

А.М. КОРСАКОВ, А.В. БАХШИЕВ, Л.А. АСТАПОВА, Л.А. СТАНКЕВИЧ  
**РЕАЛИЗАЦИЯ ПОВЕДЕНЧЕСКИХ ФУНКЦИЙ НА  
СПАЙКОВЫХ НЕЙРОННЫХ СЕТЯХ**

*Корсаков А.М., Бахшиев А.В., Астапова Л.А., Станкевич Л.А.* Реализация поведенческих функций на спайковых нейронных сетях.

**Аннотация.** Рассматривается моделирование поведенческих функций животных, в частности, условного рефлекса. Проводится анализ современного состояния нейронных сетей с возможностью структурного реконфигурирования. В основу модели рефлекса положена нейронная сеть, базирующаяся на сегментной спайковой модели нейрона с возможностью структурной адаптации дендритного дерева к входному паттерну импульсов. Модель нейрона позволяет описывать и изменять онлайн структуру (размер тела клетки, количество и длина дендритов, количество синапсов) в зависимости от поступающего на её входы паттерна импульсов. Приведено краткое описание сегментной спайковой модели нейрона, отмечены её основные особенности с точки зрения возможности её структурного реконфигурирования. Описывается способ структурной адаптации модели к входному паттерну импульсов. Для исследования работы предложенной модели нейрона в сети, в качестве примера обосновывается выбор условного рефлекса, как частного случая механизма формирования ассоциативных связей. Приведено описание структурной схемы и алгоритма формирования условного рефлекса как с положительным, так и с отрицательным подкреплением. Представлено пошаговое описание экспериментов по формированию ассоциативных связей и условного рефлекса. Сделан вывод о перспективности применения спайковых сегментных моделей нейронов для повышения биоправдоподобности реализации поведенческих функций в нейроморфных системах управления. Рассмотрены дальнейшие перспективные направления развития нейроморфных систем, основанных на спайковых сегментных моделях нейрона.

**Ключевые слова:** нейроморфные системы, спайковый нейрон, спайковые нейронные сети, условный рефлекс, ассоциативные связи, управление поведением

**1. Введение.** В настоящее время активно разрабатываются системы управления динамическими объектами, по своей структуре, функциям и способам обработки информации подобных нервной системе живых организмов. Это связано с тем, что при решении многих трудноформализуемых задач классические вычислительные методы оказываются неэффективными. Так, при распознавании изображений и речевых сообщений часто невозможно создать и использовать точные математические модели и соответствующие методы решения. В то же время мозг достаточно эффективно решает такие задачи за счет массивного параллелизма своих нейронных сетей и способности к их структурной и параметрической настройке. Поэтому мозг считается непревзойденным инструментом восприятия и анализа больших потоков информации и принятия решений. Однако принципы обработки сигналов и их передачи между нейронными образованиями мозга и нервной си-

стемы в целом остаются малоизученными, поскольку их структура чрезвычайно сложна и с трудом поддается анализу существующими методами.

Современные искусственные нейронные сети в определенной степени облегчают решение трудноформализуемых задач [1]. Однако использование в них формальных нейронов с функциями взвешенного суммирования входных сигналов и нелинейной обработки выходного сигнала лишь в самых общих чертах соответствуют своим биологическим прототипам, что существенно ограничивает их возможности по сравнению с мозгом и нервной системой.

Нейроморфный подход, связанный с созданием математических моделей компонентов нервной системы и их аппаратных реализаций, в которых обработка сигналов адекватна биологическим прототипам, открывает новые возможности решения трудноформализуемых задач в технических системах. Предполагается, что разработка на основе нейроморфного подхода новых компонентов и архитектур глубоких нейронных сетей и специальных алгоритмов их обучения позволит создавать универсальные системы, эффективно решающие множество трудноформализуемых задач в пространствах высокой размерности и в условиях существенных неопределенностей [2]. Такой подход также перспективен в плане раскрытия механизмов переработки информации в мозге и нервной системе, что дает возможность обосновать использование выявляемых принципов структурной организации нейронов и выполняемых ими функций в сети при построении нейроморфных систем.

В общем случае под нейроморфными системами понимаются искусственные нейронные сети, архитектура и дизайн которых основаны на особенностях структуры и принципах работы реальных нейробиологических систем. Их моделирование стимулировано желанием понять и технически воплотить такие ключевые особенности нейронных структур мозга, как высокая чувствительность, адаптивность, обучаемость, устойчивость к повреждениям, способность иметь дело с нечеткой, избыточной, зашумленной информацией и, наконец, параллельный и распределенный способ обработки информации [3-5].

В настоящее время нейроморфные системы в основном создаются на спайковых (импульсных) нейронах. Спайковый нейрон – это искусственный нейрон, оперирующий с непрерывно поступающим многомерным потоком спайков как с потоком точечных событий. Простейшей моделью спайкового нейрона является модель порогового интегратора, IF (Integrate-and-Fire) [6], описываемая дифференциальным уравнением первого порядка. В общем случае каждый входной спайк приводит к отклику нейрона как динамической системы на импульсное

входное воздействие. Эти отклики называются постсинаптическими потенциалами и меняют потенциал мембраны нейрона во времени. Как и формальные модели нейронов, спайковый нейрон интегрирует несколько входных сигналов с некоторыми весами и способен генерировать выходные спайки, идущие на входные синапсы других нейронов на единственном выходном канале. Однако в отличие от бинарных и частотных моделей, в спайковом нейроне ведется интегрирование не только пространственной, но и временной информации.

Нейроморфные системы, построенные на базе простых спайковых нейронов, настраиваются на задачи (адаптируются), в основном, путем параметрической настройки нейронов и сетей, то есть изменением весов связей и порогов нейронов [7]. Однако известно, что в нервной системе осуществляется не только параметрическая, но и структурная адаптация нейронов и сетей под решаемую задачу. Это вдохновило исследователей на создание спайковых динамически развивающихся нейронных сетей eSNN (Evolving Spiking Neural Network), способных работать в реальном времени. 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.

Например, в ряде исследований [8-12] для каждого нового вектора входных данных, который требуется распознавать, динамически выделяется новый выходной нейрон, который подключается к входным нейронам. Инициализация, обновление весов и установление связей нейронов, чтобы настроить сеть на распознавание входного вектора, осуществляется с использованием правила RO (Rank Order). В некоторых реализациях нейроны с одинаковыми весовыми векторами объединяются на основе евклидова расстояния между ними. Это позволяет достичь очень быстрого обучения (может быть достаточно только одного прохода) как при обучении с учителем, так и без учителя [8]. Тем не менее, подход требует решения ряда проблем, таких как автоматическая настройка нескольких параметров обучения и повышение масштабируемости обучения для больших наборов данных.

Подход, описанный в [11], расширяет модель eSNN и предлагает новую динамическую модель спайковой нейронной сети deSNN [13]. Предлагаемый метод основан на таких механизмах обучения, как RO и обучение с помощью временных спайков – правила синаптической пластичности, управляемой спайками SDSF (Spike Driven Synaptic Plasticity). На этих же механизмах основан метод, предложенный в [14].

Нейрон LIF (Leaky Integrate-and-Fire) учится распознавать весь пространственно-временной паттерн, используя только одну итерацию в режиме онлайн-обучения. В [14] авторы отмечают возможность реализации нейрона и сети на нейроморфном оборудовании. Однако все еще нерешенным остается вопрос оптимизации многочисленных параметров нейронной сети.

В работе [15] представлен метод инкрементного обучения спайковой нейронной сети, структура скрытых слоев которой изменяется динамически с использованием алгоритма кластеризации (обучения без учителя). Однако входной и выходной слой классификации динамическими не являются и обучаются с учителем. Теми же авторами алгоритм модифицирован до алгоритма обучения спайковой нейронной сети с учителем SpikeComp [16], входной слой которой не является динамическим, а выходной слой состоит из динамически добавляемых нейронов, причем имеет место динамическое обновление весов или центров кластеров. При этом алгоритм SpikeComp, основанный на точном времени спайка, добавляет гораздо меньше выходных нейронов, чем метод eSNN, основанный на ранжировании. Кроме того, в [17] авторы представили усовершенствование метода обучения на основе ранжирования [12, 13], называемое SpikeTemp. Для преобразования входных данных используются гауссовские рецептивные поля и методы кодирования популяции с квадратным косинусом.

Архитектура спайковой нейронной сети с динамически изменяемыми синапсами представлена в [18]. Показано, что такая сеть способна выполнять классификацию образов с использованием временного кодирования. Используется обучение с учителем, основанное на методе эволюционной стратегии, ES (evolutionary strategy) [19], который используется для поиска оптимальных параметров, лежащих в основе процесса обучения без вычисления производных. Сеть поддерживает топологию прямой связи и может использоваться в качестве системы обнаружения признаков.

Динамическое формирование кластеров в популяциях импульсных нейронов, а также пластичность, зависящая от времени спайка – STDP (Spike-Timing Dependent Plasticity) использовано в [20]. Структура спайковой нейронной сети постоянно корректируется путем добавления и сокращения популяций нейронов. Кроме того, количество нейронов в каждой популяции постоянно изменяется по мере поступления новых данных. Алгоритм STDP используется для регулировки силы синаптических связей.

В [21] предложена саморегулирующаяся развивающаяся нейронная сеть SRESN (Self-Regulating Evolving Spiking Neural), в которой используется специальная схема кодирования популяции IF нейронов. Во время обучения саморегулирующийся механизм выбирает подходящую стратегию обучения (добавление нейронов, обновление параметров или пропуск выборки) на основе знаний, хранящихся в сети, и новых знаний, присутствующих в обучающей выборке. Веса нового нейрона инициализируются с использованием модифицированной схемы обучения в порядке ранжирования.

Применение модели нейрона с учетом описания структуры дендритного дерева предложено в [22], однако модель не рассматривает сигналы в сети как спайковые. Подход к созданию пластичных нейронных сетей на основе эволюционного подхода рассматривается в [23]. Такой подход, несомненно, имеет ряд преимуществ при решении задач поиска оптимальной структуры нейронной сети на этапе проектирования.

Анализ приведенных примеров, демонстрирующих спайковые нейронные сети и методы их структурного и параметрического обучения, позволяет сделать вывод о том, что для существенного увеличения адаптивной способности таких сетей необходимо рассматривать не только параметрическую, но и структурную адаптацию нейронных сетей, как на уровне изменения топологии связей между узлами (нейронами) сети, так и на уровне усложнения модели каждого узла, например, путем перехода к сегментным (компаратментным) моделям нейронов. По мнению авторов, это даст возможность более эффективной реализации поведенческих функций в нейроморфных системах управления, например, в робототехнике.

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, возможность структурной онлайн перестройки самой модели нейрона.

В настоящей работе рассматривается возможность реализации поведенческих функций в нейроморфных системах, построенных на спайковых нейронных сетях с сегментными нейронами. Для этого предлагается специальный алгоритм структурной адаптации нейронов ко входным паттернам импульсов, а также алгоритм формирования ассоциативных связей нейронной сети, для настройки ее на реализацию

определенных поведенческих функций. Работа алгоритмов демонстрируется на примере реализации простых поведенческих функций типа безусловного и условного рефлекса.

Далее в разделе 2 приведена постановка задачи, определены основные термины, представлена используемая при моделировании структурная схема модели нейрона, приведены её важнейшие свойства с точки зрения возможностей структурного реконфигурирования дендритного и синаптического аппаратов. Раздел 3 описывает принцип структурной адаптации спайковой сегментной модели нейрона, решается задача адаптации модели нейрона к произвольному паттерну импульсов. В разделе 4 представлены структурные схемы организации нейронной сети для моделирования ассоциативных связей и, как частный случай, для моделирования условного рефлекса (как с положительным, так и с отрицательным подкреплением). Также в разделе 4 приведен алгоритм для моделирования процесса формирования ассоциативных связей. В разделе 5 представлено пошаговое описание экспериментов по формированию ассоциативных связей и условного рефлекса. В заключительном разделе 6 приведено обсуждение результатов работы, отмечены основные недостатки предлагаемых моделей, а также намечены перспективные пути развития данного направления работ.

**2. Постановка задачи.** Цель данной работы – показать возможность реализации поведенческих функций на сети из сегментных спайковых нейронов. Для этого требуется решить задачу разработки алгоритмов структурной адаптации нейрона к входному паттерну импульсов и формирования ассоциативных связей нейронной сети, отображающей заданную поведенческую функцию.

В основу настоящей работы положена разработанная авторами ранее модель спайкового нейрона, подробно описанная в [24]. В данной модели предполагается, что на входы поступают импульсные потоки, которые преобразуются в синапсах в аналоговые величины, описывающие динамические процессы выделения и распада медиатора в синаптической щели. Входные и выходные сигналы нейрона равны нулю в отсутствии импульса и константе на время действия импульса.

Структурная схема рассматриваемой модели показана на рисунке 1.

Здесь  $B1-BL$  – участки мембраны, описывающие тело нейрона.  $D_{ij}$  – участки мембраны, описывающие  $i$ -й дендрит.  $S_{ijl}$  – модели синаптической передачи. Их суммарное влияние оказывает либо возбуждающее  $gs_{ijl}$ , либо тормозное  $ga_{ijl}$  воздействие на соответствующий участок мембраны.

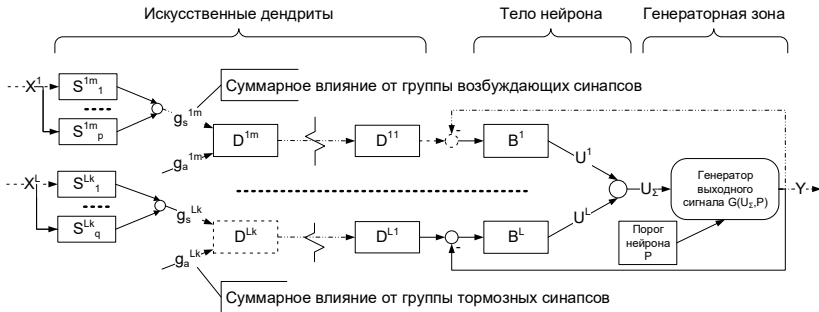


Рис. 1. Структурная схема модели сегментного спайкового нейрона для решения задачи распознавания паттерна импульсов

Такая структура модели соответствует решению задачи структурного обучения нейрона паттерну импульсов, представляемому входным вектором  $X$ . Отметим особенности предложенной модели нейрона, играющие существенную роль при решении задачи разработки алгоритмов структурного обучения модели нейрона:

- возможность создания произвольного числа сегментов тела нейрона (участков мембраны с обратной связью), что означает возможность изменять размерность входного паттерна импульсов;
- возможность независимого наращивания длин дендритов (участков мембраны без обратной связи); увеличение длины дендрита приводит к временной задержке сигнала и к уменьшению его амплитуды;
- возможность добавления произвольного числа синапсов на произвольном участке мембраны (теле, дендрите); добавление синапса приводит к увеличению амплитуды сигнала;
- возможность произвольной организации 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.

Под паттерном импульсов будем понимать совокупность сигналов, поступающих на входы модели нейрона (дендриты) за некоторый (выбранный) 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) модели нейрона. Предполагается, что за выбранный промежуток времени поступления паттерна на отдельном входе (дендрите) может быть зафиксировано не более одного входного импульса.

Выходной сигнал генерируется в низкопороговой зоне модели нейрона (генератор потенциала действия) и представляет собой одиночный импульс, либо серию импульсов единичной амплитуды, формируемых при превышении величиной потенциала некоторого порога. 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.

Как будет показано далее, это возможно достичь путём добавления отдельных сегментов дендритов и добавлением синапсов на конечный сегмент дендрита.

Процедуру наращивания длины дендрита будем называть синхронизацией, а процедуру добавления синапсов – нормализацией. Процессы синхронизации и нормализации для конкретного паттерна будем называть обучением модели нейрона данному паттерну импульсов. Генерацию потенциала действия при фиксированном паттерне импульсов и соответствующей ему конфигурации обученной модели нейрона будем называть распознаванием данного паттерна импульсов.

Общий подход к реализации поведенческой функции может быть сведён к минимизации отличия целевой поведенческой реакции сети  $f_h$  на заданный паттерн импульсов от реальной реакции  $f_{beh}$ , то есть:

$$\begin{cases} f_{beh} = F(\bar{x}, t) \\ \widehat{f}_{beh} = \widehat{F}(\bar{x}, n_1, \dots, n_M, c_{i,j}, t_1, \dots, t_T), \\ f_{beh} - \widehat{f}_{beh} \rightarrow \min, \end{cases} \quad (1)$$

где  $\bar{x}$  – вектор входного воздействия;  $F$  – поведенческий функционал, связывающий входы и выходы биологического прототипа во времени;  $\widehat{F}$  – нейросетевое отображение поведенческой функции;  $n_k$  – число сегментов в  $k$ -м нейроне ( $k = 1, \dots, M$ );  $c_{i,j}$  – связи между  $i$ -м и  $j$ -м нейронами;  $t_k$  – моменты времени прихода сигналов на вход  $k$ -го сегмента.



В процессе такой минимизации производится структурная настройка нейронной сети для установления нужной последовательности выходных импульсов.

**3. Структурная адаптация модели нейрона.** Как было указано выше, обучение модели нейрона заданному паттерну импульсов сводится к решению двух подзадач – синхронизации и нормализации.

Задача синхронизации сигналов заключается в максимальном временном сопоставлении экстремумов кривых потенциалов всех дендритов при суммировании их вкладов внутри низкопороговой зоны нейрона.

Способом решения данной задачи будет минимизация модуля суммы разностей между временем фиксации экстремума кривой потенциала базового дендрита и временами фиксации экстремумов кривых потенциалов остальных дендритов (рис. 2), что достигается путём добавления отдельных сегментов на дендриты нейрона (наращивание дендритов). Под базовым дендритом будем понимать такой дендрит, в котором начальный экстремум кривой потенциала фиксируется с наибольшим запаздыванием. Следует отметить, что базовый дендрит не наращивается.



Рис. 2. Параллельное наращивание дендритов с временным сдвигом сигналов

На рисунке 2 цифрой «1» обозначен суммарный вклад дендритов в потенциал внутри низкопороговой зоны, цифрой «2» – потенциал базового дендрита. Остальные кривые описывают потенциал наращиваемых дендритов.

Следующим шагом является решение задачи нормализации сигналов путём добавления синапсов. Задача нормализации заключается в компенсации потери амплитуды потенциала на отдельном дендрите при наращивании его длины и решается после задачи синхронизации, таким образом, наращивание длины дендритов уже произошло, а экстремумы кривых потенциалов отдельных дендритов синхронизированы (правый график на рис. 2).

Поскольку две эти задачи (синхронизация и нормализация) связаны, для решения задачи нормализации необходимо на первой итерации алгоритма синхронизации (до того, как произошло наращивание дендритов) запомнить эталонные значения экстремумов кривых потенциалов отдельных дендритов.

Имея эталонные значения экстремумов кривых потенциалов отдельных дендритов, для каждого дендрита будем добавлять синапс на последний сегмент этого дендрита до тех пор, пока максимум потенциала данного дендрита не превысит эталонного значения.

После превышения эталонного значения требуется удалить один синапс с последнего сегмента данного дендрита. Таким образом, задача нормализации сигнала на данном дендрите может быть переформулирована следующим образом: требуется найти максимальное количество синапсов на последнем сегменте каждого дендрита, но так, чтобы максимальное значение потенциала на данном дендрите не превысило эталонного (рис. 3).




Рис. 3. Параллельное увеличение числа синапсов на дендритах

На рисунке 3 цифрой «1» обозначен суммарный вклад дендритов в потенциал внутри низкопороговой зоны, остальные кривые описывают потенциалы отдельных дендритов.

Следует отметить, что данная процедура может совершаться параллельно (одновременно) для всех дендритов.

Все значения максимальной суммарной амплитуды потенциалов дендритов, при которых происходит генерация выходного импульса, независимо от числа дендритов в модели нейрона, укладываются в один и тот же коридор значений. Это позволяет подобрать универсальный порог срабатывания модели нейрона на паттерн импульсов, которому она ранее обучалась.

#### 4. Структурная схема формирования ассоциативных связей.

Для комплексной проверки свойств модели спайкового нейрона с возможностью структурной адаптации и взаимодействия таких нейронов в сети требовалось подобрать пример организации естественной нейронной сети для его воспроизведения посредством описанной выше модели нейрона. Требованиями к такой естественной сети являлись, с одной стороны, достаточная её исследованность в рамках нейрофизиологии, а с другой - простота в реализации. В качестве такого примера была выбрана схема формирования условного рефлекса по Э.А. Асратяну [25] (рис. 4).




Рис. 4. Схема нейронных путей формирования слюноотделительного рефлекса на действие света (по Э.А. Асратяну)

Согласно этой модели, условный раздражитель, например звонок, вызывает безусловно-рефлекторную ориентировочную реакцию. Звонок, являясь индифферентным раздражителем для пищевого рефлекса, пока не вызывает отделения слюны. В то же время безусловный раздражитель – пища – вызывает появление слюноотделения. Таким образом, в коре (и стволе мозга) одновременно возникают очаги возбуждения, и если их одновременное возбуждение повторяется многократно, то между этими центрами происходит формирование пути проведения нервных импульсов, обеспечивающее замыкание условно-рефлекторной временной связи. После установления такой связи условный звуковой сигнал звонка приобретает для животного новое значение – сигнала или информации о предстоящем кормлении. С этого момента для вызова безусловного пищевого рефлекса, проявляющегося слюноотделением, двигательным беспокойством, другими вегетативными реакциями, становится достаточно подачи только условного раздражителя – включения звонка [26].

В биологии рефлексы с положительным подкреплением – это такие рефлексы, при выработке которых применяется мотивационно благоприятное или желаемое подкрепление. Главным свойством положительного подкрепления является то, что оно увеличивает частоту соответствующей реакции или побуждает животное приближаться к источнику подкрепления. Те же рефлексы, в которых применяется мотивационно неблагоприятное подкрепление (то есть подкрепление, которого хочется избежать), например удары током, называются рефлексами с отрицательным подкреплением. Оно, напротив, снижает частоту соответствующей реакции или заставляет удаляться от источника подкрепления и избегать ситуации в целом, если этот источник с ней неразрывно связан.

В рамках настоящего исследования на моделях сегментного спайкового нейрона следовало воспроизвести условный рефлекс и формирование ассоциативных связей.

Описанная выше модель нейрона с возможностью структурной адаптации позволяет нам предложить схему организации нейронной сети, которая воспроизводит условный рефлекс (рис. 5).




Рис. 5. Структурная схема нейронной сети, воспроизводящей условный рефлекс

На рисунке 5 «УР» – это нейрон с возможностью структурной адаптации, отвечающий условному раздражителю («условный раздражитель»); «БР» – нейрон с возможностью структурной адаптации, отвечающий безусловному раздражителю («безусловный раздражитель»); «И» – нейрон, реализующий функцию «И» (нейрон «И»); «УРф» – нейрон, формирующий условный рефлекс («большой нейрон»); «БРф» – нейрон, реализующий функцию «ИЛИ» и отвечающий безусловному рефлексу (нейрон «ИЛИ»).

На момент начала работы системы из всех связей, изображённых на рисунке 5, создаётся лишь связь «БР – БРф», что постулирует изначальное существование безусловного рефлекса.

При старте системы происходит обучение моделей нейронов «УР» и «БР» входным, произвольно выбранным, паттернам импульсов (способом, описанным в пункте 3). По завершении процесса обучения формируются связи «УР – И» и «БР – И», что соответствует моменту начала формирования рефлекторной дуги «РД».

Нейрон «И», состоящий из двух сегментов сомы, обучается сигналам, поступающим от нейронов «УР» и «БР». Обучение возможно лишь до определённого, заданного параметром, предела. Если рассинхронизация входных сигналов больше заданного этим параметром порога, воздействие условного и безусловного раздражителей не считается одновременным и дальнейшее формирование рефлекторной дуги не происходит. В противном случае, по окончании обучения нейрон «И» начинает генерировать выходные импульсные сигналы и создаёт связь «И – УРф».

Нейрон «УРф» представляет из себя «большой» нейрон, то есть количество сегментов его сомы больше единицы. Конкретное значение размера «большого» нейрона выбирается пользователем и фактически означает скорость, с которой система сформирует условный рефлекс при одновременном воздействии условного и безусловного раздражителей. Нейрон «И» формирует связь лишь с одним из сегментов сомы «большого» нейрона, что является недостаточным для генерации моделью нейрона «УРф» выходного импульсного сигнала. Однако при поступлении на вход нейрона «УРф» импульсов от нейрона «И», происходит добавление синапсов на входной участок сомы, что повышает значение потенциала внутри низкопороговой зоны «большого» нейрона. Когда порог генерации потенциала действия в низкопороговой зоне нейрона оказывается превышенным, происходит генерация выходного импульса моделью нейрона «УРф», что приводит к формированию связи «УР – БРф». Таким образом рефлекторная дуга замыкается.

Особенностью модели нейрона «БРф», состоящего лишь из одного сегмента сомы, является наличие на этом сегменте двух синапсов, что позволяет данной модели реализовывать функцию «ИЛИ». К одному из этих синапсов, как указывалось выше, произведено подключение связи от нейрона «БР» ещё при инициализации. Ко второму подключается связь от нейрона «УР» при начале генерации выходных импульсов нейроном «УРф». При формировании этой связи и при наличии

возбуждения на входе нейрона «УР», модель нейрона «БРФ» оказывается способной генерировать выходные импульсы даже при отсутствии активности со стороны нейрона «БР».

Другими словами, для вызова безусловной реакции становится достаточно подачи только условного раздражителя, что и означает завершение формирования условного рефлекса.

Следует отметить, что все описанные ранее сформированные связи между моделями нейронов подключались к возбуждающим моделям синапсов. Кроме того, данная схема реализует условный рефлекс с положительным подкреплением. Но для реализации условного рефлекса с отрицательным подкреплением нам достаточно на последнем шаге алгоритма подключить связь от нейрона «УР» не к возбуждающему, а к тормозному синапсу на соме нейрона «БРФ».

Как будет показано в эксперименте, в результате такого подключения нейрон «БРФ» не будет генерировать выходных импульсов при активности нейрона «УР» даже в том случае, если поступает входной сигнал от нейрона «БР».

Отметим также, что входные паттерны импульсов для условного и безусловного раздражителей в ходе описанных ниже экспериментов выбирались произвольно, выходные же импульсы просто фиксировались без какой-либо их дальнейшей обработки. Однако следует понимать, что со стороны входов на каком-либо этапе обработки должны располагаться модели афферентных нейронов, преобразующие внешние воздействия (зрительные, слуховые и т.п.) в импульсные потоки. Со стороны же выходов системы на каком-то этапе должны располагаться модели эфферентных нейронов, преобразующих импульсные потоки, например, в мышечные сокращения. Вариант такого взаимодействия на примере модели «сетчатка – афферентный нейрон – глазная мышца» был описан авторами в [27].

Рассмотрим теперь схему формирования ассоциативных связей в общем случае (рис. 6). В качестве его биологической интерпретации можно предложить формирование взаимных ассоциаций на различные раздражители при их продолжительном одновременном воздействии на субъект.

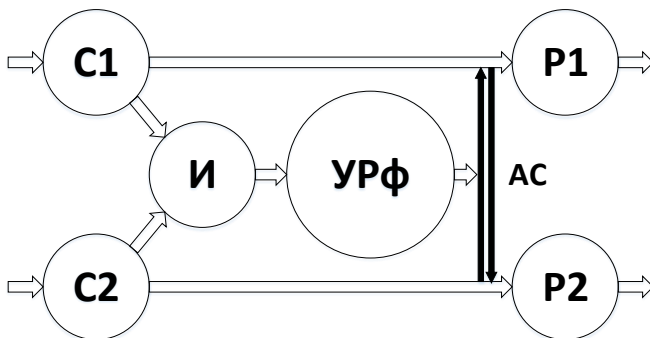


Рис. 6. Обобщённая структурная схема нейронной сети, формирующей ассоциативные связи

На рисунке 6 «С1» – это нейрон, на который поступает паттерн импульсов, который можно условно считать первым стимулом («стимул №1»). Нейрон «P1» имеет лишь один сегмент сомы, на котором, однако, расположено две модели синапса. Связь «С1 – P1» образуется при инициализации системы. Таким образом, модель нейрона «P1» реализует безусловную реакцию на стимул «С1».

Аналогично, нейроны «С2» и «P2» реализуют безусловную реакцию «P2» на стимул «С2» («стимул №2»). Связь «С2 – P2» также создаётся при инициализации системы.

Нейроны «И» и «УРФ» моделируют образование рефлекторной дуги способом, полностью совпадающим с описанным выше для условного рефлекса, за одним исключением: при начале генерации сигналов нейроном «УРФ» образуется сразу две ассоциативных связи («АС») – «С1 – P2» и «С2 – P1». Таким образом, нейроны «P1» и «P2» приобретают способность генерировать выходные сигналы (импульсы) при активности лишь одного входа: «С1» либо «С2».

Формирование ассоциативных связей реализовано в соответствии с алгоритмом на рисунке 7. Алгоритм формирования условного рефлекса выглядит аналогичным образом с заменой условных сокращений за исключением того, что на последнем шаге формируются не две, а одна связь «УР – БРФ».

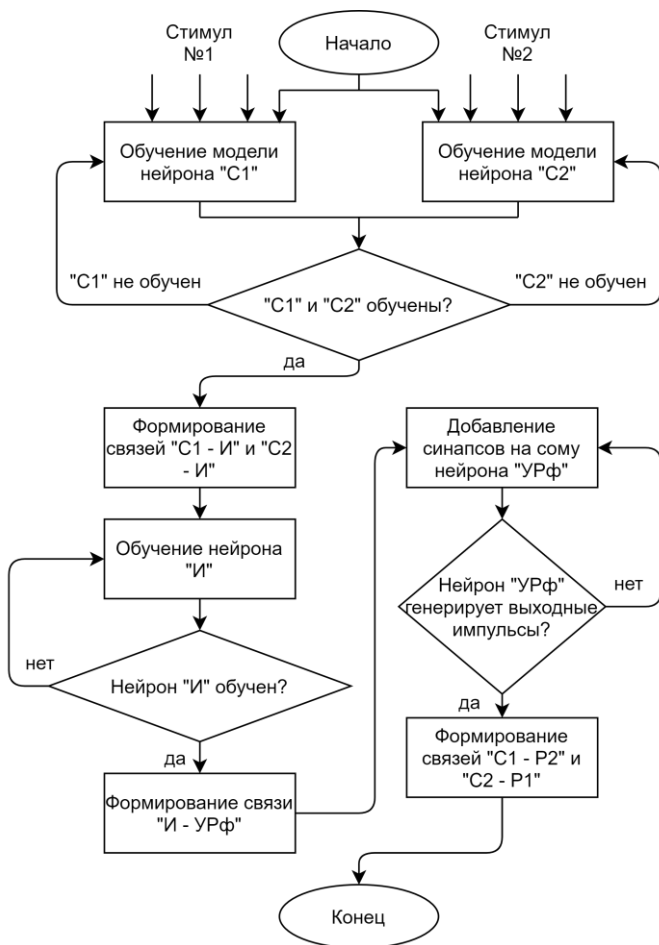


Рис. 7. Алгоритм формирования ассоциативных связей

### 5. Эксперименты по формированию ассоциативных связей.

Создание моделей нейронных сетей 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 структурным описанием.



Для решения поставленной задачи использовалась программная платформа, описанная в [28, 29].

Результатом работы алгоритма в случае модели условного рефлекса являлся ответ модели нейрона безусловной реакции при активности модели нейрона условного раздражителя даже при отсутствии активности модели нейрона безусловного раздражителя. В случае модели формирования ассоциативных связей результатом работы являлась способность пары нейронов, моделирующих реакцию на стимулы, генерировать выходные сигналы (импульсы) при активности лишь одного произвольного стимула.

На рисунке 8 представлена исходная модель для воспроизведения условного рефлекса, реализованная в упомянутой выше программной платформе.

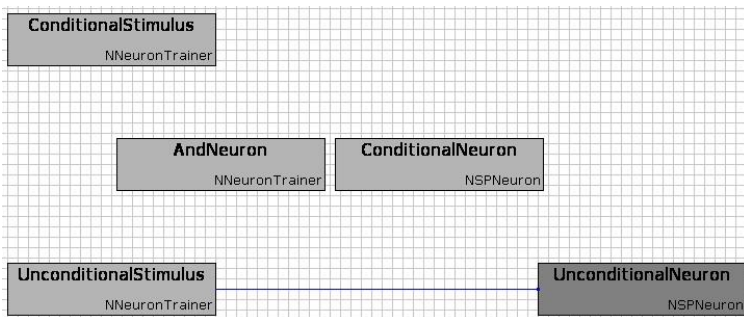


Рис. 8. Инициализированная модель формирования условного рефлекса

На рисунке 8 «ConditionalStimulus» – это нейрон, отвечающий условному раздражителю (рис. 5); «UnconditionalStimulus» – нейрон, отвечающий безусловному раздражителю; «AndNeuron» – нейрон, реализующий функцию «И»; «ConditionalNeuron» – нейрон, формирующий условный рефлекс; «UnconditionalNeuron» – нейрон, реализующий функцию «ИЛИ» и отвечающий безусловному рефлексу.

После начала работы системы установлена лишь одна связь, отражающая изначальное наличие безусловного рефлекса.

В качестве входных паттернов импульсов в описываемом эксперименте были выбраны следующие паттерны импульсов: (0,03; 0; 0,09; 0,06) для нейрона, отвечающего условному раздражителю, и (0,09; 0,06; 0,03; 0) для нейрона, отвечающего безусловному раздражителю. Отдельные сигналы в паттерне заданы как величины задержки относительно начала генерации очередного паттерна. Величина измерения – секунда. Частота генерации паттернов составляла 0,67 Гц.

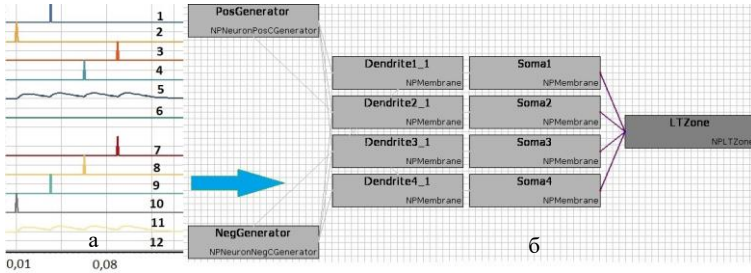


Рис. 9. Входные паттерны импульсов и инициализированная модель нейрона с возможностью обучения: а) входные паттерны импульсов; б) инициализированная модель нейрона с возможностью обучения

На рисунке 9а цифрами 1–4 обозначен входной паттерн импульсов, отвечающий условному раздражителю; 5,11 – суммарный потенциал в низкопороговой зоне нейронов; 6 – выход нейрона, отвечающего условному раздражителю; 7-10 – входной паттерн импульсов, отвечающий безусловному раздражителю; 12 – выход нейрона, отвечающего безусловному раздражителю.

На рисунке 9б: PosGenerator и NegGenerator – вспомогательные блоки, задающие начальное состояние активности участка мембраны; DendriteN\_I–I-й сегмент N-го дендрита; SomaN – N-й сегмент сомы; LTZone –низкопороговая зона нейрона.

В результате процесса обучения нейронов «ConditionalStimulus» и «UnonditionalStimulus» соответствующим им входным паттернам импульсов, в определённый момент времени эти нейроны начинают генерировать выходной сигнал. Этот момент соответствует окончанию обучения нейронов и образованию связей «ConditionalStimulus – AndNeuron» и «UnonditionalStimulus – AndNeuron». На рисунке 10 представлена структурная организация обученного нейрона, отвечающего безусловному раздражителю.



Рис. 10. Структурная организация нейрона, отвечающего безусловному раздражителю

Как видно из рисунка 10, в результате обучения нейрона, представленного на рисунке 9б, длины четырёх дендритов составили десять, семь, четыре и один сегмент.

На следующем шаге, после образования связей «ConditionalStimulus – AndNeuron» и «UnonditionalStimulus – AndNeuron», начинается обучение нейрона, реализующего функцию «И». Структурная организация этого нейрона приведена на рисунке 11.





Рис. 11. Структурная организация нейрона, реализующего функцию «И»

Блоки на рисунке 11 имеют то же значение, что и на рисунке 9б. Важной особенностью этого нейрона является генерация им выходных импульсов лишь в случае одновременной активности двух его входов.

В нашем случае входные импульсы приходят на вход данного нейрона одновременно, что в качестве простого примера хорошо иллюстрирует алгоритм структурной адаптации модели нейрона (рисунок 12).



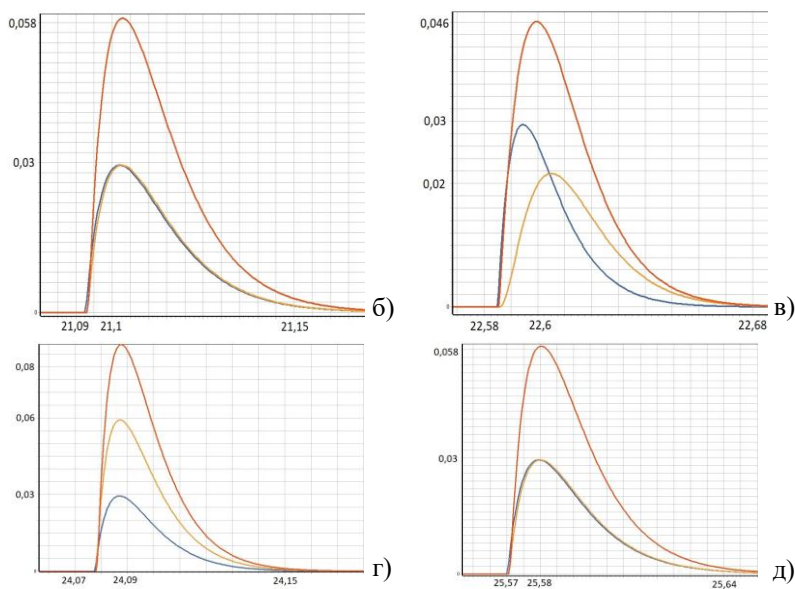


Рис. 12. Обучение нейрона, реализующего функцию «И»: а) всплески суммарного потенциала внутри низкопороговой зоны нейрона; б-д) виды всплесков суммарного потенциала

На рисунке 12а можно видеть четыре всплеска суммарного потенциала внутри низкопороговой зоны нейрона, каждый из которых соответствует отдельной итерации, а все они вместе – полному циклу обучения нейрона. Детально эти всплески проиллюстрированы на рисунках 12б-д. На рисунках 12б-д кривые с наибольшей амплитудой соответствуют суммарному значению потенциала внутри низкопороговой зоны нейрона, остальные кривые – отдельным дендритам.

Рисунок 12б соответствует первому всплеску – началу обучения модели нейрона, когда на его вход одновременно пришло два импульса. Одновременность означает отсутствие необходимости структурно адаптировать нейрон, тем не менее, необходимо в этом убедиться алгоритмически.

На рисунке 12в произошло наращивание одного из дендритов на один сегмент. Это соответствует процедуре синхронизации. Как видно из рисунка, экстремум потенциала, соответствующего данному дендриту, получил временное смещение (запаздывание) относительно базового дендрита и, вместе с тем, уменьшил свою амплитуду.

В результате фиксации увеличения рассинхронизации сигналов с двух дендритов лишний сегмент дендрита был удалён, и начался процесс нормализации (рис. 12г). В результате был добавлен синапс на последний сегмент дендрита. Как видно на рисунке, рассинхронизация пропадает, но увеличивается амплитуда, соответствующая данному дендриту.

В результате фиксации превышения экстремумом этой амплитуды эталонного значения, лишний синапс удаляется, и обучение заканчивается с конфигурацией структуры нейрона, эквивалентной той, что и была до начала обучения (рис. 12д).

После завершения обучения нейрона, реализующего функцию «И», создаётся связь «AndNeuron – ConditionalNeuron», и «большой» нейрон начинает наращивать синапсы (рис. 13).

На рисунке 13а показана структура модели «большого» нейрона. В данном эксперименте «большой» нейрон состоял из десяти сегментов модели сомы «SomaN». «LTZone» - модель генератора выходного импульса (потенциала действия). Каждый новый входной импульс от модели нейрона, реализующего функцию «И» (рис. 13в), добавлял на данный сегмент сомы новый синапс. Это отражено на рисунке 13б, где ExcSynapseN – N-я модель возбуждающего синапса; ExcChannel – модель возбуждающего ионного канала; InhSynapse1 – модель тормозного синапса; InhChannel – модель тормозного ионного канала.

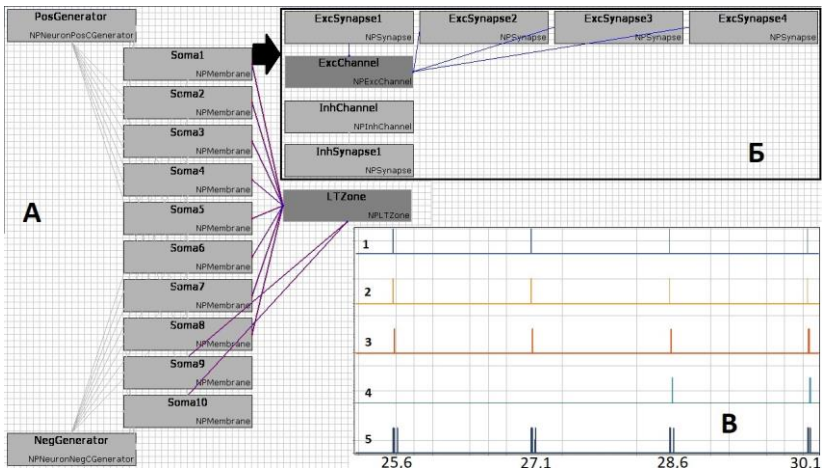


Рис. 13. Обучение нейрона, формирующего условный рефлекс

На рисунке 13в обозначены: 1 – выход нейрона, отвечающего условному раздражителю; 2 – выход нейрона, отвечающего безусловному раздражителю; 3 – выход нейрона, реализующего функцию «И»; 4 – выход нейрона, формирующего условный рефлекс («большой» нейрон); 5 – выход нейрона, реализующего функцию «ИЛИ» и отвечающего безусловному рефлексу.

Как видно из рисунка 13в, в определённый момент «большой» нейрон начинает генерировать выходные импульсы, после чего формируется связь «ConditionalStimulus – UnconditionalNeuron», и, таким образом, рефлекторная дуга «РД» замыкается.

На рисунке 14 изображена схема единственного сегмента сомы нейрона, реализующего функцию «ИЛИ» и отвечающего безусловному рефлексу.




Рис. 14. Схема сомы нейрона, реализующего функцию «ИЛИ» и отвечающего безусловному рефлексу

Блоки на рисунке 14 имеют то же значение, что и на рисунке 13б. В момент инициализации системы формируется отвечающая безусловному рефлексу связь «UnconditionalStimulus – UnconditionalNeuron», которая соединена с блоком «ExcSynapse1» на рисунке 14. После замыкания рефлекторной дуги связь «ConditionalStimulus – UnconditionalNeuron» соединяется с блоком «ExcSynapse2». Теперь достаточно активности на входе лишь одной из моделей синапсов для того, чтобы нейрон, реализующий функцию «ИЛИ», генерировал выходные импульсы.

Результат работы модели, сформировавшей условный рефлекс, приведён на рисунке 15.



Рис. 15. Работа системы при активности лишь условного раздражителя

Графики на рисунке 15 расположены в том же порядке, что и на рисунке 13в. Как видно из рисунка 15, отключение в какой-то момент времени безусловного раздражителя привело к прекращению активности выходов блоков «AndNeuron» и «ConditionalNeuron», однако, выход блока «UnconditionalNeuron» продолжает быть активным.

Таким образом, условный рефлекс был сформирован.

Отметим, что всё вышесказанное относилось лишь к условному рефлексу с положительным подкреплением. Для того, чтобы сформировать условный рефлекс с отрицательным подкреплением, нам необходимо на последнем шаге алгоритма при организации связи «ConditionalStimulus – UnconditionalNeuron» соединить выход низкопороговой зоны блока «ConditionalStimulus» с блоком «InhSynapse1» (тормозный синапс), а не с блоком «ExcSynapse2» (возбуждающий синапс) (рис. 14). В таком случае, после завершения формирования рефлекса, при активности условного раздражителя, на выходе блока «UnconditionalNeuron» генерация выходных импульсов не будет производиться вне зависимости от наличия или отсутствия активности безусловного раздражителя (рис. 16).




Рис. 16. Формирование условного рефлекса с отрицательным подкреплением

Графики на рисунке 16 расположены в том же порядке, что и на рисунке 13в. На рисунке 16 на итерации «1» подходит к завершению обучение модели «большого» нейрона, рефлекторная дуга «РД» не замкнута. Блок «UnconditionalNeuron» генерирует выходной импульс из-за активности выхода нейрона, отвечающего безусловному раздражителю.

На итерации «2» обучение «большого» нейрона завершается. «Большой» нейрон генерирует выходной импульс, что служит сигналом к формированию связи «ConditionalStimulus – UnconditionalNeuron».

На итерации «3» связь «ConditionalStimulus – UnconditionalNeuron» сформирована. Активность на выходе нейрона «UnconditionalNeuron» пропадает, несмотря на активность выхода на модели безусловного раздражителя.

На итерации «4» стимуляция модели условного раздражителя отключается, что приводит к восстановлению активности на выходе нейрона «UnconditionalNeuron».

Таким образом, условный рефлекс с отрицательным подкреплением был сформирован.

Рассмотрим теперь формирование ассоциативных связей в спайковых сегментных нейронных сетях в общем случае. На рисунке 6 была приведена структурная схема нейронной сети, формирующей ассоциативные связи. На рисунке 17 представлена инициализированная модель для формирования ассоциативных связей, отвечающая этой структурной схеме.



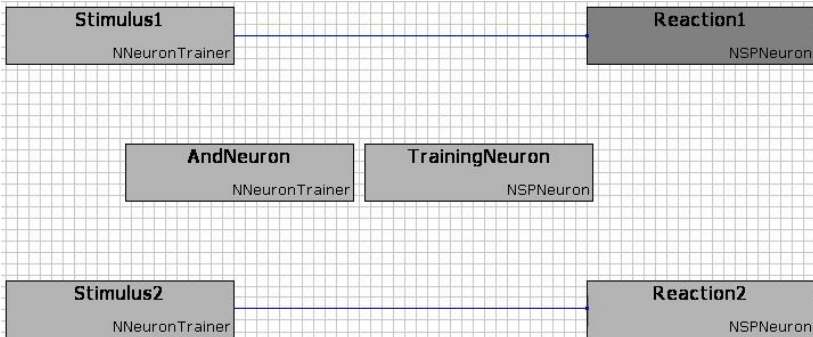


Рис. 17. Инициализированная модель для формирования ассоциативных связей

На рисунке 17 «Stimulus1» – это нейрон, на который поступает паттерн импульсов (здесь и ниже см. рис. 6). Нейрон «Reaction1» имеет лишь один сегмент сомы, на котором, однако, расположено два синапса. Связь «Stimulus1 – Reaction1» образуется при инициализации системы. Нейроны «Stimulus2» и «Reaction2» реализуют безусловную реакцию нейрона «Reaction2» на стимул «Stimulus2». Связь «Stimulus2 – Reaction2» также создаётся при инициализации системы.

Блоки «AndNeuron» и «TrainingNeuron» моделируют образование рефлекторной дуги способом, полностью совпадающим с описанным выше для условного рефлекса, за одним исключением: при начале генерации сигналов нейроном «TrainingNeuron» образуется сразу две ассоциативных связи – «Stimulus1 – Reaction2» и «Stimulus2 – Reaction1». Таким образом, нейроны «Reaction1» и «Reaction2» приобретают способность генерировать выходные сигналы (импульсы) при активности лишь одного входа: «Stimulus1» либо «Stimulus2» (рис. 18).




Рис. 18. Формирование ассоциативных связей

На рисунке 18 обозначены: I – выход нейрона, обученного стимулу №1; II – выход нейрона, обученного стимулу №2; III – выход нейрона, реализующего функцию «И»; IV – выход нейрона, формирующего ассоциативные связи («большой» нейрон); V – выход нейрона, отвечающего за реакцию на стимул №1; VI – выход нейрона, отвечающего за реакцию на стимул №2.

На первой итерации, изображенной на рисунке 18 («1»), все нейроны обучены и ассоциативные связи сформированы, что видно по наличию активности на выходе нейрона, формирующего ассоциативные связи (график «IV»). На этой итерации активны оба стимула и выходы обоих нейронов, отвечающих за реакцию.

На второй итерации («2»), генерация первого стимула была отключена, тем не менее, активны оба нейрона, отвечающие за реакцию. И аналогично для итерации №3 («3»): генерация второго стимула отключена, тем не менее, активны оба нейрона, отвечающие за реакцию.

Как видим, ассоциативные связи были сформированы.

**6. Заключение.** Анализ существующих архитектур спайковых нейронных сетей показал, что в рамках структурной адаптации рассматриваются в основном вопросы регулирования количества нейронов и синапсов. В работе показано, что 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, а также алгоритм формирования ассоциативных связей нейронной сети, показали возможность реализации поведенческих функций в нейроморфных системах управления, построенных на спайковых нейронных сетях с сегментными нейронами.

Предложенный метод и реализующий его алгоритм структурной адаптации модели нейрона к произвольному паттерну входных импульсов фактически обеспечивает обучение нейрона положительной реакции на данный паттерн. После завершения обучения нейрон приобретает возможность распознавать паттерн входных импульсов, которому он был ранее обучен. Однако следует отметить, что предлагаемый метод структурной адаптации модели нейрона не дает возможности переобучения отдельного нейрона в автоматическом режиме.

Эффективность предложенной схемы и реализующего ее алгоритма формирования ассоциативных связей в сети сегментных спайковых нейронов показана на примере реализации простых поведенческих функций типа безусловного и условного рефлекса с положительным и отрицательным подкреплением. Однако следует отметить, что созданные на настоящий момент времени ассоциативные связи не обладают способностью со временем ослабевать либо полностью разрушаться.

Поиск решения для устранения недостатков предложенных методов структурной адаптации сегментных нейронов к входному паттерну, а также формирования ассоциативных связей при настройке спайковой нейронной сети на заданную поведенческую функцию, является перспективным направлением развития исследований по данной тематике. Остаётся также открытым вопрос автоматического выбора сигналов, которые должны быть ассоциированы друг с другом в нейроморфной системе. В настоящее время пара связываемых друг с другом стимулов задаётся оператором. Переход на верхний уровень моделирования ассоциативных процессов представляется сложной, но перспективной задачей [30]. В планах дальнейших исследований значится также создание моделей, не ограниченных лишь парой входных паттернов импульсов, и способных создавать сложные взаимосвязи (как возбуждающие, так и тормозные) между составляющими их слоями спайковых нейронов.

### Литература

1. *Shrestha A., Mahmood A.* Review of deep learning algorithms and architectures. IEEE Access. Institute of Electrical and Electronics Engineers Inc. 2019. Vol. 7. pp. 53040–53065.
2. *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.
3. *James C. D. et al.* A historical survey of algorithms and hardware architectures for neural-inspired and neuromorphic computing applications // *Biologically Inspired Cognitive Architectures*. 2017. vol. 19. pp. 49–64.
4. *Schuman C.D., Potok T.E.* A Survey of Neuromorphic Computing and Neural Networks in Hardware // arXiv preprint arXiv:1705.06963. 2017.
5. *Мельников Г.С., Мельникова Э.И., Самков В.М.* Нейроморфные системы анализа изображений (обзор) // Труды Международного научно-технического конгресса «Интеллектуальные системы и информационные технологии-2020» («IS&IT'20»). Т.2. Таганрог: Изд-во Ступина С.А. 2020. с. 120–148.
6. *Feng J.* Is the integrate-and-fire model good enough a review // *Neural Networks*. 2001. vol. 14. no. 6. pp. 955–975.
7. *Gaier A., Ha. D.* Weight Agnostic Neural Networks // 33rd Conference on Neural Information Processing Systems (NeurIPS 2019). 2019. pp. 1–19.
8. *Kasabov N. K.* Evolving Connectionist Systems: The Knowledge Engineering Approach // London, Springer Science & Business Media. 2007. 451 p.
9. *Soltic S., Kasabov N. K.* Knowledge extraction from evolving spiking neural networks with rank order population coding // *International Journal of Neural Systems*. 2010. vol. 20. no. 06. pp. 437–445.

10. *Wysoski S. G., Benuskova L., Kasabov N.* Fast and adaptive network of spiking neurons for multi-view visual pattern recognition // *Neurocomputing*. 2008. vol. 71. no. 13. pp. 2563–2575.
11. *Wysoski S. G., Benuskova L., Kasabov N. K.* Evolving spiking neural networks for audiovisual information processing // *Neural Networks*. 2010. vol. 23. no. 7. pp. 819–835.
12. *Wysoski S. G., Benuskova L., Kasabov N.* On-Line Learning with Structural Adaptation in a Network of Spiking Neurons for Visual Pattern Recognition // *Artificial Neural Networks*. 2006. vol. 4131. pp. 61–70.
13. *Dhoble K., Nuntalid N., Indiveri G., Kasabov N.* Online spatio-temporal pattern recognition with evolving spiking neural networks utilising address event representation, rank order, and temporal spike learning // *The 2012 International Joint Conference on Neural Networks (IJCNN)*. 2012. pp. 1–7.
14. *Kasabov N. K., Dhoble K., Nuntalid N., Indiveri G.* Dynamic evolving spiking neural networks for on-line spatio- and spectro-temporal pattern recognition // *Neural Networks*. 2013. vol. 41. pp. 188–201.
15. *Wang J., Belatreche A., Maguire L., McGinnity T. M.* An online supervised learning method for spiking neural networks with adaptive structure // *Neurocomputing*. 2014. vol. 144. pp. 526–536.
16. *Wang J., Belatreche A., Maguire L. P., McGinnity T. M.* SpikeComp: An Evolving Spiking Neural Network with Adaptive Compact Structure for Pattern Classification // *Neural Information Processing*. 2015. vol. 9490. pp. 259–267.
17. *Wang J., Belatreche A., Maguire L. P., McGinnity T. M.* SpikeTemp: An Enhanced Rank-Order-Based Learning Approach for Spiking Neural Networks With Adaptive Structure // *IEEE Transactions on Neural Networks and Learning Systems*. 2017. vol. 28. no. 1. pp. 30–43.
18. *Belatreche A., Maguire L. P., McGinnity M.* Advances in Design and Application of Spiking Neural Networks // *Soft Computing*. 2017. vol. 3. no. 11. pp. 239–248.
19. *XinYao, Yong Liu, Guangming Lin.* Evolutionary programming made faster // *IEEE Transactions on Evolutionary Computation*. 1999. vol. 3. no. 2. pp. 82–102.
20. *Belatreche A., Paul R.* Dynamic cluster formation using populations of spiking neurons // *The 2012 International Joint Conference on Neural Networks (IJCNN)*. 2012. pp. 1–6.
21. *Dora, S., Subramanian, K., Suresh, S., Sundararajan, N.* Development of a Self-Regulating Evolving Spiking Neural Network for classification problem // *Neurocomputing*. 2016. vol. 171. pp. 1216–1229.
22. *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.
23. *Soltoggio A., Stanley K. O., Risi S.* Born to learn: The inspiration, progress, and future of evolved plastic artificial neural networks // *Neural Networks*. 2018. vol. 108. pp. 48–67.
24. *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.
25. *Асратян Э.А.* Учение академика И.П. Павлова о высшей нервной деятельности // Серия: Знание, Серия III №1 М.: Знание. 1956. 32 с.
26. *Кубарко, А. И.* Нормальная физиология. В 2 ч. Ч. 2: учебник / А. И. Кубарко, А. А. Семенович, В. А. Переверзев, Д. А. Александров, Л. М. Лобанок, А. Н. Харламов // Минск: Выш. шк. 2014. 604 с.
27. *Korsakov, A., Bakhshiev, A.* The Neuromorphic Model of the Human Visual System // *Studies in Computational Intelligence*. 2021. vol. 1452. pp. 339–346.
28. *Бахшиев А. В.* Библиотека средств разработки моделей нейронных сетей со сложной и динамически меняющейся архитектурой – NMSDK // *Нейроинформатика, ее приложения и анализ данных: материалы XVIII Всероссийского семинара*, 8–10

октября 2010 г. / под ред. А. Н. Горбаня, Е. М. Миркеца. ИВМ СО РАН. Красноярск. 2010. С. 26–30.

29. *Bakhshiev A. V., Fomin I. S., Gundelakh F. V., Demcheva A. A., Korsakov A. M.* The architecture of a software platform for growing spiking neural networks simulator developing // Journal of Physics: Conference Series. 2020. vol. 1679. pp. 042001.
30. *Bakhshiev A., Korsakov A., Stankevich L.* The hierarchical memory based on compartmental spiking neuron model // 13th International Conference on Artificial General Intelligence, AGI 2020. 2020. vol. 12711. pp. 34–43.

**Корсаков Антон Михайлович** — старший научный сотрудник, 913 лаборатория «Технологий искусственного интеллекта», ЦНИИ РТК. Область научных интересов: нейроморфные системы и спайковые нейронные сети, математические основы управления робототехническими системами, системы технического зрения. Число научных публикаций — 27. anton\_korsakov@mail.ru; Тихорецкий проспект, д. 21, г. Санкт-Петербург, 194064, РФ; м.т.: +7(911)7842747.

**Бахшиев Александр Валерьевич** — канд. техн. наук, доцент, высшая школа автоматизации и робототехники, ИММиТ, СПбПУ Петра Великого. 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 — 90. ralexab@gmail.com; ул. Политехническая, д.29, г. Санкт-Петербург, 195251; м.т.: +7(921)748-0010.

**Астапова Любовь Алексеевна** — студент-магистр, высшая школа автоматизации и робототехники, ИММиТ, СПбПУ Петра Великого, математик 2к, 913 лаборатория "Технологий искусственного интеллекта", ЦНИИ РТК. Область научных интересов: нейроморфные системы и спайковые нейронные сети, математические основы управления робототехническими системами, системы технического зрения. Число научных публикаций — 2. astapova.la@yandex.ru; Тихорецкий проспект, д. 21, г. Санкт-Петербург, 194064, РФ; м.т.: +7(812)7852931.

**Станкевич Лев Александрович** — канд. техн. наук, доцент, начальник отдела, отдел разработки ООО «АйБрей», ведущий научный сотрудник, ЦНИИ РТК. Область научных интересов: искусственный интеллект, когнитивные системы, антропоморфная робототехника, интерфейсы «мозг-компьютер». Число научных публикаций — 265. Stankevich\_lev@inbox.ru; РФ, г. Санкт-Петербург, Тихорецкий пр. 21, 194064, м.т.: +7(812)297-08-73.

**Поддержка исследований.** Работа проводилась в рамках выполнения в ЦНИИ РТК государственного задания Минобрнауки России на 2021 год: “Разработка и исследование новых архитектур реконфигурируемых растущих нейронных сетей, методов и алгоритмов их обучения”.

A. KORSAKOV, A. BAKHSHIEV, L. ASTAPOVA, L. STANKEVICH  
**BEHAVIORAL FUNCTIONS IMPLEMENTATION ON  
SPIKING NEURAL NETWORKS**

*Korsakov A., Bakhshiev A., Astapova L., Stankevich L.* **Behavioral Functions Implementation on Spiking Neural Networks.**

**Abstract.** The question of behavioral functions modeling of animals (in particular, the modeling and implementation of the conditioned reflex) is considered. The analysis of the current state of neural networks with the possibility of structural reconfiguration is carried out. The modeling is carried out by means of neural networks, which are built on the basis of a compartmental spiking model of a neuron with the possibility of structural adaptation to the input pulse pattern. The compartmental spike model of a neuron is able to change its structure (the size of the cell body, the number and length of dendrites, the number of synapses) depending on the incoming pulse pattern at its inputs. A brief description of the compartmental spiking model of a neuron is given, and its main features are noted in terms of the possibility of its structural reconfiguration. The method of structural adaptation of the compartmental spiking model of the neuron to the input pulse pattern is described. To study the work of the proposed model of a neuron in a network, the choice of a conditioned reflex as a special case of the formation of associative connections is justified as an example. The structural scheme and algorithm of formation of a conditioned reflex with both positive and negative reinforcement are described. The article presents a step-by-step description of experiments on the associative connection formation in general and conditioned reflex (both with positive and negative reinforcement), in particular. The conclusion is made about the prospects of using spiking compartmental models of neurons to improve the efficiency of the implementation of behavioral functions in neuromorphic control systems. Further promising directions for the development of neuromorphic systems based on spiking compartmental models of the neuron are considered.

**Keywords:** Neuromorphic Systems, Spike Neuron, Spike Neural Networks, Classical Conditioning, Associative Connections

**Korsakov Anton** — Senior Researcher, Laboratory of Artificial Intelligence Technologies, RTC. Research interests: neuromorphic systems and spike neural networks, mathematical foundations of robotic systems control, computer vision. The number of publications — 27. anton\_korsakov@mail.ru; 21 Tikhoretsky pr., Saint-Petersburg, 194064, Russia; phone +7(911)7842747.

**Bakhshiev Aleksandr** — Ph.D., Docent, 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 — 90. palexab@gmail.com; 29 Politechnicheskaya ul., Saint-Petersburg, 195251, Russia; office phone: +7(921)748-0010.

**Astapova Lyubov** — Student, Peter the Great St.Petersburg Polytechnic University (SPbPU), mathematician, Laboratory of Artificial Intelligence Technologies, RTC. Research interests: neuromorphic systems and spike neural networks, mathematical foundations of robotic systems control, computer vision. The number of publications — 2. astapova.la@yandex.ru; 21 Tikhoretsky pr., Saint-Petersburg, 194064, Russia; office phone: +7(981)7852931.

**Stankevich Lev** — Ph.D., Docent, Head of Development, Department of “AiBrain”, Senior researcher, Laboratory of Artificial Intelligence Technologies, RTC. Research interests: artificial intelligence, cognitive systems, anthropomorphic robotics, brain-computer interfaces.

The number of publications — 265. Stankevich\_lev@inbox.ru; 21 Tikhoretsky pr., Saint-Petersburg, 194064, Russia; phone: +7(812)297-08-73.

**Acknowledgements.** This work was done as the part of the state task of the Ministry of Education and Science of Russia for 2021 "Development and study of new architectures of reconfigurable growing neural networks, methods and algorithms for their learning".

## References

1. *Shrestha A., Mahmood A.* Review of deep learning algorithms and architectures // IEEE Access. Institute of Electrical and Electronics Engineers Inc. 2019. vol. 7. pp. 53040 - 53065.
2. *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.
3. *James C. D. et al.* A historical survey of algorithms and hardware architectures for neural-inspired and neuromorphic computing applications // Biologically Inspired Cognitive Architectures. 2017. vol. 19. pp. 49–64.
4. *Schuman C.D., Potok T.E.* A Survey of Neuromorphic Computing and Neural Networks in Hardware // arXiv preprint arXiv:1705.06963. 2017.
5. *Mel'nikov G.S., Mel'nikova Je.I., Samkov V.M.* Nejromorfnye sistemy analiza izobrazhenij (obzor) // Trudy Mezhdunarodnogo nauchno-tehnicheskogo kongressa «Intel'lectual'nye sistemy i informacionnye tehnologii-2020» («IS&IT'20»). T.2. Taganrog: Izd-vo Stupina S.A. 2020. pp. 120-148. (In Russ.).
6. *Feng J.* Is the integrate-and-fire model good enough a review // Neural Networks. 2001. vol. 14. no. 6. pp. 955–975.
7. *Gaier A., Ha. D.* Weight Agnostic Neural Networks // 33rd Conference on Neural Information Processing Systems (NeurIPS 2019). 2019. pp. 1–19.
8. *Kasabov N. K.* Evolving Connectionist Systems: The Knowledge Engineering Approach // London, Springer Science & Business Media. 2007. 451 p. *Soltic S., Kasabov N. K.* Knowledge extraction from evolving spiking neural networks with rank order population coding // International Journal of Neural Systems. 2010. vol. 20. no. 06. pp. 437–445.
9. *Wysoski S. G., Benuskova L., Kasabov N.* Fast and adaptive network of spiking neurons for multi-view visual pattern recognition // Neurocomputing. 2008. vol. 71. no. 13. pp. 2563–2575.
10. *Wysoski S. G., Benuskova L., Kasabov N. K.* Evolving spiking neural networks for audiovisual information processing // Neural Networks. 2010. vol. 23. no. 7. pp. 819–835.
11. *Wysoski S. G., Benuskova L., Kasabov N.* On-Line Learning with Structural Adaptation in a Network of Spiking Neurons for Visual Pattern Recognition // Artificial Neural Networks. 2006. vol. 4131. pp. 61–70.
12. *Dhoble K., Nuntalid N., Indiveri G., Kasabov N.* Online spatio-temporal pattern recognition with evolving spiking neural networks utilising address event representation, rank order, and temporal spike learning // The 2012 International Joint Conference on Neural Networks (IJCNN). 2012. pp. 1–7.
13. *Kasabov N. K., Dhoble K., Nuntalid N., Indiveri G.* Dynamic evolving spiking neural networks for on-line spatio- and spectro-temporal pattern recognition // Neural Networks. 2013. vol. 41. pp. 188–201.
14. *Wang J., Belatreche A., Maguire L., McGinnity T. M.* An online supervised learning method for spiking neural networks with adaptive structure // Neurocomputing. 2014. vol. 144. pp. 526–536.

15. Wang J., Belatreche A., Maguire L. P., McGinnity T. M. SpikeComp: An Evolving Spiking Neural Network with Adaptive Compact Structure for Pattern Classification // *Neural Information Processing*. 2015. vol. 9490. pp. 259–267.
16. Wang J., Belatreche A., Maguire L. P., McGinnity T. M. SpikeTemp: An Enhanced Rank-Order-Based Learning Approach for Spiking Neural Networks with Adaptive Structure // *IEEE Transactions on Neural Networks and Learning Systems*. 2017. vol. 28. no. 1. pp. 30–43.
17. Belatreche A., Maguire L. P., McGinnity M. Advances in Design and Application of Spiking Neural Networks // *Soft Computing*. 2017. vol. 3. no. 11. pp. 239–248.
18. XinYao, Yong Liu, Guangming Lin. Evolutionary programming made faster // *IEEE Transactions on Evolutionary Computation*. 1999. vol. 3. no. 2. pp. 82–102.
19. Belatreche A., Paul R. Dynamic cluster formation using populations of spiking neurons // *The 2012 International Joint Conference on Neural Networks (IJCNN)*. 2012. pp. 1–6.
20. Dora, S., Subramanian, K., Suresh, S., Sundararajan, N. Development of a Self-Regulating Evolving Spiking Neural Network for classification problem // *Neurocomputing*. 2016. vol. 171. pp. 1216–1229.
21. 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.
22. Soltoggio A., Stanley K. O., Risi S. Born to learn: The inspiration, progress, and future of evolved plastic artificial neural networks // *Neural Networks*. 2018. vol. 108. pp. 48–67.
23. 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.
24. Asratjan Je. A. Uchenie akademika I. P. Pavlova o vysshej nervnoj dejatel'nosti // *Seriya: Znanie, Seriya III №1 M.: Znanie*. 1956. 32 p. (In Russ.).
25. Kubarko, A. I. Normal'naja fiziologija. V 2 ch. Ch. 2: uchebnik / A. I. Kubarko, A. A. Semenovich, V. A. Pereverzev, D. A. Aleksandrov, L. M. Lobanok, A. N. Harlamov // *Minsk: Vysh. shk.* 2014. 604 p. (In Russ.).
26. Korsakov, A., Bakhshiev, A. The Neuromorphic Model of the Human Visual System // *Studies in Computational Intelligence*. 2021. vol. 1452. pp. 339–346.
27. Bakhshiev A. V. Biblioteka sredstv razrabotki modelej nejronnyh setej so slozhnoj i dinamičeski menjajushhejsja arhitekturoj – NMSDK // *Nejroinformatika, ee prilozhenija i analiz dannyh: materialy XVIII Vserossijskogo seminar, 8–10 oktjabrja 2010 g. / pod red. A. N. Gorbanja, E. M. Mirkesa. IVM SO RAN. Krasnojarsk*. 2010. pp. 26–30. (In Russ.).
28. Bakhshiev A. V., Fomin I. S., Gundelakh F. V., Demcheva A. A., Korsakov A. M. The architecture of a software platform for growing spiking neural networks simulator developing // *Journal of Physics: Conference Series*. 2020. vol. 1679. pp. 042001.
29. Bakhshiev A., Korsakov A., Stankevich L. The hierarchical memory based on compartmental spiking neuron model // *13th International Conference on Artificial General Intelligence, AGI 2020*. 2020. vol. 12711. pp. 34–43.