

А.М. КОРСАКОВ, Л.А. АСТАПОВА, А.В. БАХШИЕВ  
**ПРИМЕНЕНИЕ СЕГМЕНТНОЙ СПАЙКОВОЙ МОДЕЛИ  
НЕЙРОНА СО СТРУКТУРНОЙ АДАПТАЦИЕЙ ДЛЯ РЕШЕНИЯ  
ЗАДАЧ КЛАССИФИКАЦИИ**

*Корсаков А.М., Астапова Л.А., Бахшиев А.В. Применение сегментной спайковой модели нейрона со структурной адаптацией для решения задач классификации.*

**Аннотация.** Рассматриваются варианты применения сегментной спайковой модели нейрона с возможностью структурной адаптации для решения задач классификации. Проводится анализ современного состояния спайковых нейронных сетей. Делается вывод о крайне низком количестве работ по исследованию сегментных моделей нейрона. В качестве модели нейрона для данной работы обосновывается выбор сегментной спайковой модели. Приводится краткое описание такой модели, отмечены её основные особенности, позволяющие производить её структурное реконфигурирование. Описывается способ структурной адаптации модели ко входному паттерну импульсов. Приводится общая схема организации сегментных спайковых нейронов в сеть для решения задачи классификации. В качестве кодирования числовой информации в паттерны импульсов выбирается временное кодирование. Приводятся краткие результаты экспериментов по решению задачи классификации на общедоступных наборах данных (Iris, MNIST). Делается вывод о сопоставимости полученных результатов с результатами, полученными классическими методами. Кроме того, приводится подробное пошаговое описание экспериментов по определению состояния телеуправляемого необитаемого подводного аппарата: определение расстояния такого аппарата до дна и определение характера его движения. Показано соответствие полученных результатов реальному состоянию телеуправляемого необитаемого подводного аппарата. Сделан вывод о перспективности применения спайковых сегментных моделей нейрона с возможностью структурной адаптации при решении задач классификации. Рассмотрены дальнейшие перспективные продолжения исследований основанных на сегментных спайковых моделях нейрона.

**Ключевые слова:** нейроморфные системы, спайковый нейрон, спайковые нейронные сети, задача классификации, телеуправляемый необитаемый подводный аппарат.

**1. Введение.** Искусственные нейронные сети (ИНС) представляют собой упрощённые модели биологических нейронных сетей [1]. В классических ИНС входы и выходы нейронов обычно имеют вид аналоговых величин, в то время как в биологических нейронах эти сигналы определяются частотой импульсов [2]. Однако экспериментальные данные нейробиологии свидетельствуют о том, что биологическая нервная система кодирует информацию не только при помощи частоты возбуждения нейронов, но и через моменты времени генерации импульсов (спайков) [3]. Используя биологически правдоподобные модели спайковых нейронов в качестве базовой единицы для построения спайковых нейронных сетей (СНС), авторы [4-6] кодируют и обрабатывают нейронную информацию при помощи

рассчитанных последовательностей спайков. СНС часто называют третьим поколением нейронных сетей [7]. Они обладают значительно большими возможностями настройки нейронных сигналов, а также аппроксимации любой непрерывной функции [8]. Кроме того, показано, что они являются подходящим инструментом для обработки пространственно-временной информации [9].

Обучение с учителем в ИНС обеспечивает механизм принудительного сопоставления входных данных с желаемым результатом [10, 11]. Экспериментальные исследования показали, что обучение с учителем существует и в биологической нервной системе [12], но нет четкого понимания, как конкретно биологические нейронные сети реализуют этот процесс. Показано, что алгоритмы обучения с учителем для традиционных ИНС, такие как алгоритм обратного распространения ошибки [13], не могут быть использованы непосредственным образом для СНС [14].

Обучение с учителем для СНС является важной областью исследований. Исследователи проделали большой объём работы по обучению с учителем для СНС и достигли определённых результатов [14]. Алгоритмы обучения с учителем для СНС, предложенные в последние годы, можно разделить на несколько категорий с разных точек зрения [15]:

- по способу сетевой архитектуры их можно разделить на алгоритмы обучения с учителем для однослойных СНС, многослойных СНС с прямым распространением сигнала и рекуррентных СНС;
- по режиму работы их можно разделить на алгоритмы онлайн обучения и алгоритмы оффлайн обучения (алгоритмы пакетного обучения) [16];
- по способу кодирования информации их можно разделить на СНС, которые в ответ на входные временные или пространственно-временные данные в качестве выходных данных генерируют один спайк, и на СНС, которые генерируют последовательность спайков;
- по структурной динамике их можно разделить на обучение при фиксированных структурах СНС (регулярные СНС) и обучение в реконфигурируемых СНС (нерегулярные СНС) [17];
- по способу представления знаний их можно разделить на обучение, не основанное на знаниях, и обучение, направленное на получение знаний [18].

Произведя анализ требований к СНС для решения задачи классификации с учётом выше сказанного, авторы пришли к следующим результатам:

- с точки зрения сетевой архитектуры предлагается использовать СНС с прямым распространением сигнала,
- с точки зрения режима работы в настоящей работе будет использоваться оффлайн обучение. Более предпочтительное онлайн обучение на данный момент является лишь перспективным направлением, по которому в настоящее время ведутся работы,
- с точки зрения кодирования информации используется временное (time-to-first-spike) кодирование, что повышает энергоэффективность системы в случае аппаратной реализации,
- с точки зрения структурной динамики предлагаемый подход относится к реконфигурируемым растущим нейронным сетям, однако, в рассмотренных в разделах 6 и 7 примерах используются фиксированные структуры, что является достаточным для рассматриваемых задач.

Следует отметить, что с точки зрения авторов приведённая выше классификация является не полной, поскольку в ней не рассматривается возможность структурного реконфигурирования самой модели нейрона. К настоящему времени работы, использующие такой подход, практически отсутствуют. Применение модели нейрона с учетом описания структуры дендритного дерева предложено в [19], однако модель не рассматривает сигналы в сети как спайковые.

Анализ существующих решений, демонстрирующих спайковые нейронные сети и методы их структурного и параметрического обучения, позволяет сделать вывод о том, что для существенного увеличения адаптивной способности таких сетей представляется необходимым рассматривать не только параметрическую, но и структурную адаптацию нейронных сетей, под которой будем понимать изменение топологии связей между узлами (нейронами) сети и усложнение модели каждого узла путем перехода к сегментным (компаратментным) моделям нейронов. По мнению авторов, это даст возможность более эффективно решать задачи классификации на основе СНС.

В качестве альтернативы традиционным стратегиям развития, регулирующим количество нейронов в процессе обучения и адаптирующим веса нейронов в динамическом режиме, в настоящей работе предлагается подход, предлагающий, помимо возможности динамического изменения структуры нейронной сети и связей между отдельными нейронами, использование структурной онлайн перестройки самой модели нейрона.

В настоящей работе рассматривается возможность решения задачи классификации с использованием СНС с сегментными

нейронами. Для этого предлагается специальный алгоритм структурной адаптации нейронов ко входным паттернам импульсов, а также общая схема организации таких нейронов в сеть для решения поставленной задачи. Работа алгоритмов демонстрируется как на общедоступных модельных наборах данных (*Iris*, *MNIST*), так и на реальных данных, полученных в ходе экспериментов на телеуправляемом необитаемом подводном аппарате.

Далее в разделах 2 и 3 представлена структурная схема модели нейрона, использовавшаяся при моделировании, описан принцип структурной адаптации спайковой сегментной модели нейрона. В разделе 4 представлена общая схема решения задачи классификации паттернов импульсов. Раздел 5 описывает способ перевода числовой информации в паттерны импульсов. В разделе 6 кратко приведены результаты экспериментов по решению задачи классификации на общедоступных наборах данных, тогда как в разделе 7 представлено подробное пошаговое описание экспериментов по решению задачи классификации на данных состояния телеуправляемого необитаемого подводного аппарата. В заключительном разделе 8 приведено обсуждение результатов работы.

**2. Сегментная спайковая модель нейрона с возможностью структурной адаптации.** На рисунке 1 представлена схема сегментной спайковой модели нейрона (CSNM – Compartmental Spiking Neuron Model) [20], использованная в ходе выполнения работы. Предполагается, что на вход поступают спайки, которые преобразуются в синапсах в выходную величину, отображающую влияние синаптического тока на сегмент мембраны нейрона.

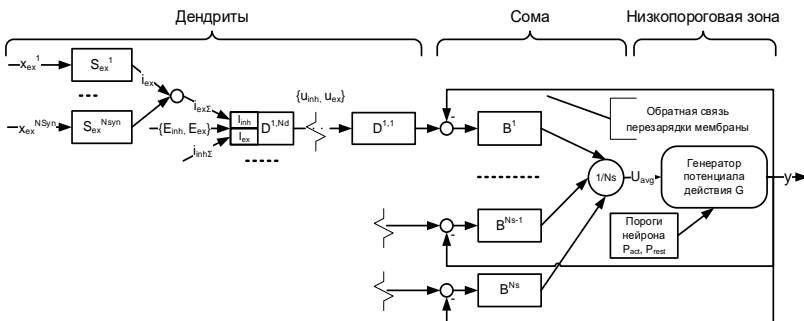


Рис. 1. Схема модели нейрона

Здесь  $B^1-B^{Ns}$  – участки мембраны, описывающие тело нейрона.  $D^{ij}$  – участки мембраны, описывающие  $i$ -й дендрит.  $S_{ex}^i$  – модели

синаптической передачи. Их суммарное влияние оказывает либо возбуждающее (через ионный канал  $I_{inh}$ ), либо тормозное (через ионный канал  $I_{ex}$ ) воздействие на соответствующий участок мембраны.

Полагаем, что нейроны обмениваются информацией через события (возникновение спайков), которые можно представить по формуле:

$$x_i = \begin{cases} 1, & t \in [t_i; t_i + \Delta t] \\ 0, & t \notin [t_i; t_i + \Delta t] \end{cases} \quad (1)$$

где  $x_i$  – выход нейрона в  $i$ -й интервал времени, а  $t$  – время.

Представленная структурная организация модели нейрона позволяет проводить расчет систем дифференциальных уравнений для каждого нейрона независимо, поскольку нейроны обмениваются исключительно информацией о моменте времени возникновения спайка, а входной вектор системы уравнений модели нейрона формируется внутри модели как функция от моментов времени прихода спайков.

Система в целом характеризуется набором из следующих гиперпараметров: размер нейрона  $N_s$  (число сегментов сомы), множество длин дендритов  $N_d$  и число возбуждающих и тормозных синапсов  $N_{syn}$  для каждого сегмента мембраны. Их значения определяют структуру системы, которая формирует требуемую реакцию нейрона на входные воздействия.

Настоящая статья не ставит своей задачей подробное математическое описание использовавшейся модели нейрона. Такое описание можно найти в работе [21].

**3. Постановка задачи.** Отметим возможности рассмотренной модели нейрона, играющие существенную роль при решении задачи её структурного обучения:

- создание произвольного числа сегментов тела нейрона, что означает возможность изменять размерность входного паттерна импульсов,

- независимое наращивание длин дендритов. Увеличение длины дендрита приводит к временной задержке сигнала и к уменьшению его амплитуды,

- добавление произвольного числа синапсов на произвольном участке мембраны (соме, дендрите). Добавление синапса приводит к увеличению амплитуды сигнала,

- произвольная организация связей (как возбуждающих, так и тормозных) между отдельными элементами.

Всё вышеперечисленное означает возможность структурного реконфигурирования модели нейрона, что, в свою очередь, позволяет изменять время прихода и амплитуду сигнала с каждого из дендритов на сому нейрона.

В рамках решения задачи структурной адаптации работа будет вестись с паттернами импульсов, под которыми будем понимать совокупность сигналов, поступающих на входы нейрона (дендриты) за некоторый промежуток времени. Отдельный входной сигнал представляет собой одиночный импульс единичной амплитуды. Соответственно отдельные сигналы в паттерне имеют одинаковую (единичную) амплитуду, но, в общем случае, различное время поступления на соответствующий вход (дендрит) нейрона. Считаем, что за определённый промежуток времени поступления паттерна, на отдельном входе (дендрите) может быть зафиксировано не более одного входного сигнала.

Результатом распознавания конкретного паттерна будем считать генерацию выходного сигнала нейроном. Выходной сигнал генерируется в низкопороговой зоне нейрона (генератор потенциала действия) и представляет собой импульсы единичной амплитуды, формируемые при превышении порога величиной мембранного потенциала. Само же значение потенциала внутри низкопороговой зоны нелинейно связано с суммой сигналов, пришедших на вход нейрона. Таким образом, для преодоления порога и генерации потенциала действия, необходимо максимизировать сумму вкладов в потенциал внутри низкопороговой зоны от всех дендритов, что может быть достигнуто синхронизацией действия входных сигналов в нейроне, т. е. одновременностью прихода всех импульсов паттерна на тело нейрона.

Как было показано выше, синхронизация может быть достигнута путём добавления в модель отдельных сегментов дендритов. Однако, это приводит к уменьшению амплитуды входного сигнала, приходящего на сому, на данном дендрите, что могло бы стать препятствием для выбора фиксированного, универсального для всех входных паттернов, порога генерации. Уменьшение сигнала компенсируется добавлением синапсов на конечный сегмент дендрита, что приводит к увеличению амплитуды входного сигнала на соме.

Процедуру наращивания длины дендрита будем называть синхронизацией, тогда как процедуру добавления синапсов – нормализацией (рисунок 2). Таким образом, нашей задачей является максимизация потенциала внутри низкопороговой зоны нейрона путём синхронизации и нормализации, с целью вызвать генерацию

потенциала действия. Процессы синхронизации и нормализации в рамках структурной адаптации к конкретному паттерну соответствуют обучению нейрона данному паттерну импульсов. Генерация потенциала действия при фиксированном паттерне импульсов и соответствующей ему конфигурации обученного нейрона является результатом распознавания данного паттерна импульсов.




Рис. 2. Структурная адаптация модели нейрона: синхронизация (а), нормализация (б)

Алгоритм расчёта структурной адаптации модели нейрона приведён на рисунке 3.

Результаты экспериментальных исследований структурной адаптации спайковой модели нейрона представлены в работе [22].

**4. Общая схема решения задачи классификации с использованием сегментной спайковой модели нейрона.** Важной особенностью обученного нейрона является его способность отвечать на паттерны импульсов до некоторого предела отличные, чем паттерн импульсов, которому данный нейрон обучался. Однако, время ответа нейрона на паттерн импульсов, отличный от паттерна импульсов, которому нейрон обучался, различается со временем ответа нейрона на паттерн импульсов, которому тот был обучен. В первом случае это время оказывается больше, т. е. чем ближе входной паттерн импульсов, к паттерну импульсов, которому обучен нейрон, тем быстрее происходит генерация выходного импульса в нейроне.

На рисунке 4 представлена общая структурная схема организации в сеть обученных нейронов, решающая поставленную задачу.

Пусть задачу классификации требуется решить для  $K$  различных классов. Результатом решения является отнесение тестового паттерна импульсов к одному из этих классов, либо не отнесение ни к одному из них.

На представленной схеме каждому классу соответствуют  $M$  нейронов ( $M$  – размер обучающей выборки для класса), каждый из которых обучен своему обучающему примеру (обучающему паттерну).

В результате предъявления тестового примера (тестового паттерна) всей системе, каждый из обученных нейронов производит сравнение своего обучающего паттерна с тестовым и, при превышении суммарным значением мембранного потенциала фиксированного порога, происходит генерация выходного импульса теми из нейронов, для которых указанный порог оказался превышен.

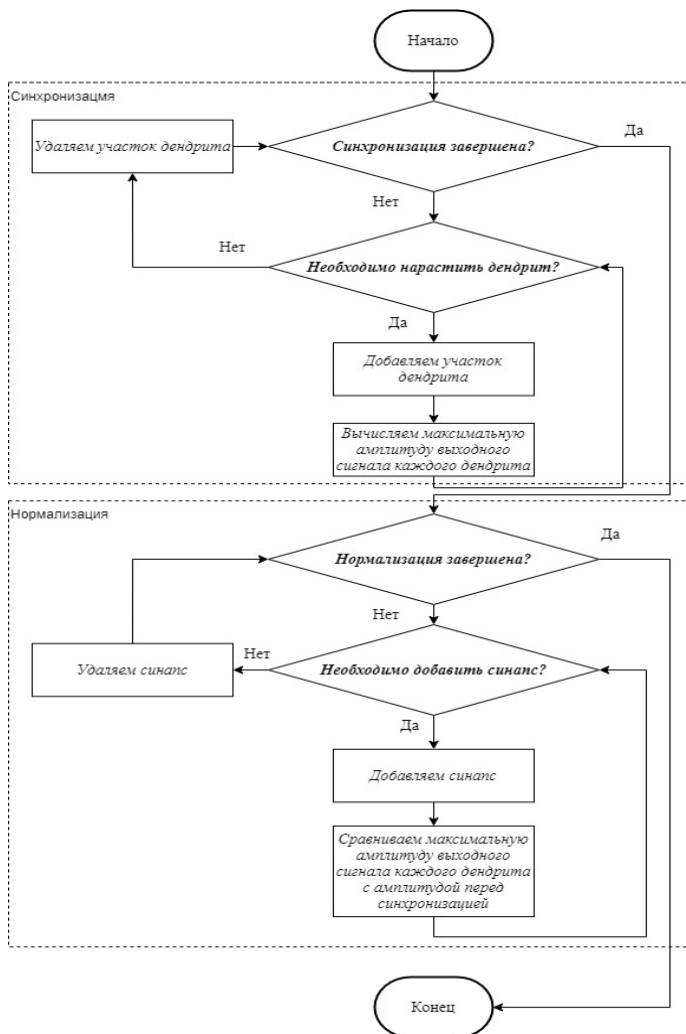


Рис. 3. Алгоритм расчёта структурной адаптации модели нейрона



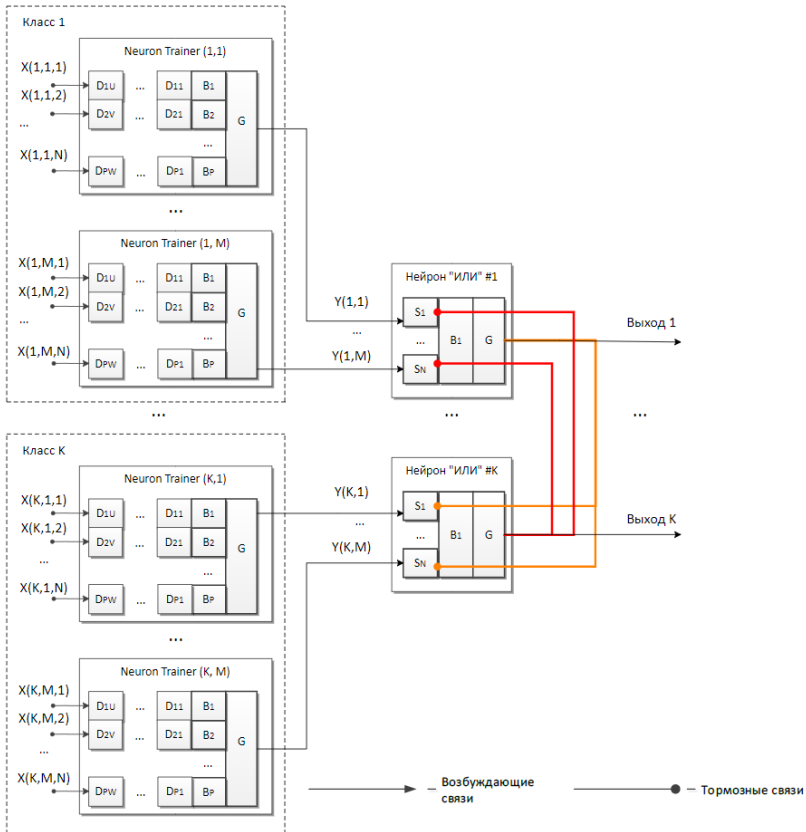


Рис. 4. Общая схема решения задачи классификации паттернов импульсов

Выходы нейронов, принадлежащих одному классу, поступают в качестве входов на соответствующий данному классу нейрон, реализующий функцию логического «ИЛИ». Логический элемент «ИЛИ» подразумевает наличие нескольких входов, при этом активность лишь одного из входов элемента приводит к активности его единственного выхода (рисунок 5).

На рисунке 5  $G$  – генератор потенциала действия,  $B^1$  – сегмент сомы нейрона,  $S^n$  –  $n$ -й синапс сомы нейрона.




Рис. 5. Структурная схема нейрона, реализующего логическую функцию «ИЛИ»

Нейрон, реализующий функцию логического «ИЛИ» имеет лишь один элемент сомы, на котором располагаются возбуждающие синапсы в количестве, равном размерности входного паттерна. Каждый отдельный сигнал паттерна поступает на соответствующий ему возбуждающий синапс. Таким образом, активность лишь одного из входов нейрона позволяет модели генерировать выходной сигнал.

Как указывалось ранее, быстрее выходной импульс генерируют те из нейронов, для которых их обучающий паттерн оказался ближе к тестовому. Таким образом, естественным решением является организация тормозных связей от каждого из нейронов «ИЛИ» ко всем остальным, т. е. нейрон, чей обучающий паттерн оказался ближе к тестовому («нейрон-победитель»), успевает затормозить все остальные нейроны. На рисунке 4 тормозные связи от первого нейрона «ИЛИ» к  $K$ -ому обозначены оранжевым цветом, а от  $K$ -ого к первому – красным. Реакция соответствующего нейрона «ИЛИ» и означает отнесение тестового паттерна к соответствующему классу.

Стоит отметить и возможность генерации выходных спайков несколькими нейронами «ИЛИ», если сигналы поступили на их входы в пределах одного расчётного интервала времени. Таким образом, сформулируем три варианта ответа схемы на рисунке 4 на предъявление ей тестового паттерна:

- нейрон, отклик с которого пришёл первым, успевает затормозить все остальные нейроны, в результате активизируется выход лишь с одного нейрона «ИЛИ». Такое распознавание будем называть «уверенным»,

- на входной паттерн два или более нейрона реагируют одновременно, в результате активизируются выходы с двух или нескольких нейронов «ИЛИ». Такое распознавание будем называть «неуверенным»,

– в результате поступления на вход нейронов тестового паттерна активации выходов нейронов «ИЛИ» не происходит. Такую ситуацию будем называть «отсутствием распознавания».

**5. Кодирование числовых данных.** Перед подачей входных данных в сеть необходимо закодировать числовые признаки в значения временных задержек. Согласно [23], использовавшийся метод кодирования можно определить, как «time-to-first-spike», или, другими словами, временное кодирование.

Определим входной набор данных как:

$$X = \{(x_1^1; x_2^1; \dots; x_N^1; y^1), (x_1^2; x_2^2; \dots; x_N^2; y^2), \dots, (x_1^M; x_2^M; \dots; x_N^M; y^M)\}, \quad (2)$$

где  $M$  – общий размер входных данных, а  $N$  – размерность пространства признаков.

Согласно [24] задержку  $d_n^m$   $n$ -ого признака  $m$ -ого примера входных данных  $X$  можно вычислить по формуле (3).

$$d_n^m = \frac{x_n^m - x_{min}^n}{x_{max}^n - x_{min}^n} \cdot T, \quad (3)$$

где  $x_{min}^n$  – минимальное значение  $n$ -ого признака по всему набору данных,  $x_{max}^n$  – максимальное значение  $n$ -ого признака по всему набору данных, а  $T$  – ширина временного окна.

Можно заметить, что кодирование данных в данном случае является простой линейной нормализацией с заданным диапазоном.

Очевидно, что в процессе распознавания паттерна импульсов значимыми являются лишь относительные смещения отдельных спайков в паттерне, смещение всего паттерна по временной шкале никак не сказывается на результате распознавания. Поскольку в рассматриваемых ниже задачах, помимо относительных, значимы и абсолютные величины времени спайков, необходимо привязать паттерн импульсов к некоторому абсолютному значению. Для решения этой задачи в модель вводился дополнительный – калибровочный – дендрит. Значение временной задержки на таком дендрите всегда принимает максимальное значение, т. е. равное ширине временного окна. Таким образом, при добавлении калибровочного дендрита во входной вектор, размерность пространства признаков становится равной  $N+1$ .

**6. Эксперименты по решению задачи классификации на общедоступных наборах данных.** Для проведения исследований

разработанной схемы для решения задачи классификации (рисунок 4) необходимы общедоступные наборы данных, применимые в данной области. Наиболее популярными наборами реальных данных являются *Iris* и MNIST.

Набор данных *Iris* [25] представляет собой описание цветков (по 50 измерений) трех типов. Для каждого цветка измерены четыре величины, которые выступают в качестве признаков. Набор данных *Iris* широко используется в машинном обучении в связи с небольшим размером и двумя линейно неразделимыми классами. Подробно результаты работы с базой данных *Iris* с использованием предложенной на рисунке 4 схемы описаны авторами в [26]. При обучении лишь по одному примеру на класс авторам удалось достичь результатов, сопоставимых с существующими на данный момент решениями.

База данных MNIST [27] – объёмная база данных образцов рукописного написания цифр является стандартом для исследований методов распознавания изображений с помощью машинного обучения в первую очередь на основе нейронных сетей. База данных состоит из 60000 изображений в оттенках серого размером 28 x 28, состоящих из 10 цифр, а также тестового набора из 10000 изображений. Цифры нормализованы по размеру и центрированы. В данном наборе каждое изображение представлено массивом чисел от 0 до 255, что соответствует интенсивностям пикселей, расположенных построчно. Исходными признаками можно считать интенсивности каждого пикселя, т. е. размер исходного пространства признаков равен 784.

Помимо решения самой задачи классификации, работа с базой данных MNIST предполагала значительный объём исследований, связанный с понижением размерности пространства признаков, где авторами к настоящему моменту получены оригинальные решения (в результате размерность признаков удалось снизить до значения два). Тем не менее, работа в этом направлении в настоящий момент всё ещё продолжается, поэтому здесь приведём лишь предварительный результат.

В качестве обучающей выборки в экспериментах с базой данных MNIST было использовано лишь по одному обучающему примеру для каждого из десяти классов (в противовес 6000 обучающих примеров на класс, используемых при стандартных экспериментах с MNIST). Результаты сведены в таблице 1.

Из таблицы 1 видно, что результаты предложенной сети сопоставимы с результатами, полученными на стандартных классификаторах.

Таблица 1. Результаты стандартных классификаторов на наборе данных MNIST в сравнении с предложенным методом, полученные на одних и тех же исходных данных

Метод	Средняя точность классификации, %
Перцептрон	36,8 ± 7,5
Логистическая регрессия	66,9
kNN	77
Random Forest	52,4 ± 2,8
Support Vector Machine	77,3
MPL	81,1 ± 0,4
<b>Предложенная сеть</b>	<b>68,7</b>

**7. Эксперименты по решению задачи классификации на данных состояния телеуправляемого необитаемого подводного аппарата.** В разделе 6 были представлены экспериментальные результаты, полученные в ходе решения модельных задач с использованием стандартных наборов входных данных. Далее представлены результаты экспериментов, полученные на реальных входных данных в ходе натурных испытаний телеуправляемого необитаемого подводного аппарата (ТНПА) [28, 29].

Актуальной задачей при управлении ТНПА является оценка состояния такого аппарата до дна. Одним из решений данной задачи может быть использование эхолота в составе доплеровского лага. Однако, точность измерения не всегда соответствует требуемой, а ошибки измерения зачастую носят критический характер.

В рамках настоящей работы был произведён эксперимент по решению данной задачи с использованием сегментной СНС. В качестве входных данных для обучения и классификации использовались гистограммы распределения яркостей пикселей видеокadres, полученных с видеокамеры, установленной на ТНПА. При приближении ТНПА ко дну, происходит постепенное изменение гистограммы изображения дна за счёт увеличения эффекта отражения от дна света от установленного на ТНПА прожектора (рисунок 6).



Рис. 6. Кадры с изображением дна, полученные с видеокамеры, установленной на ТНПА, на расстоянии: а) 7 метров; б) 2 метра; в) 0,5 метров

Характер изменения гистограммы продемонстрирован на рисунке 7.



Рис. 7. Характер изменения гистограммы при приближении ТНПА ко дну

На рисунке 7 по оси абсцисс отложена яркость пикселей на изображениях, по оси ординат – количество пикселей. Для построения гистограммы весь диапазон яркости (0–255) разбивался на восемь равных отрезков. Из рисунка 7 легко можно заметить, что правая часть гистограммы не является значимой с точки зрения классификации положения ТНПА по глубине. Исходя из этого три правых столбца гистограммы не учитывались в дальнейшем процессе обучения и классификации.

В рассматриваемом эксперименте оставшиеся пять столбцов гистограммы использовались в качестве признаков (и один калибровочный), тогда как число классов было выбрано равным трём. Для каждого класса использовался лишь один обучающий пример. Соответствующие обучающим примерам изображения проиллюстрированы на рисунке 6.

Создание моделей СНС с возможностью структурного реконфигурирования как самой сети, так и её элементов, подразумевает необходимость обеспечить возможность описывать системы, в которых заранее не определена топология связей между элементами системы и их структурное описание. Для этой цели была разработана специальная программная среда NMSDK, описанная в [30]. В указанной программной среде была построена схема

классификации, позволявшая относить входной кадр к одному из трёх классов: «0,5», «2,0» и «7,0» (рисунок 8).

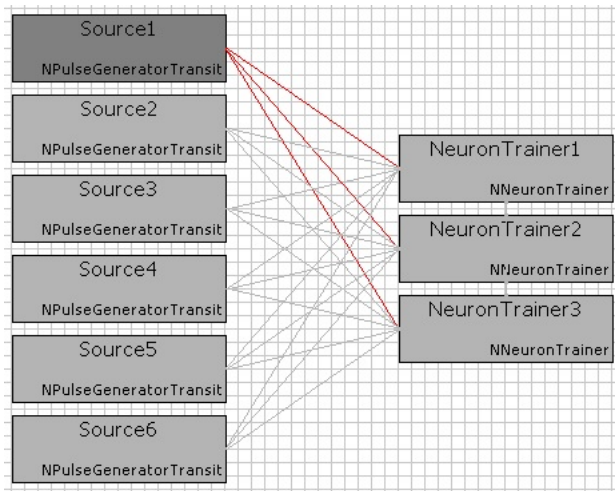


Рис. 8. Схема классификации кадров по расстоянию ТНПА от дна в среде NMSDK

На рисунке 8 справа показаны нейроны CSNM: «NeuronTrainer1» – для класса «0,5»; «NeuronTrainer2» – для класса «2,0», а «NeuronTrainer3» – для класса «7,0». «Source1» – I-й генератор импульсов, причём все блоки «Source» в совокупности задают требуемый паттерн импульсов.

В соответствии с методом кодирования, описанным в разделе 5, изображённым на рисунок 7 кривым соответствуют задержки спайков (в секундах), представленные на рисунке 9.

"0,5"	0,156	0,341	0,228	0,182	0,089	0,002	0	0
"2,0"	0,009	0,484	0,351	0,154	0	0	0	0
"7,0"	0	0,292	0,658	0,047	0,001	0	0	0

Рис. 9. Величины задержки спайков для обучающих примеров по трём классам (в секундах)

Как упоминалось ранее, три правых столбца таблицы на рисунке 9 не являются значимыми с точки зрения классификации положения ТНПА по глубине. Исходя из этого, нейроны с возможностью структурной адаптации обучались паттернам импульсов, сформированным спайками с задержками, приведёнными в

первых пяти столбцах таблицы на рисунке 9. Шестой дендрит являлся калибровочным (раздел 5), задержка на котором принимала постоянное значение, равное 0,2 секунды (принятой ширине временного окна). Структуры обученных нейронов, приведённые на рисунках 10-12, получены в среде моделирования NMSDK. Изменяемая часть в левых сторонах рисунков показывает количество дендритов, добавленных в ходе структурной адаптации.

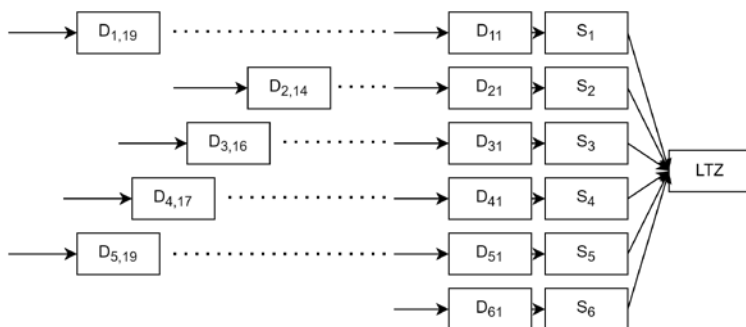


Рис. 10. Структура нейрона, отвечающего классу  $\langle 0,5 \rangle$ , после обучения

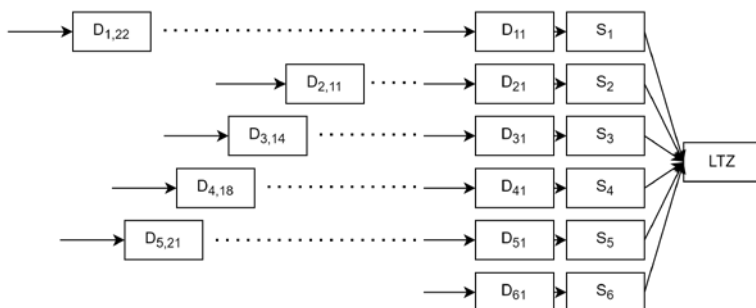


Рис. 11. Структура нейрона, отвечающего классу  $\langle 2,0 \rangle$ , после обучения



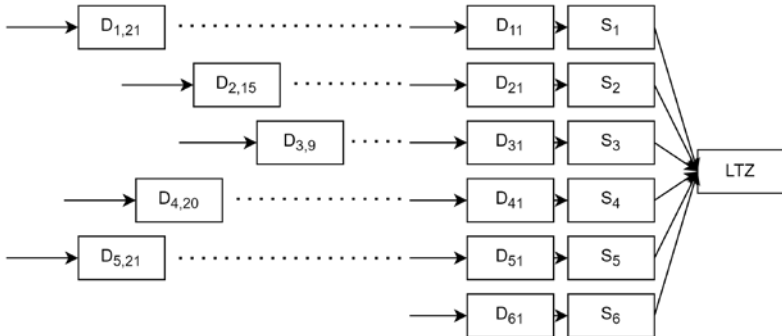


Рис. 12. Структура нейрона, отвечающего классу «7,0», после обучения

На рисунках 10-12 обозначены:  $LTZ$  – низкопороговая зона нейрона;  $S_i$  –  $i$ -й сегмент тела нейрона (сомы);  $D_{ij}$  –  $j$ -й сегмент  $i$ -го дендрита нейрона.

После процедуры обучения на вход системы подавалась последовательность из сорока восьми кадров, соответствующая процессу погружения ТНПА с высоты семи метров до дна. Результаты расчёта продемонстрированы на рисунке 13.




Рис. 13. Результаты расчёта процесса погружения ТНПА

На рисунке 13 по оси абсцисс отложены номера измерений, серым обозначены точки, соответствующие классу «0,5»; оранжевым –

классу «2,0»; синим – классу «7,0». Шкала А показывает номера отвечающих нейронов. Нулевое значение на шкале А иллюстрирует отсутствие отклика соответствующего обученного нейрона. Ответ нейрона, обученного примеру из класса «0,5» обозначен значением «1»; нейрона, обученного примеру из класса «2,0» – значением «2»; нейрона, обученного примеру из класса «7,0» – значением «3».

Из рисунка 13 видно, что характер отклика нейронов соответствует характеру движения ТНПА (погружение). На кадрах 38 и 39 можно видеть отклик сразу двух нейронов: нейрона, соответствующего классу «0,5», и нейрона, соответствующего классу «2,0». Это соответствует промежуточному положению ТНПА между точками с расстоянием 0,5 и 2 метра от дна, т. е. примерно одному метру. Такой одновременный отклик нейронов был определен в разделе 4 как «неуверенное» распознавание.

Следующий эксперимент был посвящён определению характера движения ТНПА. В ходе эксперимента ТНПА совершал движение по прямоугольной траектории на одной глубине (маневр «коробочка») (рисунок 14).




Рис. 14. Траектория движения ТНПА в ходе маневра «коробочка»

Данная траектория обеспечивалась работой двух из десяти движителей ТНПА (рисунки 15 и 16).




Рис. 15. Изменение скорости вращения правого движителя ТНПА в ходе эксперимента




Рис. 16. Изменение скорости вращения левого движителя ТНПА в ходе эксперимента

На графиках, на рисунках 15 и 16, показаны скорости вращения правого и левого движителей ТНПА (в радианах в минуту с учётом направления вращения) во времени (в тактах измерения) в ходе эксперимента.

В рассматриваемом эксперименте показания датчиков левого и правого движителей использовались в качестве признаков, тогда как число классов было выбрано равным трём. Для каждого класса использовался лишь один обучающий пример, причём примеры для обучения выбирались случайным образом.

Исходя из сказанного выше и разработанных методов классификации с использованием сегментных СНС (раздел 4), была построена схема классификации, позволяющая относить входной кадр к одному из трёх классов: «направо», «налево» и «прямо» (рисунок 17).

На рисунке 17 справа показаны нейроны CSNM: «NeuronTrainer1» – для класса «налево»; «NeuronTrainer2» – для класса «направо», а «NeuronTrainer3» – для класса «прямо». «Source1» – I-й генератор импульсов, причём все блоки «Source» в совокупности задают требуемый паттерн импульсов.




Рис. 17. Схема классификации кадров по характеру движения ТНПА в среде NMSDK

В соответствии с методом кодирования, описанным в разделе 5, выбранным в качестве обучающих примеров тактам измерения соответствуют следующие задержки спайков (в секундах):

Класс	M_Right	M_Left	1	2	3
«направо»	29,2276	-54,344	0,117406	0,009317	0,2
«налево»	63,4238	-18,2747	0,189838	0,107025	0,2
«прямо»	39,867	-43,7107	0,139942	0,038121	0,2

Рис. 18. Исходные данные (слева) и величины задержки спайков для обучающих примеров по трём классам в секундах (справа)

Нейроны (рисунок 17) обучались паттернам импульсов, сформированными спайками с задержками, приведёнными в таблице на рисунке 18. Третий дендрит являлся калибровочным (раздел 5), задержка на котором принимала постоянное значение, равное 0,2 секунды (принятой ширине временного окна). Структуры обученных нейронов, приведённые на рисунках 19–21, получены в среде моделирования NMSDK. Изменяемая часть в левых сторонах рисунков показывает количество дендритов, добавленных в ходе структурной адаптации.




Рис. 19. Структура нейрона, отвечающего классу «направо», после обучения




Рис. 20. Структура нейрона, отвечающего классу «налево», после обучения




Рис. 21. Структура нейрона, отвечающего классу «прямо», после обучения

После процедуры обучения на вход системы подавалась последовательность из 42851 записей значений скоростей вращения правого и левого движителей ТНПА. Результаты расчёта продемонстрированы на рисунке 22.




Рис. 22. Результаты расчёта процесса движения ТНПА в ходе маневра «коробочка»

На рисунке 22 по оси абсцисс отложены номера измерений, по оси ординат – угол курса движения ТНПА в радианах, синим цветом обозначены точки, соответствующие классу «направо»; оранжевым – классу «налево»; серым – классу «прямо». Жёлтые точки показывают угол курса движения ТНПА в радианах. Нулевое значение иллюстрирует отсутствие отклика соответствующего обученного нейрона. Ответ нейрона, обученного примеру из класса «направо» обозначен значением «7»; нейрона, обученного примеру из класса «налево» – значением «8»; нейрона, обученного примеру из класса «прямо» – значением «9».

Из рисунка 22 видно, что характер отклика нейронов соответствует характеру движения ТНПА.

Следует подчеркнуть, что во всех приведённых в разделах 6 и 7 экспериментах размер обучающей выборки составлял лишь один пример на класс. Эксперименты на тех же самых входных данных с использованием классических методов результатов не дали. Для получения результатов классическими методами необходимо увеличить размер обучающей выборки.

**8. Заключение.** Анализ существующих архитектур спайковых нейронных сетей показал, что для большинства спайковых нейронных сетей создана традиционная стратегия развития, которая изменяет их структуру путем регулирования количества нейронов в процессе обучения, а также в динамическом режиме адаптирует сеть под задачу, настраивая веса нейронов в реальном времени. По мнению авторов, адаптивная способность спайковой нейронной сети может быть увеличена, если использовать модели нейронов с изменяемой структурой дендритного дерева и синаптического аппарата.

Использование наряду с настройкой параметров нейронов и структуры нейронной сети, дополнительной возможности настройки внутренней структуры самих нейронов, по мнению авторов этой работы, может значительно повысить эффективность реализации поведенческих функций в нейроморфных системах управления.

Представленные в работе алгоритмы структурной адаптации для решения задач распознавания паттернов импульсов, были протестированы на решении задачи классификации. Опираясь на рассмотренные примеры, область применимости разработанной системы можно отнести к решению задач диагностики. По мнению авторов, основной областью применимости могли бы стать задачи с низкой доступностью обучающей выборки, высокой сложностью оценки состояния системы оператором, или даже с отсутствием возможности такой оценки, и с крайне высокими последствиями ошибки, например – задачи аварийной диагностики сложных систем.

По мнению авторов, полученные результаты показывают эффективность разработанных нейроморфных средств при решении задач классификации. Намечены пути продолжения этих исследований, направленные на разработку нейрологических реализаций спайковых нейронных сетей и переход к их аппаратной реализации.

### **Литература**

1. Prieto A. et al. Neural networks: An overview of early research, current frameworks and new challenges // *Neurocomputing*. 2016. vol. 214. pp. 242–268.
2. Haykin S.S. Neural networks and learning machines // Harlow: Pearson Education. 2009. 934 p.
3. Walter F., Röhrbein F., Knoll A. Computation by time // *Neural Processing Letters*. 2016. vol. 44. no. 1. pp. 103–124.
4. Gerstner W., Kistler W.M. Spiking neuron models: Single neurons, populations, plasticity // Cambridge: Cambridge University Press. 2002. 496 p.
5. Izhikevich E.M. Which model to use for cortical spiking neurons // *IEEE Transactions on Neural Networks*. 2003. vol. 14. pp. 1569–1572.
6. Lin X., Zhang T. Dynamical properties of piecewise linear spiking neuron model // *Tien Tzu Hsueh Pao/Acta Electronica Sinica*. 2009. vol. 37. no. 6. pp. 1270–1276.
7. Ghosh-Dastidar S., Adeli H. Spiking neural networks // *International Journal of Neural Systems*. 2009. vol. 19. no. 4. pp. 295–308.
8. Maass W. Lower bounds for the computational power of networks of spiking neurons // *Neural computation*. 1996. vol. 8. no. 1. pp. 1–40.
9. Kulkarni S.R., Rajendran B. Spiking neural networks for handwritten digit recognition—Supervised learning and network optimization // *Neural Networks*. 2018. vol. 103. pp. 118–127.
10. Almási A.D. et al. Review of advances in neural networks: Neural design technology stack // *Neurocomputing*. 2016. vol. 174. pp. 31–41.
11. Denève S., Alemi A., Bourdoukan R. The brain as an efficient and robust adaptive learner // *Neuron*. 2017. vol. 94. no. 5. pp. 969–977.

12. Glaser J.I. et al. The roles of supervised machine learning in systems neuroscience // *Progress in neurobiology*. 2019. vol. 175. pp. 126–137.
13. Rummelhart, D.E. Learning representations by back-propagating errors // *Nature*. 1986. vol. 323. no. 9. pp. 533–536.
14. Lin X. et al. Supervised learning algorithms for spiking neural networks: a review // *Acta electronica sinica*. 2015. vol. 43. no. 3. pp. 577.
15. Wang X., Lin X., Dang X. Supervised learning in spiking neural networks: A review of algorithms and evaluations // *Neural Networks*. 2020. vol. 125. pp. 258–280.
16. Lobo J.L. et al. Spiking neural networks and online learning: An overview and perspectives // *Neural Networks*. 2020. vol. 121. pp. 88–100.
17. Kasabov N. et al. Dynamic evolving spiking neural networks for on-line spatio-and spectro-temporal pattern recognition // *Neural Networks*. 2013. vol. 41. pp. 188–201.
18. Kasabov N. *Time-Space, Spiking Neural Networks and Brain-Inspired Artificial Intelligence* // Berlin: Springer-Nature. 2018. 738 p.
19. Khan G.M., Miller J.F. In search of intelligence: evolving a develop-mental neuron capable of learning // *Connection Science*. 2014. vol. 26. no. 4. pp. 297–333.
20. Bakhshiev A.V., Gundelakh F.V. Mathematical Model of the Impulses Transformation Processes in Natural Neurons for Biologically Inspired Control Systems Development // *CEUR Workshop Proceedings*. 2015. vol. 1452. pp. 1–12.
21. Bakhshiev A., Demcheva A., Stankevich L. CSNM: The Compartmental Spiking Neuron Model for Developing Neuromorphic Information Processing Systems // *International Conference on Neuroinformatics*. 2021. pp. 327–333.
22. Бахшиев А.В., Корсаков А.М., Астапова Л.А., Станкевич Л.А. Структурная адаптация сегментной спайковой модели нейрона // *Нелинейная динамика в когнитивных исследованиях - 2021 : Труды VII Всероссийской конференции, Нижний Новгород, 20–24 сентября 2021 года*. 2021. С. 30–33.
23. Park S. et al. T2FSNN: deep spiking neural networks with time-to-first-spike coding // *2020 57th ACM/IEEE Design Automation Conference (DAC)*. 2020. pp. 1–6.
24. Lin P. et al. SpikeCD: a parameter-insensitive spiking neural network with clustering degeneracy strategy // *Neural Computing and Applications*. 2019. vol. 31. no. 8. pp. 3933–3945.
25. UCI Machine Learning Repository: Iris Data Set [Electronic resource]. URL: <https://archive.ics.uci.edu/ml/datasets/iris> (дата обращения: 22.04.2021).
26. Astopova L. A. et al. Compartmental spiking neuron model for pattern classification // *Journal of Physics: Conference Series*. 2021. vol. 2094. no. 3. pp. 032032.
27. MNIST handwritten digit database, Yann LeCun, Corinna Cortes and Chris Burges [Electronic resource]. URL: <http://yann.lecun.com/exdb/mnist/> (дата обращения: 12.10.2021).
28. Щур Н.А., Половко С.А., Деулин А.А. Применение методов вычислительной гидродинамики для получения характеристик переходных процессов АНПА // *Робототехника и техническая кибернетика*. 2020. Т. 8. №4. С. 287–295.
29. Горюнов В.В., Половко С.А., Щур Н.А. Разработка схемотехнического решения и конструкции емкостной матрицы датчиков давления для применения в робототехнике // *Робототехника и техническая кибернетика*. 2020. Т. 8. №4. С. 308–318.
30. Bakhshiev A.V. et al. The architecture of a software platform for growing spiking neural networks simulator developing // *Journal of Physics: Conference Series*. 2020. vol. 1679. no. 4. pp. 042001.

**Корсаков Антон Михайлович** — старший научный сотрудник, лаборатория «технологий искусственного интеллекта», Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ



РТК). Область научных интересов: нейроморфные системы и спайковые нейронные сети, математические основы управления робототехническими системами, системы технического зрения. Число научных публикаций — 34. anton\_korsakov@mail.ru; Тихорецкий проспект, 21, 194064, Санкт-Петербург, Россия; р.т.: +7(911)784-2747.

**Астапова Любовь Алексеевна** — инженер-программист, Санкт-Петербургский политехнический университет Петра Великого (СПбПУ). Область научных интересов: нейроморфные системы и спайковые нейронные сети, математические основы управления робототехническими системами, системы технического зрения. Число научных публикаций — 8. astapova.la@yandex.ru; улица Политехническая, 29, 195251, Колпино, Россия; р.т.: +7(981)785-2931.

**Бахшиев Александр Валерьевич** — канд. техн. наук, доцент, Санкт-Петербургский политехнический университет Петра Великого (СПбПУ). Область научных интересов: применение методов искусственного интеллекта в решении задач технического зрения, развитие биологически-инспирированных подходов к созданию систем управления и обработки информации, разработка новых архитектур спайковых нейронных сетей. Число научных публикаций — 108. palexab@gmail.com; Политехническая улица, 29, 195251, Санкт-Петербург, Россия; р.т.: +7(921)748-0010.

**Поддержка исследований.** Работа проводилась в рамках выполнения государственного задания Минобрнауки России № 075-01623-22-00 «Исследование и разработка биоподобной системы управления поведением мобильных роботов на базе энергоэффективных программно-аппаратных нейроморфных средств».

A. KORSAKOV, L. ASTAPOVA, A. BAKHSHEV  
**APPLICATION OF A COMPARTMENTAL SPIKING NEURON  
MODEL WITH STRUCTURAL ADAPTATION FOR SOLVING  
CLASSIFICATION PROBLEMS**

*Korsakov A., Astapova L., Bakhshiev A. Application of a Compartmental Spiking Neuron Model with Structural Adaptation for Solving Classification Problems.*

**Abstract.** The problem of classification using a compartmental spiking neuron model is considered. The state of the art of spiking neural networks analysis is carried out. It is concluded that there are very few works on the study of compartmental neuron models. The choice of a compartmental spiking model is justified as a neuron model for this work. A brief description of such a model is given, and its main features are noted in terms of the possibility of its structural reconfiguration. The method of structural adaptation of the model to the input spike pattern is described. The general scheme of the compartmental spiking neurons' organization into a network for solving the classification problem is given. The time-to-first-spike method is chosen for encoding numerical information into spike patterns, and a formula is given for calculating the delays of individual signals in the spike pattern when encoding information. Brief results of experiments on solving the classification problem on publicly available data sets (Iris, MNIST) are presented. The conclusion is made about the comparability of the obtained results with the existing classical methods. In addition, a detailed step-by-step description of experiments to determine the state of an autonomous uninhabited underwater vehicle is provided. Estimates of computational costs for solving the classification problem using a compartmental spiking neuron model are given. The conclusion is made about the prospects of using spiking compartmental models of a neuron to increase the bioplausibility of the implementation of behavioral functions in neuromorphic control systems. Further promising directions for the development of neuromorphic systems based on the compartmental spiking neuron model are considered.

**Keywords:** neuromorphic systems, spiking neuron, spiking neural networks, classification task, autonomous underwater vehicle.

**Korsakov Anton** — Senior researcher, Laboratory of artificial intelligence technologies, Russian state scientific center for robotics and technical cybernetics (RTC). Research interests: neuromorphic systems and spike neural networks, mathematical foundations of robotic systems control, computer vision. The number of publications — 34. anton\_korsakov@mail.ru; 21, Tikhoretsky Av., 194064, St. Petersburg, Russia; office phone: +7(911)784-2747.

**Astapova Lyubov** — Software engineer, Peter the Great St.Petersburg Polytechnic University (SPbPU). Research interests: neuromorphic systems and spike neural networks, mathematical foundations of robotic systems control, computer vision. The number of publications — 8. astapova.la@yandex.ru; 29, Polytechnic St., 195251, Kolpino, Russia; office phone: +7(981)785-2931.

**Bakhshiev Aleksandr** — Ph.D., Associate professor, Peter the Great St.Petersburg Polytechnic University (SPbPU). Research interests: application of artificial intelligence methods in solving computer vision problems, development of biologically inspired approaches to the creation of information management and processing systems, development of new spike neural network architectures. The number of publications — 108.

palexab@gmail.com; 29, Polytechnic St., 195251, St. Petersburg, Russia; office phone: +7(921)748-0010.

**Acknowledgements.** This work was done as a part of the state task of the Ministry of Education and Science of Russia No. 075-01623-22-00 «Research and development of a biosimilar system for controlling the behavior of mobile robots based on energy-efficient software and hardware neuromorphic tools».

## References

1. Prieto A. et al. Neural networks: An overview of early research, current frame-works and new challenges. *Neurocomputing*. 2016. vol. 214. pp. 242–268.
2. Haykin S.S. *Neural networks and learning machines*. Pearson Education. 2009. 934 p.
3. Walter F., Röhrbein F., Knoll A. Computation by time. *Neural Processing Letters*. 2016. vol. 44. no. 1. pp. 103–124.
4. Gerstner W., Kistler W.M. *Spiking neuron models: Single neurons, populations, plasticity*. Cambridge University Press. 2002. 496 p.
5. Izhikevich E.M. Which model to use for cortical spiking neurons. *IEEE Transactions on Neural Networks*. 2003. vol. 14. pp. 1569–1572.
6. Lin X., Zhang T. Dynamical properties of piecewise linear spiking neuron model. *Tien Tzu Hsueh Pao/Acta Electronica Sinica*. 2009. vol. 37. no. 6. pp. 1270–1276.
7. Ghosh-Dastidar S., Adeli H. Spiking neural networks. *International Journal of Neural Systems*. 2009. vol. 19. no. 4. pp. 295–308.
8. Maass W. Lower bounds for the computational power of networks of spiking neurons. *Neural computation*. 1996. vol. 8. no. 1. pp. 1–40.
9. Kulkarni S.R., Rajendran B. Spiking neural networks for handwritten digit recognition — Supervised learning and network optimization. *Neural Networks*. 2018. vol. 103. pp. 118–127.
10. Almási A.D. et al. Review of advances in neural networks: Neural design technology stack. *Neurocomputing*. 2016. vol. 174. pp. 31–41.
11. Denève S., Alemi A., Bourdoukan R. The brain as an efficient and robust adaptive learner. *Neuron*. 2017. vol. 94. no. 5. pp. 969–977.
12. Glaser J.I. et al. The roles of supervised machine learning in systems neuroscience. *Progress in neurobiology*. 2019. vol. 175. pp. 126–137.
13. Rummelhart, D.E. Learning representations by back-propagating errors. *Nature*. 1986. vol. 323. no. 9. pp. 533–536.
14. Lin X. et al. Supervised learning algorithms for spiking neural networks: a review. *Acta electronica sinica*. 2015. vol. 43. no. 3. pp. 577.
15. Wang X., Lin X., Dang X. Supervised learning in spiking neural networks: A review of algorithms and evaluations. *Neural Networks*. 2020. vol. 125. pp. 258–280.
16. Lobo J.L. et al. Spiking neural networks and online learning: An overview and perspectives. *Neural Networks*. 2020. vol. 121. pp. 88–100.
17. Kasabov N. et al. Dynamic evolving spiking neural networks for on-line spatio-and spectro-temporal pattern recognition. *Neural Networks*. 2013. vol. 41. pp. 188–201.
18. Kasabov N. *Time-Space, Spiking Neural Networks and Brain-Inspired Artificial Intelligence*. Springer-Nature. 2018. 738 p.
19. Khan G.M., Miller J.F. In search of intelligence: evolving a developmental neuron capable of learning. *Connection Science*. 2014. vol. 26. no. 4. pp. 297–333.
20. Bakhshiev A.V., Gundelakh F.V. Mathematical Model of the Impulses Transformation Processes in Natural Neurons for Biologically Inspired Control Systems Development. *CEUR Workshop Proceedings*. 2015. vol. 1452. pp. 1–12.

21. Bakhshiev A., Demcheva A., Stankevich L. CSNM: The Compartmental Spiking Neuron Model for Developing Neuromorphic Information Processing Systems. International Conference on Neuroinformatics. 2021. pp. 327–333.
22. Bakhshiev A.V. et al. Strukturnaja adaptacija segmentnoj spajkovoju modeli nejrona. Nelinejnaja dinamika v kognitivnyh issledovanijah - 2021 : Trudy VII Vserossijskoj konferencii, Nizhnij Novgorod, 20–24 sentjabrja 2021 goda. 2021. pp. 30–33. (In Russ.).
23. Park S. et al. T2FSNN: deep spiking neural networks with time-to-first-spike coding. 2020 57th ACM/IEEE Design Automation Conference (DAC). 2020. pp. 1–6.
24. Lin P. et al. SpikeCD: a parameter-insensitive spiking neural network with clustering degeneracy strategy. Neural Computing and Applications. 2019. vol. 31. no. 8. pp. 3933–3945.
25. UCI Machine Learning Repository: Iris Data Set [Electronic resource]. URL: <https://archive.ics.uci.edu/ml/datasets/iris> (accessed: 22.04.2021).
26. Astapova L. A. et al. Compartmental spiking neuron model for pattern classification. Journal of Physics: Conference Series. 2021. vol. 2094. no. 3. pp. 032032.
27. MNIST handwritten digit database, Yann LeCun, Corinna Cortes and Chris Burges [Electronic resource]. URL: <http://yann.lecun.com/exdb/mnist/> (accessed: 12.10.2021).
28. Tschur N., Polovko S., Deulin A. Application of the computational fluid dynamics methods to obtain the characteristics of AUV transient responses. Robotics and Technical Cybernetics. 2020. vol. 8. no. 4. pp. 287-295. (In Russ.).
29. Goryunov V., Polovko S., Tschur N. echnology of cybernetic models' creating for the synthesis and refinement of autonomous underwater vehicle motion control system controllers. Robotics and Technical Cybernetics. 2020. vol. 8. no. 4. pp. 308-318. (In Russ.).
30. Bakhshiev A.V. et al. The architecture of a software platform for growing spiking neural networks simulator developing. Journal of Physics: Conference Series. 2020. vol. 1679. no. 4. pp. 042001.