
Информационные системы и модели

УДК 004.383.8.032.26

Модели спайковых нейронных сетей и области их применения

Антонов А.М., Щаников С.А.

В статье представлен обзор научных публикаций по теме спайковых или импульсных нейронных сетей. В обзоре выделены основные направления исследований в данной области и показаны достоинства существующих подходов к реализации импульсных нейронных сетей. Так же в статье описаны и рассмотрены проблемы, существующие в данной области.

Ключевые слова: мемристоры, спайковые нейронные сети, синаптическая пластичность, численное моделирование, компьютерное моделирование.

Введение


В настоящее время в область обработки данных все сильнее и сильнее интегрируются методы искусственного интеллекта. Хотя, формальные искусственные нейронные сети (формальные ИНС) применяются наиболее чаще остальных видов нейронных сетей (НС), как показывают результаты исследований, лучших показателей позволяют достичь спайковые или же импульсные нейронные сети (СИНС), в которых информация кодируется не в числовом виде, а последовательностью импульсов – спайков. Спайковая нейронная сеть является самой реалистичной, с точки зрения физиологии, моделью нейронной сети и так же имеет ряд преимуществ по сравнению с классическими НС, таких как энергоэффективность, масштабируемость и возможность взаимодействия с динамической асинхронной средой.

Как информационная система, нейрон в такой сети имеет входы (дендриты), связи (называемые синапсами), тело (сому), реализующее обработку информации, и выход — аксон. Сигналы, зарождающиеся в теле нейрона, проходят через его аксон на синапс следующего нейрона, после чего комбинируются с сигналами, поступившими от других нейронов, определяя дальнейшее поведение этого нейрона. При этом одно из главных отличий СИНС от формальных ИНС состоит именно в природе сигналов, передаваемых от

одного нейрона к другому. В импульсных нейросетях нейроны обмениваются очень короткими импульсами, амплитуда которых всегда одинакова, — так называемыми спайками [1].

Нейрон в СИНС обладает некоторым потенциалом, который накапливается во времени и при достижении определенного порога генерирует спайк, после чего значение потенциала падает до нижнего уровня. То есть, сеть получает на входы серию спайков и выдает серию спайков на выходе (рис. 1). Информация при этом кодируется точной позицией отдельных спайков во времени либо их средней частотой. Фактор времени в таких нейронных сетях становится крайне важным — важны задержки распространения импульсов в межнейронных связях, временные характеристики отдельных нейронов как динамических систем и так далее.

Спайк с точки зрения биологии (рис. 2) является сигналом, генерируемым нейронами в нервной системе. Он обычно имеет более сложную форму, чем простой импульс, может длиться доли миллисекунды и обычно имеет определенный временной профиль. Хотя спайк с физиологической точки зрения нельзя приравнять к импульсу (прямоугольному или треугольному), при реализации СИНС на компьютере из-за принципа его работы, эти понятия можно приравнять. То есть в контексте спайковых нейронных сетей термины "спайк"




и "импульс" используются взаимозаменяемо и означают одно и то же.

Устройство спайковых нейронных сетей и виды их нейронов

СИНС состоят из импульсных нейронов, связанных синапсами. Рассмотрим устройство импульсной нейронной сети через процесс прохождения по ней сигналов. Работа СИНС начинается с получения входных сигналов, которые представляют информацию, поступающую в сеть. Входные сигналы могут быть как аналоговыми (непрерывными значени-

ями), так и импульсами (спайками), в зависимости от конкретной архитектуры СИНС. Сигналы проходят через синапсы, которые связывают нейроны между собой. У каждого синапса есть вес, который определяет важность этой связи. Веса регулируют то насколько сильно входные сигналы влияют на активацию нейрона. Каждый нейрон имеет мембрану. Она состоит из двух элементов: потенциал мембраны (мембранный потенциал) и порог активации. Потенциал мембраны накапливает некоторое суммарное значение заряда из поступающих в нейрон импульсов,



а порог активации – это значение мембранного потенциала, которое нейрон должен достичь, чтобы сгенерировать спайк. То есть, если сумма взвешенных входных сигналов превышает этот порог, нейрон генерирует спайк. Тут стоит ещё раз отметить, что в СИНС время имеет значение: нейроны реагируют на спайки с учетом временных интервалов между ними. Спайки, сгенерированные нейронами, интегрируются с течением времени. Это может быть реализовано, например, путем суммирования спайков в небольших временных интервалах, так же это позволяет учитывать временную зависимость в данных. Результат работы импульсной нейронной сети может быть зафиксирован в выходных нейронах, которые генерируют спайки в зависимости от обработанных данных. Выходные спайки могут быть интерпретированы как ответ сети [4].

В науке до конца не изучен вопрос кодирования информации в нейронах с использованием спайков, и это является одним из ключевых аспектов исследований в данной области. Считается, что информация может быть представлена двумя основными методами: частотой генерации спайков и точным временем появления спайков (так называемым временным кодированием). Существует разнообразие подходов к кодированию с использованием частоты спайков, включая подсчет их количества, анализ плотности спайков или популяционную активность.

Долгое время было распространено представление о спайках как коротких, резких импульсах в потенциале мембраны нейрона, которые служат для передачи информации между нейронами [7]. Однако вопрос о том, как именно информация кодируется с использованием спайков, остается предметом активного обсуждения в сообществе вычислительной нейробиологии. Вначале считалось, что мозг кодирует информацию через частоту генерации спайков [8]. Но исследования в области нейробиологии показали, что высокоскоростная обработка информации в мозге не мо-

жет быть осуществлена с использованием исключительно схемы кодирования на основе частоты спайков [9].

Например, в случае быстрой обработки информации, такой как распознавание цвета, визуальных данных, запахов и аудио-сигналов, выявлено, что человеческая система обработки информации может выполнять задачи за время, составляющее менее 100 миллисекунд [10]. Учитывая, что каждый нейрон требует приблизительно 10 миллисекунд для обработки сигнала, становится очевидным, что частотное кодирование становится неэффективным на таких кратких временных интервалах.

В этом контексте, точное временное кодирование спайков представляет собой более обоснованный метод для обеспечения высокоскоростной обработки сигналов. Кроме того, передача информации путем кодирования количества спайков требует значительных энергетических ресурсов. Вдобавок, метод кодирования через точное время спайка позволяет эффективно передавать больше информации с использованием ограниченного количества спайковых нейронов [11]. Таким образом, представляется, что точное временное кодирование отдельных спайков, а не только их количества или частоты, вероятно, является ключевым механизмом передачи информации.

Тем не менее, следует отметить, что точные механизмы обучения биологических нейронов все еще остаются предметом исследований.

В настоящее время существует два направления исследования СИНС:

- создание компьютерных моделей, которые точно повторяют модели функционирования нейронов мозга, благодаря чему станет возможным как объяснение механизмов его работы, так и диагностика/лечение заболеваний и травм ЦНС;

- создание компьютерных моделей, абстрактно повторяющих модели функционирования нейронов мозга, что позволит использовать все преимущества мозга, таких как помехозащищенность и энергоэффективность, при

анализе больших объемов данных, запоминанию, принятию оптимальных решений [6].

Далее сосредоточимся на рассмотрении второго вида исследований и рассмотрим классификацию топологий для таких СИНС. Обычно рассматривается 3 типа топологий: сети с прямой связью, рекуррентные и гибридные сети. Примерами гибридных сетей являются такие сети как: Synfire [12] и отказоустойчивая СИНС [13], в которых некоторые части могут использовать исключительно прямую связь, в то время как другие части имеют рекуррентную топологию.

Широко известно, что архитектура нейронных сетей в головном мозге изменяется динамически в процессе обучения. Ученые полагают, что первичные сенсорные и зрительные области имеют стабильное ядро, которое меняется незначительно со временем, но при этом они имеют гибкие периферические области, которые часто подвергаются изменениям [14]. Примерами нейронных сетей с динамической топологией являются эволюционирующая спайковая нейронная сеть (eSNN) [15], нейронная сеть с динамической эволюцией (deSNN) [16] и метод формирования динамических кластеров с использованием популяций спайковых нейронов [17]. Это позволяет увеличить их способность обработки информации и придать им большую схожесть с биологическими системами.

СИНС, модели которых, основаны на биологических принципах функционирования мозга, моделируют активность нейронов с учетом времени и генерируют импульсы (спайки) вместо непрерывных значений. В таких сетях выделяют несколько основных типов нейронов:

- интегрирующие-и-генерирующие нейроны (Integrate-and-Fire). Это самая популярная модель нейрона в СИНС. Интегрирующие нейроны накапливают входные сигналы во времени для принятия решения о генерации спайка. Когда мембранный потенциал достигает определенного порогового значения, нейрон генерирует спайк и сбрасывает свой потенциал. Они могут быть как возбуждающими (генерирующими спайки при

достижении порога), так и тормозными (генерирующими спайки при превышении порога).

- реципрокальные нейроны (Reciprocal Neurons). Эти нейроны могут работать в парах и ингибировать друг друга, то есть активация одного нейрона может привести к ингибированию другого и наоборот. Так же один нейрон может генерировать спайки, которые подавляют активность другого нейрона, и наоборот. Они обычно применяются в сетях, использующих механизмы взаимодействия и ингибиции, такие как «competitive learning networks», могут включать в себя реципрокальные элементы.

- нейроны с долгосрочной зависимостью (LSTM-нейроны): LSTM (Long Short-Term Memory) — это особый тип рекуррентных нейронов, предназначенных для моделирования долгосрочных зависимостей в данных и предотвращения проблемы затухания («vanishing gradient problem»), которая часто возникает при обучении глубоких нейронных сетей. Модель LSTM была предложена Селлом Хохрайтером и Юргеном Шмидхубером в 1997 году. Они способны удерживать информацию в течение долгого времени и обрабатывать последовательные данные. Так же LSTM включает в себя механизмы для предотвращения проблемы затухания градиента, что позволяет эффективно обучать глубокие нейронные сети, использует «вентильные механизмы», такие как вентили забывания (forget gate), вентили входа (input gate), и вентили выхода (output gate), чтобы регулировать поток информации и управлять, какая информация передается или забывается и поддерживает состояние ячейки (Cell State), которое служит для передачи информации в течение времени.

Далее сосредоточимся на рассмотрении Integrate-and-Fire нейронов, так как они наиболее распространены для решения задач с помощью СИНС и среди них так же можно выделить разные модели нейронов. Рассмотрим самые популярные:

- LIF (Leaky Integrate-and-Fire). Эта модель включает в себя интегрирование входных сиг-

налов и высылающие импульсы при достижении определенного порога. Название «Leaky Integrate-and-Fire» отражает основные характеристики этой модели. Leaky или же утечка в названии означает, что модель предполагает наличие утечки тока, что означает постепенную утрату заряда мембраной нейрона со временем. Это моделируется с использованием параметра, который характеризует скорость утечки.

Математически модель LIF-нейрона может быть описана следующим образом (1):

$$\tau_m \frac{dV}{dt} = -(V - V_{rest}) + R_m I(t), \quad (1)$$

где: V - мембранный потенциал, V_{rest} - потенциал покоя, τ_m - постоянная времени мембраны, R_m - сопротивление мембраны, $I(t)$ - входной ток.

Если V достигает порогового значения, то нейрон генерирует импульс и сбрасывает свой потенциал до V_{rest} [18].

Модель Ходжкина-Хаксли (Hodgkin-Huxley). Эта модель представляет собой классическую математическую модель динамики мембранного потенциала нейрона, созданную британскими физиологами Аланом Ходжкином и Эндрю Хаксли в 1952 году. Эта модель описывает процессы, происходящие в нейронах, которые генерируют потенциалы действия (спайки). Модель Ходжкина-Хаксли основана на исследованиях биологии и включает в себя четыре основных компонента: мембранный ток содиума, мембранный ток калия, ток утечки.

Мембранный ток содиума (I_{Na}) — ток, обусловленный протеканием ионов натрия через мембрану.

Мембранный ток калия (I_K) — ток, обусловленный протеканием ионов калия через мембрану.

Ток утечки (I_{leak}) — ток, связанный с утечкой ионов через мембрану.

Емкостная составляющая (C_m) — емкостное поведение мембраны.

Динамику модели Ходжкина-Хаксли можно описать так (2):

$$C_m \frac{dV_{mem}}{dt} = I - I_{Na} - I_K - I_{leak}, \quad (2)$$

где: V_{mem} - мембранный потенциал, C_m - емкость мембраны, I - внешний ток (включает в себя внешние стимулы), I_{Na} - мембранный ток содиума (рассчитывается через дифференциальное уравнение), I_K - мембранный ток калия (рассчитывается через дифференциальное уравнение), I_{leak} - ток утечки (рассчитывается через дифференциальное уравнение).

Динамика модели Ходжкина-Хаксли описывается системой дифференциальных уравнений и является ключевым вкладом в понимание генерации потенциалов действия, так же, являясь основой для более сложных моделей нейрона, таких как модели Ижикевича и другие. Она помогла исследователям понять механизмы, лежащие в основе возбудимости и проводимости нейронов.

Модель Ижикевича. Это математическая модель нейрона, предложенная российским физиком и нейрофизиологом Евгением Ижикевичем в 2003 году. Эта модель представляет собой упрощенный способ описания динамики мембранного потенциала и генерации спайков в нейронах. Основные элементы модели Ижикевича включают два дифференциальных уравнения, которые описывают динамику мембранного потенциала и восстановления. Модель включает в себя две переменные состояния: мембранный потенциал (V) и восстановительную переменную (u).

Уравнения модели Ижикевича выглядят следующим образом (3, 4):


$$\frac{dV}{dt} = k(V - V_r)(V - V_t) - u + I, \quad (3)$$

где: V - мембранный потенциал, u - восприимчивость к стимуляции, k - чувствительность мембраны к входным стимулам, V_r - уровень потенциала в покое, V_t - пороговый потенциал, I - внешний ток (включает в себя внешние стимулы).

$$\frac{du}{dt} = a(b(V - V_r) - u), \quad (4)$$

где: a, b - параметры, влияющие на динамику переменной u ,

При каждом срабатывании спайка нейрон переходит в новое состояние, зависящее от динамики мембранного потенциала и параметров модели, которые можно настраивать




для получения различных типов динамического поведения. Модель Ижикевича позволяет эффективно моделировать разнообразные типы нейронов, включая как возбуждающие, так и тормозные нейроны, а также нейроны с различными типами возбудимости. Эта модель стала популярной в исследованиях импульсных нейронных сетей и используется для анализа и моделирования динамического поведения нейронов [19].

В конце части о видах нейронов в СИНС так же стоит отметить, что в настоящее время было предложено множество моделей импульсных нейронов, и они демонстрируют компромисс между биологической точностью и вычислительной осуществимостью (рис. 3) и, что точные типы и характеристики нейронов могут различаться в зависимости от конкретной архитектуры и задачи импульсной нейронной сети.

Применение спайковых нейронных сетей

За последние десятилетия в области нейронных сетей достигнут заметный прогресс, в основном связанный с развитием глубокого обучения, обеспечивающего выдающуюся производительность в областях, таких как компьютерное зрение и обработка естественного языка, а именно: обнаружение объектов [21], сегментация изображений [22], перевод

и генерация текста [23]. Тем не менее, СИНС до сих пор не полностью соответствуют формальным ИНС с точки зрения производительности при решении типовых задач машинного обучения. Даже такие широко используемые наборы классификационных данных, как MNIST [24] и CIFAR-10 [25], по-прежнему представляют собой проблему для сетей такого типа. Несмотря на это, исследования в этой области активно ведутся и в их процессе уже были сделаны успешные шаги. Одним из таких примеров является обнаружение объектов, где СИНС добилась аналогичных результатов с формальной ИНС, но при этом была гораздо более энергоэффективной с точки зрения вычислений. Сеть была обучена с использованием набора данных KITTI [26]. Еще одним примером из области компьютерного зрения является сегментация изображений, выполненная с использованием сверточной нейронной сети (СНС) UNET на базе СИНС. В этом случае СНС была обучена на наборе данных ISBI 2D EM и преобразована в СИНС [27]. Еще одним применением СИНС является их использование в транспортных средствах с датчиками «Лидар» (LiDAR). Была продемонстрирована способность автономно контролировать скорость и рулевое управление в статических и динамических условиях [28].



Так же, важной тенденцией в подходах к компьютерному зрению на основе СИНС являются камеры, работающие на основе событий (рис. 4). Эти устройства захватывают видео с фиксированной частотой кадров и записывают только изменения значений интенсивности пикселей. Их вывод представляет собой последовательность событий включения/выключения, которые можно интерпретировать как входные импульсы для СИНС. Они называются динамическими видеосенсорами (DVS). Их основные преимущества включают низкое энергопотребление, широкий динамический диапазон, высокое временное разрешение и меньшие требования к объему памяти [29]. Для проверки производительности спайковых нейронных сетей с использованием динамических видеосенсоров необходимо наличие специализированных наборов данных. К сожалению, их не так много, поскольку DVS обычно требуется включать в процесс создания набора данных. Несмотря на это, были предприняты попытки преобразовать существующие наборы данных для машинного обучения в форму, совместимую с событийной природой DVS. Примеры включают N-MNIST, N-Caltech101 [30] и CIFAR10-DVS [31].

СИНС активно применяются в анализе данных, основанном на событиях, благодаря их высокой энергоэффективности [32]. Когда речь идет о рассмотрении СИНС с точки зрения энергоэффективности, следует упомянуть несколько областей их применения. Было об-

наружено, что использование СИНС в задачах, связанных с рефлексивной обработкой информации, может быть эффективным и применимо в концептуальных ячейках и связанным с ними математической концепции многомерного мозга. Рефлексивные спайковые нейронные сети (Reflective Spiking Neural Networks) могут использовать присущую им динамику для имитации сложных, неврефлективных функций мозга, таких как создание новых навыков на основе ранее изученных. СИНС могут быть реализованы как аналоговые вычислительные системы [33].

Помимо вышеупомянутых областей применения, СИНС также используются в областях когнитивной обработки. Одним из примеров является модель пространственной памяти, реализованная в СИНС и использованная на роботе, перемещающемся в среде с нейтральными и вредными зонами. В этом алгоритм STDP перестраивает связи в СИНС и формирует пространственную память, аналогичную когнитивным картам, связанным с негативным опытом, что приводит к обучению робота избегать вредных зон [34]. Еще одной областью когнитивного развития является применение СИНС для ассоциативного обучения восприятию информации. Этот подход уточняет отношения между восприятием информации и может отражать связь с естественным общением с человеком. Предложенный метод был применен в роботе-партнере, который учится взаимодействовать с людьми [35].

Роботы обычно имеют ограниченные аппаратные ресурсы, и поэтому энергоэффективные спайковые нейронные сети, работающие на асинхронном оборудовании на основе событий, могут идеально подходить для применения в этой области. СИНС, работающая на нейроморфном процессоре Intel Loihi, использовалась для решения задач локализации в одномерном пространстве и построения карты (SLAM) одновременно и достигла точности, сравнимой с алгоритмом GMapping, при этом потребляя в 100 раз меньше энергии [36].

СИНС имитируют человеческий мозг, поэтому они менее эффективны на стандартном синхронном компьютерном оборудовании (на архитектуре фон Неймана), чем формальные ИНС, из-за необходимости запрашивать модель в цикле временных шагов. Однако эти сети могут быть гораздо более эффективными на специализированном нейроморфном оборудовании. Такое оборудование состоит из асинхронных схем и управляется событиями [37]. Аппаратная асинхронность допускает раздельность потоков данных (многопоточность) в СИНС. Известно, что менее 10 % нейронов головного мозга одновременно активны [38]. Это свойство не используется в формальных ИНС, поскольку все нейроны активны при каждом прямом проходе сети. Многопоточность данных также повышает эффективность алгоритмов обучения для нейронных сетей. Алгоритмы обучения изменяют только части сети в зависимости от активности подмножества нейронов. Ярким примером алгоритма обучения в этой категории является пластичность, зависящая от времени пика (STDP) и ее производные [39]. Противоположный подход к обучению, в котором участвуют все нейроны на каждой итерации, — это обратное распространение ошибки. Этот подход используется для формальных ИНС и предполагает использование функции потерь, которая описывает, насколько хорошо/плохо сеть выполняет данную задачу. Это минимизирует потери за счет обновления весов на основе их индивидуальных градиентов. Важность программно-аппаратной организации имеет решающее значение для дальнейшего развития нейроробототехники. Одной из наиболее важных инфраструктур для этого является среда нейронной инженерии (NEF) [40].

Заключение

Проведенный обзор публикаций в области современного исследования спайковых нейронных сетей, позволяет сделать выводы о том, что за последнее десятилетие СИНС привлекли огромное внимание и показали, что они многообещающи в плане возможности обработки естественной информации, низкого энергопотребления и высокой биологической правдоподобности. На данный момент спайковые ИНС хуже формальных ИНС подходят для работы на обычных компьютерах из-за необходимости проведения моделирования за несколько временных шагов, но реализация всего потенциала СИНС стоит затрат на решение стоящих перед этим задач.

Обучение СИНС. Существует два основных подхода к их обучению: обучение с помощью STDP и преобразование предварительно обученной формальной ИНС в модель СИНС. Первый подход имеет проблему, заключающуюся в том, что СИНС, обученная методом градиентного спуска, ограничена малой архитектурой и обеспечивает низкую производительность на крупномасштабных наборах данных, таких как ImageNet. Второй подход увеличивает вычислительную сложность из-за большого количества временных шагов, хотя эти СИНС достигают точности, сравнимой с искусственными [41].

Архитектура СИНС. Хотя большинство существующих работ по формальным ИНС сосредоточено на проблеме классификации изображений и используют доступные архитектуры ИНС, такие как VGG или Resnet, наличие соответствующей архитектуры СИНС имеет решающее значение. В 2022 году мета-обучение, такое как поиск нейронной архитектуры (NAS), было использовано для поиска лучшей архитектуры СИНС [42].

Производительность СИНС. Хотя СИНС продемонстрировали впечатляющее преимущество в отношении энергоэффективности, а по точности они догнали формальные ИНС, все это достигалось на сложной, разреженной и зашумленной пространственно-временной информации и в определенных условиях. Для составления конкуренции формальным искусственным нейронным сетям, СИНС требует аппаратной реализации, чтобы отойти от структуры фон Неймана. На момент написания статьи в этой области активно ведутся исследования и разработки, что демонстрируется разработанными устройствами: Neurogrid, BrainScaleS, Intel Loihi, IBM TrueNorth, Tianjic или мемристоры (memristors)

[18]. Однако эти технологии не так широко распространены.

В конце можно подвести итог, что исследования в области СИНС активно ведутся и можно не просто сказать, что это перспективная научная область, но и ожидать гораздо большего прогресса в развитии спайковых нейронных сетей.

Литература

1. Киселев М.В. Моделирование импульсных нейронных сетей - цели, методы, аппаратные платформы / I Национальный конгресс по когнитивным исследованиям, искусственному интеллекту и нейроинформатике. Сборник пленарных и индустриальных докладов. Доклады симпозиумов. Москва, 2020. С. 81-84.
2. В.Л. Дунин-Барковский Нейронные механизмы естественного и искусственного интеллекта / I Национальный конгресс по когнитивным исследованиям, искусственному интеллекту и нейроинформатике. Сборник пленарных и индустриальных докладов. Доклады симпозиумов. Москва, 2020. С. 22-29.
3. Kiselev M. Empirical models as a basis for synthesis of large spiking neural networks with pre-specified properties / В сборнике: NCTA 2014 - Proceedings of the International Conference on Neural Computation Theory and Applications. 6. 2014. С. 264-269
4. Maas, Wolfgang. Networks of spiking neurons: The third generation of neural network models / Neural Networks : journal. 1997. С. 1659-1671.
5. Скарп И.И. Концепция построения биологической правдоподобной искусственной нейронной сети / Нейро-нечеткие технологии моделирования в экономике. Киев: КНЕУ, 2014. С. 188—218.
6. Киселев М.В., Как исследования нейронных сетей перешли из лабораторий в компании? – URL: <https://postnauka.org/faq/36677> (Проверено: 03.12.2023)
7. A review of learning in biologically plausible spiking neural networks / Aboozar Taherkhani, Ammar Belatreche, Yuhua Li et al. // Neural Networks. – 2020. — Feb. — Vol. 122. — P. 253–272.
8. Masquelier T., Deco G. Learning and Coding in Neural Networks // Principles of Neural Coding. — CRC Press, 2013. — May. — P. 513–526.
9. Brette R. Philosophy of the Spike: Rate-Based vs. Spike-Based Theories of the Brain // Frontiers in Systems Neuroscience. — 2015. — Vol. 9. — Publisher: Frontiers.
10. A review of learning in biologically plausible spiking neural networks / Aboozar Taherkhani, Ammar Belatreche, Yuhua Li et al. // Neural Networks. – 2020. — Feb. — Vol. 122. — P. 253–272.
11. Paugam-Moisy H., Bohte S. Computing with Spiking Neuron Networks // Handbook of Natural Computing / Ed. by Grzegorz Rozenberg, Thomas Bäck, Joost N. Kok. — Berlin, Heidelberg : Springer, 2012. — P. 335–376.
12. Abeles M. Synfire chains // Scholarpedia. — 2009. — Jul. — Vol. 4, no. 7. — P. 1441.
13. Srinivasa N., Cho Y. Self-Organizing Spiking Neural Model for Learning Fault-Tolerant Spatio-Motor Transformations // IEEE Transactions on Neural Networks and Learning Systems. — 2012. — Oct. — Vol. 23, no. 10. — P. 1526–1538. – Conference Name: IEEE Transactions on Neural Networks and Learning Systems.
14. Task-Based Core-Periphery Organisation of Human Brain Dynamics / Danielle S. Bassett, Nicholas F. Wymbs, M. Puck Rombach et al. // arXiv:1210.3555 [condmat, physics:nlin, q-bio, stat]. — 2013. — Oct.
15. Wysoski S. G., Benuskova L., Kasabov N. Fast and adaptive network of spiking neurons for multiview visual pattern recognition // Neurocomputing. – 2008. — Aug. — Vol. 71, no. 13. — P. 2563–2575.
16. Dynamic evolving spiking neural networks for on-line spatio- and spectro-temporal pattern recognition / Nikola Kasabov, Kshitij Dhoble, Nuttapod Nuntalid, Giacomo Indiveri // Neural Networks. — 2013. — May. — Vol. 41. — P. 188–201.
17. Belatreche A., Paul R. Dynamic cluster formation using populations of spiking neurons // Unknown Host Publication. — 2012. — Jul. — P. 1–6.
18. В.А. Евграфов, Е.А. Ильюшин. Спайковые нейронные сети / International Journal of Open Information Technologies. 2021 — Vol. 9. — no. 7.
19. E.M. Izhikevich, Dynamical Systems in Neuroscience: The Geometry of Excitability and Bursting, USA, MA, Cambridge: The MIT Press., 2007.
20. Izhikevich E.M. Which model to use for cortical spiking neurons? IEEE Trans. Neural Netw. 2004;15:1063–1070. doi: 10.1109/TNN.2004.832719.
21. Wang, C.-Y.; Bochkovskiy, A.; Liao, H.-Y.M. YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors. arXiv 2022, arXiv:2207.02696.
22. Ronneberger, O.; Fischer, P.; Brox, T. U-Net: Convolutional networks for biomedical image segmentation. In Medical Image Computing and Computer-Assisted Intervention (MICCAI); LNCS; Springer: Cham, Switzerland, 2015; Volume 9351, pp. 234–241.
23. Brown, T.; Mann, B.; Ryder, N.; Subbiah, M.; Kaplan, J.D.; Dhariwal, P.; Neelakantan, A.; Shyam, P.; Sastry, G.; Askell, A.; et al. Language Models Are Few-Shot Learners. In Advances in Neural Information Processing Systems; Larochelle, H., Ranzato, M., Hadsell, R., Balcan, M.F., Lin, H., Eds.; Curran Associates, Inc.: Red Hook, NJ, USA, 2020; Volume 33, pp. 1877–1901.
24. LeCun, Y.; Bottou, L.; Bengio, Y.; Ha, P. Gradient-Based Learning Applied to Document Recognition. Proc. IEEE 1998, 86, 2278–2324.

25. Krizhevsky, A. Learning Multiple Layers of Features from Tiny Images. – URL: <http://www.cs.toronto.edu/~kriz/learning-features-2009-TR.pdf> (Проверено: 03.12.2023).
26. Zhou, S.; Chen, Y.; Li, X.; Sanyal, A. Deep SCNN-Based Real-Time Object Detection for Self-Driving Vehicles Using LiDAR Temporal Data. *IEEE Access* 2020, 8, 76903–76912.
27. Patel, K.; Hunsberger, E.; Batir, S.; Eliasmith, C. A Spiking Neural Network for Image Segmentation. *arXiv* 2021, arXiv:2106.08921v1.
28. Shalumov, A.; Halaly, R.; Tsur, E.E. LiDAR-driven spiking neural network for collision avoidance in autonomous driving. *Bioinspiration Biomimetics* 2021, 16, ac290c.
29. Baby, S.A.; Vinod, B.; Chinni, C.; Mitra, K. Dynamic vision sensors for human activity recognition. In *Proceedings of the 2017 4th IAPR Asian Conference on Pattern Recognition (ACPR)*, Nanjing, China, 26–29 November 2017; IEEE: Nanjing, China, 2017; pp. 316–321.
30. Orchard, G.; Jayawant, A.; Cohen, G.K.; Thakor, N. Converting Static Image Datasets to Spiking Neuromorphic Datasets Using Saccades. *Front. Neurosci.* 2015, 9, 437.
31. Li, H.; Liu, H.; Ji, X.; Li, G.; Shi, L. CIFAR10-DVS: An Event-Stream Dataset for Object Classification. *Front. Neurosci.* 2017, 11, 309.
32. Han, B.; Roy, K. Deep spiking neural network: Energy efficiency through time based coding. In *Computer Vision—ECCV 2020*; Vedaldi, A., Bischof, H., Brox, T., Frahm, J.M., Eds.; *Lecture Notes in Computer Science*; Springer: Cham, Switzerland, 2020; Volume 12355.
33. Makarov, V.A.; Lobov, S.A.; Shchanikov, S.; Mikhaylov, A.; Kazantsev, V.B. Toward Reflective Spiking Neural Networks Exploiting Memristive Devices. *Front. Comput. Neurosci.* 2022, 16, 859874.
34. Lobov, S.A.; Zharinov, A.I.; Makarov, V.A.; Kazantsev, V.B. Spatial Memory in a Spiking Neural Network with Robot Embodiment. *Sensors* 2021, 21, 2678.
35. Mo, L.; Wang, G.; Long, E.; Zhuo, M. ALSA: Associative Learning Based Supervised Learning Algorithm for SNN. *Front. Neurosci.* 2022, 16, 838832.
36. Tang, G.; Shah, A.; Michmizos, K.P. Spiking Neural Network on Neuromorphic Hardware for Energy-Efficient Unidimensional SLAM. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Macau, China, 4–8 November 2019; pp. 4176–4181.
37. Ivanov, D.; Chezhegov, A.; Grunin, A.; Kiselev, M.; Larionov, D. Neuromorphic Artificial Intelligence Systems. *arXiv* 2022, arXiv:2205.13037v1.
38. Quian Quiroga, R.; Kreiman, G. Measuring Sparseness in the Brain: Comment on Bowers (2009). *Psychol. Rev.* 2010, 117, 291–297.
39. Diehl, P.U.; Cook, M. Unsupervised Learning of Digit Recognition Using Spike-Timing-Dependent Plasticity. *Front. Comput. Neurosci.* 2015, 9, 99.
40. Eliasmith, C.; Anderson, C.H. *Neural Engineering: Computation, Representation, and Dynamics in Neurobiological Systems*; MIT Press: Cambridge, MA, USA, 2003.
41. He W., Wu Y., Deng L., Li G., Wang H., Tian Y., Ding W., Wang W., Xie Y. Comparing SNNs and RNNs on neuromorphic vision datasets: Similarities and differences. *Neural Netw.* 2020;132:108–120. doi: 10.1016/j.neunet.2020.08.001.
42. Kim Y., Li Y., Park H., Venkatesha Y., Panda P. Neural Architecture Search for Spiking Neural Networks. *arXiv*. 20222201.10355

Работа выполнена при поддержке стипендии Президента РФ СП-5411.2021.5.
Поступила 03 мая 2023 г.

The article provides an overview of scientific publications on the topic of spiking or impulse neural networks. The review highlights the main areas of research in this field and shows the advantages of existing approaches to the implementation of impulse neural networks. The article also describes and discusses the problems that exist in this area.

Key words: memristors, spiking neural networks, synaptic plasticity, numerical modeling, computer modeling.

Антонов Александр Михайлович – лаборант-исследователь лаборатории разработки систем искусственного интеллекта Муромского института (филиала) ФГОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых».

E-mail: cfifant@mail.ru.

Щаников Сергей Андреевич – кандидат технических наук, ведущий научный сотрудник лаборатории разработки систем искусственного интеллекта Муромского института (филиала) ФГОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых».

E-mail: seach@inbox.ru.

Адрес: 602264, Муром, ул. Орловская, д. 23.