid.org/0009-0002-2584-1474>, vapchelko@stud.etu.ru

Vladislav L. Klenin — PhD, Associate Professor, Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197022, Russian Federation; Deputy General Director, AO NPTS “AKVAMARIN”, Saint Petersburg, 195196, Russian Federation, <https://orcid.org/0009-0009-3966-9880>, vklenin@akvamarin-npc.ru

Timur I. Karimov — PhD, Associate Professor, Associate Professor, Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197022, Russian Federation, <https://orcid.org/0000-0002-9860-8211>, tikarimov@etu.ru

Ekaterina E. Kopets — PhD, Associate Professor, Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 197022, Russian Federation, <https://orcid.org/0000-0002-5953-255X>, EEKopets@etu.ru

Статья поступила в редакцию 14.11.2025
Одобрена после рецензирования 01.02.2026
Принята к печати 22.03.2026

Received 14.11.2025
Approved after reviewing 01.02.2026
Accepted 22.03.2026



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»