

В.Ю. ОСИПОВ
**ИНТЕЛЛЕКТУАЛЬНАЯ НЕЙРОСЕТЕВАЯ МАШИНА
С ФУНКЦИЯМИ МЫШЛЕНИЯ**

Осипов В.Ю. Интеллектуальная нейросетевая машина с функциями мышления.

Аннотация. В последние годы существенно вырос интерес к искусственному интеллекту на основе нейросетевых подходов. Получен ряд значимых научных результатов, которые нашли широкое применение на практике. Большое внимание привлекли генеративно – состязательные нейросетевые модели, нейросетевые трансформеры и другие решения. Достигнут очевидный прогресс в нейросетевом распознавании и генерации образов, обработке текстов и речи, прогнозировании событий, управлении трудно формализуемыми процессами. Однако пока не удалось наделять нейросетевые машины мышлением. Все получаемые с использованием нейросетевых машин результаты можно отнести к решениям на основе различных видов связывания сигналов без полноценного управления процессами их обработки. Типичными представителями таких машин выступают ChatGPT. Возможности по интеллектуальному оперированию различными сигналами в известных нейросетевых машинах очень ограничены. Среди основных причин таких ограничений следует выделить несовершенство используемых базовых принципов нейросетевой обработки информации. Свойства нейронов длительное время рассматривались упрощенно. Обуславливалось это, как пробелами в области биологических исследованиях, так и отсутствием возможностей построения больших нейронных сетей на сложных моделях нейронов. В последние годы ситуация изменилась. Появились новые способы реализации больших нейронных сетей. Также установлено, что даже отдельные нейроны могут обладать обширной внутренней памятью и реализовывать различные функции. Однако до сих пор многие механизмы функционирования нейронов и их взаимодействия остаются не раскрытыми. Мало исследованы вопросы управляемого ассоциативного обращения к внутренней памяти нейронов. Эти недостатки существенно сдерживает создание мыслящих нейросетевых машин. Объектом исследования в статье выступает процесс интеллектуальной нейросетевой обработки информации. Предмет исследования: принципы, модели и методы такой обработки. Преследуется цель расширения функциональных возможностей нейросетевых машин по решению трудно формализуемых творческих задач за счет разработки новых принципов, моделей и методов интеллектуальной обработки информации. В интересах достижения этой цели уточняются принципы функционирования интеллектуальных нейросетевых машин, предлагаются новые модели и методы нейросетевой обработки информации. Раскрывается новая модель импульсного нейрона, как базового элемента таких машин. Искусственный мозг нейросетевых машин рекомендуется формировать в виде многослойных нейронных сетей, наделенных логическими структурами, с различными по параметрам нейронами. Предлагается новый метод многоуровневой интеллектуальной обработки информации в нейросетевых машинах на основе умных импульсных нейронов. Поясняются механизмы мышления нейросетевых машин, лежащие в их основе функции интеллектуального оперирования образами и понятиями в нейросетевой памяти. Приводятся результаты моделирования, подтверждающие справедливость предложенных решений.

Ключевые слова: нейросетевая машина, интеллектуальность, функции мышления, умные нейроны, трансформация сигналов.

1. Введение. Впервые в широкой постановке вопрос о мышлении машин был поставлен Аланом Тьюрингом [1]. Однако до сих пор идут споры: может ли машина мыслить? Известно много определений понятия «мышление» [2]. Применительно к человеку это высшая ступень познания, процесс отражения в мозгу окружающего реального мира. Он основан на психофизических механизмах обучения и непрерывного пополнения запаса понятий, представлений и вывода новых суждений и умозаключений. В другой трактовке мышление можно рассматривать, как способность отражать в мозгу реальный мир и взаимодействие с ним, а также производить интеллектуальные операции с сигналами, образами и понятиями. Применительно к интеллектуальным нейросетевым машинам предлагается придерживаться последнего определения. Мышление машин согласно [3] относится к способности их имитировать когнитивные процессы человека, включая восприятие, рассуждения, принятие решений и решение проблем. Если можно смоделировать эти процессы, то допустимо говорить о наделении интеллектуальных нейросетевых машин функциями мышления (операциями различных видов анализа и синтеза сигналов). Под такими машинами будем понимать, прежде всего, абстрактные конструкции, которые могут реализовываться программными и аппаратными способами. Допустим, что отражение реального мира в искусственном мозгу машины осуществимо путем ее непрерывного обучения. Однако это обучение должно обладать широкими возможностями, включая кодирование и запоминание больших объемов информации с реализацией последующего извлечения из памяти интересующих событий. Известные решения [4, 5] пока не обеспечивают результатов, сравнимых с биологическими системами. Нет однозначного взгляда на то, как должна кодироваться информация в памяти интеллектуальных нейросетевых машин. Количество запоминаемой информации существующими нейронными сетями невелико [6]. Что касается осуществления в нейросетевой машине интеллектуальных операций, то здесь много темных пятен. Разработан ряд нейросетевых машин [3, 7, 8], реализующих интеллектуальные операции на основе заложенных в них правил. Однако их можно считать интеллектуальными лишь в узком плане [9, 10]. Известные нейросетевые машины ориентированы на решение только отдельных задач. Среди них фильтрация сигналов, распознавание, прогнозирование и восстановление событий, управление объектами и другие [6]. Ни одна из существующих нейросетевых машин без изменения структуры не способна полноценно обрабатывать широкий

спектр творческих задач. Одна из причин такого состояния – это несовершенство принципов функционирования нейросетевых машин. Они далеки от принципов, свойственных биологическим объектам [4, 5]. Положенные в их основу нейросетевые решения имеют существенные ограничения, как по одноуровневой, так и многоуровневой интеллектуальной обработке сигналов. Во многих случаях применяемые в интеллектуальных машинах нейронные сети рассматривают как черные ящики. Лишь в последние годы удалось наделять нейронные сети прозрачными логическими структурами [11]. Несмотря на это, проблемными остаются аспекты многоуровневой ассоциативной обработки потоков сигналов в рекуррентных нейронных сетях (РНС), составляющих основу интеллектуальных нейросетевых машин. Без такой обработки нет возможности переходить в нейросетевой машине от элементарных сигналов к образам и понятиям, а также возвращаться назад. К известным моделям и методам многоуровневой ассоциативной обработки сигналов в РНС можно отнести:

- иерархическую временную память (ИВП) и корковые алгоритмы обучения;
- рекуррентные сверточные нейронные сети и родственные методы;
- иерархические рекуррентные гибридные нейросетевые модели;
- многоуровневые потоковые РНС с управляемыми элементами и методы обработки информации в них.

Наиболее полный обзор и развитие идей ИВП был представлен в [12]. Основными функциями ИВП являются обучение, распознавание и прогнозирование. Особенности ИВП заключаются в наличии регионов, организованных по иерархическому принципу. Нейроны (клетки) каждой области объединены в двумерный (2D) массив столбцов. Каждый нейрон характеризуется прямыми и горизонтальными дендритами, что обеспечивает взаимодействие нейронов как внутри областей, так и между различными областями. Недостатки ИВП и связанных с ним методов обработки сигналов заключаются в следующем. Модель не подходит для обработки непрерывных потоков сигналов. Сеть ИВП представляет собой самоорганизующуюся структуру и требует достаточно много времени в части обработки входных сигналов. Функции и возможности сети и ее элементов по интеллектуальной обработке информации весьма ограничены. Не предусмотрено управление обработкой сигналов как

внутри регионов, так и между ними. Синапсы имеют только двоичный вес.

Общее описание рекуррентных сверточных нейронных сетей и методов обработки информации в них можно найти в [13, 14]. Эти сети могут использовать разные архитектуры, типичные как для традиционных сверточных сетей [13], так и для капсульных моделей [14]. У этих архитектур есть общая особенность, например, наличие хотя бы одного сверточного слоя. В общем, рекуррентные сверточные нейронные сети включают восходящие, нисходящие и горизонтальные связи. К недостаткам рекуррентных сверточных нейронных сетей с учетом ряда снятых ограничений капсульными моделями можно отнести их узкую специализацию, направленную исключительно на распознавание образов, а также трудности реализации и обучения.

Иерархические рекуррентные гибридные модели нейронных сетей представляют собой комбинированные структуры нейронных сетей с восходящей, нисходящей и продольной обработкой сигналов. Как правило, эти модели предназначены для распознавания, машинного перевода речи и прогнозирования событий. Они состоят из рекуррентных и нейронных сетей прямого распространения. Долгая краткосрочная память [15–17], самоорганизующиеся карты [6], структуры теории адаптивного резонанса [18] и другие нейронные сети могут служить конструкциями для этих моделей [19–21]. Проводятся исследования, направленные на придание комбинированным структурам нейронных сетей большей динамики [22, 23]. К недостаткам иерархических рекуррентных гибридных моделей нейронных сетей относятся: ограниченный функционал, несовершенство правил ассоциативной многоуровневой обработки сигналов; малый объем памяти; проблемы с обучением.

Сети с управляемыми элементами можно выделить в отдельный вид многоуровневых рекуррентных нейронных сетей [11], на основе которых осуществимо создание интеллектуальных нейросетевых машин. Эти потоковые сети применимы как для оперативной, так и для глубокой обработки информации, генерации новых сигналов [24, 25, 26]. В зависимости от вариантов ввода сигналов в РНС можно решать различные творческие задачи. Многоуровневая ассоциативная обработка сигналов в таких сетях реализуется по слоям. Эти РНС основаны на идеях, отраженных в [27]. В РНС используются импульсные нейроны. Время рефрактерности после их возбуждения превышает время задержки сигналов в образуемых двухслойных контурах сети. За счет приоритета сильных связей в РНС

обеспечивается однозначное соответствие между элементами входов и выходов сети. Эти РНС способны управлять ассоциативным взаимодействием сигналов в зависимости от текущих состояний сетей. К недостаткам потоковых РНС и методов обработки сигналов относятся следующие. Это низкоуровневая обработка сигналов в каждой из сигнальных систем, что приводит к увеличению объема памяти и затратам времени. Имеются трудности ассоциативной обработки в РНС информации о времени возникновения событий различного масштаба. Как и в других РНС существенно ограничены возможности базовых элементов – нейронов. На низком уровне обработки все прозрачно, можно оперировать в РНС прошлым, настоящим и будущим временем. Однако для перехода к логическим уровням обработки различных временных масштабов, интервалов и нечетких значений времени необходимо дальнейшее развитие теории и методов связывания сигналов в РНС.

В работе [28] сформулирована принципиальная идея расширенной многоуровневой обработки сигналов в интеллектуальных нейросетевых машинах на основе РНС с управляемыми элементами. Однако она требует дальнейшего развития. Идея обращена к поиску подходящих методов управляемого связывания пространственно-временных сигналов в РНС на различных уровнях иерархии. Подобные методы должны не только расширить память и сократить затраты времени на обработку сигналов в РНС, но и повысить возможности моделирования творческой деятельности человека. В интересах этого необходимо развить принципы интеллектуальной нейросетевой обработки информации и пересмотреть взгляды на функционирование искусственных нейронов и их взаимодействие.

В последние годы уделяется повышенное внимание к устранению несовершенства моделей нейронов, используемых в нейросетевых машинах [29, 30]. Исследователи стремятся, чтобы нейроны более полно учитывали информацию о пространственно-временных характеристиках обрабатываемых сигналов. Были предприняты некоторые усилия по изучению передачи пространственной информации о входных сигналах на выходы нейронов [29 – 33]. Предложены решения [30], позволяющие с помощью векторных нейронов реализовывать вращения обрабатываемых образов, но без управляемого ассоциативного вызова сигналов из памяти нейронных сетей. В [32] рассмотрены нейроны с большим объемом внутренней памяти на микротрубочках, формализуемых мемристорами. Однако пока не взглянули на нейроны,

как на полноценные ассоциативные процессоры. Несовершенство базовых элементов (нейронов) нейросетевых машин не позволяет сделать прорыв в наделении этих машин полноценным искусственным интеллектом. Требуется поиск новых идей, моделей, методов и технологий их реализации.

2. Принципы функционирования ИНМ. Опираясь на результаты биологических исследований [3, 4, 29, 32 – 34], предлагаются следующие принципы функционирования интеллектуальной нейросетевой машины (ИНМ). На входы искусственного мозга ИНМ должны подаваться одновременно не только сигналы внешнего мира, но и формируемые управляющие воздействия. Это позволяет связывать в мозгу ИНМ все эти сигналы, и обеспечивать формирование в нем модели окружающего мира и взаимодействие с ним самой машины. Перед подачей всех сигналов на вход искусственного мозга ИНМ они должны быть приведены к «языку», воспринимаемому его нейронной сетью. Эти сигналы представимы в виде последовательных совокупностей единичных импульсов (СЕИ), несущих всю информацию об исходных воздействиях. В интересах этого сигналы могут раскладываться на пространственно-частотные, пространственно-химические, пространственно-тактильные и другие составляющие. Каждая составляющая может преобразовываться в последовательность единичных импульсов с частотой и фазой, как функциями от амплитуды и фазы составляющей. В дискретном времени эти последовательности могут представляться в виде следующих друг за другом совокупностей единичных импульсов.

Искусственный мозг ИНМ должен быть биоподобным, устойчиво функционировать в условиях ограничений потребляемой энергии. Он должен формироваться с использованием многослойных управляемых рекуррентных нейронных сетей с прозрачной логической организацией, с возможностью реализации многоуровневой ассоциативной обработки информации. Обрабатываемые в РНС СЕИ должны продвигаться как между слоями, так и вдоль их. В искусственном мозгу ИНМ должна присутствовать возможность перехода от обработки СЕИ на нижних уровнях к обработке на верхних уровнях и наоборот.

ИНМ должна мысленно оперировать различными сигналами, образами и понятиями, а также временем. Эти операции должны отражать возможные действия над реальными объектами. К таким действиям можно отнести их перемещения (сдвиги), повороты, приближения и удаления, перестановку местами, дополнение

конструктивными элементами и другие. Оперирование временем предусматривает сдвиги точек отсчета, ускорение, замедление, изменение масштаба, запоминание и сравнение интервалов, другие операции.

В искусственном мозгу ИНМ должны присутствовать механизмы управления его деятельностью, обусловленные некоторыми мотивами. Основой их на самом нижнем уровне могут выступать минимальные расходы энергии при устранении раздражителей, а на верхнем уровне – минимизация информационных противоречий. Заметим, что информационные противоречия в РНС на физическом уровне проявляются в конфликтах между нейронами.

Для обеспечения всех этих возможностей нейроны искусственного мозга ИНМ должны обладать существенно расширенными функциями, чем известные модели. Они должны в широких пределах трансформировать различные распределения сигналов на входах в другие распределения на выходах с учетом управляющих воздействий и состояния внутренней памяти. При этом внутренняя память нейронов должна быть существенно больше памяти на их синапсах [35].

3. Умные нейроны как базовые элементы ИНМ. Поясним принципы функционирования ИНМ, начиная с рассмотрения новых моделей импульсных нейронов, как базовых элементов искусственного мозга рассматриваемой машины. В отличие от известных моделей в умном импульсном нейроне предусматривается учет, откуда и какие сигналы поступили на его входы. Полагается, что каждое индивидуальное воздействие на нейрон поступает на отдельный пространственно соотнесенный вход. Такая пространственная развязка в биологических нейронах реализуема, прежде всего, дендритами. При подаче сигнала на отдельный вход токи распределяются по поверхности нейрона с ослаблением. В случае нескольких сигналов, воздействующих на привязанные к ним пространственно соотнесенные входы нейрона, на его поверхности формируются совместные распределения токов. В зависимости от характеристик этих сигналов и пространственных параметров задействованных входов нейрона, эти распределения будут иметь различные пространственно соотнесенные максимальные значения. Таким образом, для каждого варианта входных сигналов можно поставить в соответствие некоторую пространственную точку максимального приложения сигналов к нейрону. В случае превышения током в этой точке порога возбуждения нейрона формируется единичный заряд, который распределяется по синапсам с учетом точки

начала возбуждения и внутренней памяти нейрона. Полагается, что от каждой пространственной точки начала возбуждения нейрона через его тело и аксон до синапсов существуют свои пути переноса зарядов. Этим путям, микротрубочкам [32], свойственны свои проводимости, изменяемые в зависимости от перенесенных по ним зарядов. Опираясь на эти положения, можно утверждать, что каждому варианту входных сигналов будет соответствовать на выходе обученного умного нейрона свой вариант сигналов. Таким образом, даже отдельно взятый умный нейрон может однозначно трансформировать одни входные сигналы в другие. В частности, каждый умный нейрон может успешно реализовывать не только операции, связанные со сдвигами, поворотами и другими действиями над сигналами, но и с операциями, эквивалентными математическим действиям (сложением, умножением, делением, возведением в степень, логарифмированием и другими). В рассматриваемом случае происходят трансформации одних сигналов в другие в зависимости от управляющих воздействий. Заметим, что входные сигналы умного нейрона можно разделить на информационные и управляющие воздействия (рисунок 1(а, б)).

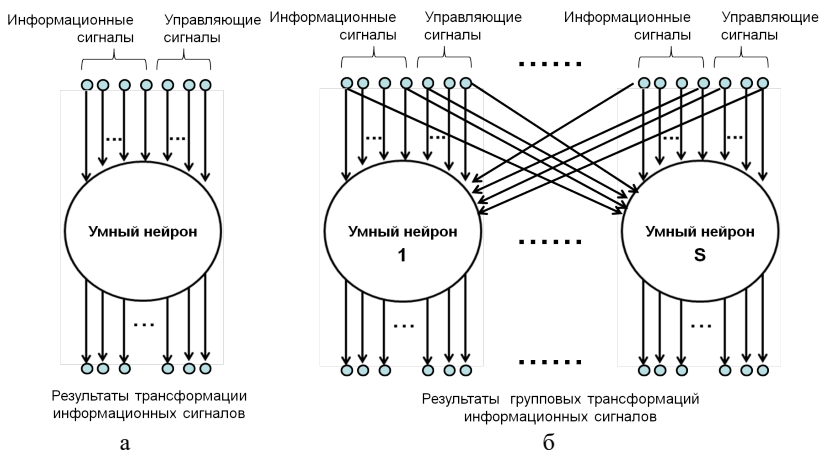


Рис. 1. Представление умных нейронов с: а) индивидуальной и б) групповой трансформацией сигналов

Изменяя только управляющие воздействия, можно одни и те же информационные сигналы преобразовывать в другие сигналы и запоминать результаты обработки. Эти умные нейроны можно рассматривать как полноценные ассоциативные процессоры с внутренней памятью, способные обращаться к ней по содержанию

входных сигналов новым способом. Число вариантов трансформации сигналов у каждого такого процессора может быть свое в зависимости от полученного опыта, результатов обучения. Группа параллельно функционирующих нейронов может реализовывать различные групповые трансформации (рисунок 1(б)), результаты их в дальнейшем могут подвергаться другим преобразованиям, в том числе рекуррентным трансформациям. Полноценное обращение к памяти по содержанию входных сигналов позволяет переходить к осмысленной обработке информации, в том числе оперировать смыслами и модельным временем.

С формальной точки зрения возбуждение j -го «умного» нейрона на момент времени t осуществимо, если ток $i_j(x_o, y_o, t)$, приложенный к точке его «тела» с координатами (x_o, y_o) больше или равен пороговому току $I_{jd}(x_o, y_o, t)$ возбуждения, $i_j(x_o, y_o, t) \geq I_{jd}(x_o, y_o, t)$, и время $t_j(t)$ после предыдущего возбуждения больше или равно времени T_r невосприимчивости нейрона после срабатывания, $t_j(t) \geq T_r$. Значение $i_j(x_o, y_o, t)$ и координаты (x_o, y_o) предлагается определять согласно (1):

$$i_j(x_o, y_o, t) = \max_{x, y \in \Omega} \sum_{z=1}^N i_{zj}(x, y, m_{x_{zj}}, m_{y_{zj}}, t), \quad (1)$$

где N – число воздействующих на j -й нейрон z -х нейронов, равное числу входных сигналов; $i_{zj}(x, y, m_{x_{zj}}, m_{y_{zj}}, t)$ – значение тока от z -го нейрона на поверхности j -го нейрона в точке с координатами x, y ; $m_{x_{zj}}, m_{y_{zj}}$ координаты точки приложения сигнала от z -го нейрона к j -му нейрону; Ω – множество возможных точек приложения сигналов к нейрону.

При возбуждении умного нейрона относительно точки (x_o, y_o) осуществляется свое распределение сгенерированного заряда по его внутренним каналам с учетом их проводимостей и проводимостей синапсов, а также состояний принимающих нейронов. Формируется вектор выходных сигналов. В зависимости от перенесенных по внутренним каналам и синапсам зарядов изменяются их проводимости, запоминаются результаты обработки информации нейроном.

При реализации памяти нейронов на мемристорах проводимости (веса) $w_{km}(t) = w_{km}(x_o, y_o, t)$ цепей передачи сигналов с k -го входа памяти на m -е выходы можно рассчитать как (2):

$$w_{km}(t) = 1 / (R_{ON_{km}}(t) + (R_{OFF_{km}}(t) - R_{ON_{km}}(t)) \cdot \exp(-A \cdot (q_{km}(t - \Delta t) + q_{km}(\Delta t))), \quad (2)$$

где $R_{ON_{km}}(t)$, $R_{OFF_{km}}(t)$ – наименьшее и наибольшее сопротивления мемристорной km цепи, $R_{ON_{km}}(t) = R_{ON} / \psi_{km}(t)$, $R_{OFF_{km}}(t) = R_{OFF} / \psi_{km}(t)$; A – коэффициент размерностью 1/кулон; $q_{km}(t - \Delta t)$ – заряд, переданный через km цепь на момент $t - \Delta t$; $q_{km}(\Delta t)$ – заряд, переданный за интервал времени Δt . Функция $\psi_{km}(t)$, от которой зависят $R_{ON_{km}}(t)$ и $R_{OFF_{km}}(t)$, может определяться согласно [11].

Значения переносимых по цепям зарядов вычисляются как (3):

$$q_{km}(t) = \int_{t_0}^t u_k(\tau) \cdot (1 - u_m(\tau) / u_k(\tau)) \cdot w_{km}(\tau) d\tau, \quad (3)$$

$u_k(\tau)$ – напряжение на выходе возбужденного k -го нейрона в момент времени τ ; $u_m(\tau)$ – текущее напряжение на входе m -го нейрона; $w_{km}(\tau)$ – проводимость (вес) km цепи.

Заметим, что при выделении только одной пространственно соотнесенной точки начала возбуждения нейрона, удовлетворяющей условию (1) и $i_j(x_o, y_o, t) \geq I_{jd}(x_o, y_o, t)$, в зависимости от ее координат возможно M вариантов распределения сигналов на выходе при одном и том же состоянии внутренней памяти. В случаях, когда может выделяться не одна, а до K локальных точек со своими максимумами токов, способных возбудить нейрон, ситуация иная. Число возможных вариантов распределения сигналов на выходе существенно возрастает и равно (4):

$$C_{\Sigma} = \sum_{k=1}^K \frac{M!}{k!(M-k)!}, \quad (4)$$

где M – число всех возможных точек возбуждения нейрона; $!$ – знак факториала; k – число точек, одновременно удовлетворяющих

условиям возбуждения нейрона, $k \leq K \leq M$. Это хорошо согласуется с результатами исследований [36], согласно которым биологический нейрон функционирует как множество независимых пороговых элементов.

Дополнительно отметим следующее. При обработке сигналов сетями умных нейронов также могут реализовываться пространственные сдвиги сигналов при передаче их от слоя к слою. За счет этого исключаются конфликты между возбужденными нейронами и нейронами, находящимися в состояниях невосприимчивости. За счет этих сдвигов нейронные сети могут наделяться логическими структурами. Особенности функционирования таких нейронных сетей рассмотрим в следующем разделе.

4. Структура искусственного мозга ИНМ и метод многоуровневой обработки информации. В качестве базовой рекуррентной нейронной сети для построения искусственного мозга ИНМ применима двухслойная сеть с управляемыми элементами и обратными связями, замыкающими контуры со временем задержки единичных импульсов меньше времени невосприимчивости нейронов сети после их возбуждения [11]. Обобщенная схема этой РНС приведена на рисунке 2(а). Эта РНС является своеобразным конструктором, позволяющим формировать различные варианты других структур нейронных сетей. В РНС предусматриваются пространственные сдвиги СЕИ при передаче от слоя к слою. За счет этих сдвигов РНС может наделяться различными одно- и многоуровневыми логическими структурами (линейными, спиральными, петлевыми и другими), а СЕИ продвигаются не только между слоями, но и вдоль них. Один из простых примеров одноуровневой логической структуры РНС приведен на рисунке 2(б). В рассматриваемом случае на вход этой сети подаются СЕИ, несущие информацию как о внешнем мире, так об управляющих воздействиях. Если после обучения сети со структурой на рисунке 2(б) усилить ассоциативный вызов сигналов в направлении ее входа, она будет последовательно вызывать из памяти связанные события.




Рис. 2. Рекуррентная нейронная сеть с управляемыми элементами:
 а) обобщенная схема; б) пример логической структуры (1, 3 – направления продвижения СЕИ вдоль и между слоями; 2 – линии разбивки слоев на логические поля за счет реализуемых пространственных сдвигов СЕИ; 4 – нейроны)

Заметим, что логическую структуру РНС на рисунке 2(б) можно представить также в однослойном варианте (рисунок 3(а)), а с помощью его осуществимо формирование многослойной РНС (искусственного мозга) с многоуровневой обработкой информации (рисунок 3(б)). В соответствии с рисунком 3(б) в РНС выделяются «кортикальные колонки». Они формируются, прежде всего, за счет многоуровневых пространственных сдвигов сигналов вдоль слоев.




Рис. 3. Варианты логических структур РНС с а) одноуровневой и б) многоуровневой обработкой сигналов: 1 – границы «кортикальных колонок»

С учетом этих сдвигов многоуровневая обработка сигналов возможна согласно методу, основу которого составляет способ [28]:

А.1. Сигнал поступает в РНС, где на каждом $k + 1$ ($k = 0, 1, \dots, K-1$) уровне обработки пороги возбуждения нейронов и амплитуды генерируемых ими единичных импульсов больше их значения на k -м уровне.

А.2. При обработке единичных импульсов каждый нейрон определяет пространственно-энергетические характеристики этих импульсов.

А.3. Когда нейрон возбужден, информация об этих характеристиках сохраняется. Она учитывается при распределении нейроном сгенерированного импульса по синапсам, соединяющим его с принимающими нейронами.

А.4. В РНС пересекающиеся выборки из последовательности СЕИ k -го уровня преобразуются в СЕИ $k + 1$ уровня. Длина этих выборок на каждом k -м уровне выбирается больше, чем реализованные пространственные сдвиги СЕИ при передаче с уровня на уровень.

А.5. Каждая СЕИ $k + 1$ уровня связывается с соответствующей выборкой k -го уровня.

А.6. Дополнительно сформированные СЕИ на уровне $k+1$ обрабатываются аналогично обработке СЕИ на k -м уровне и связываются в пространстве и времени посредством запоминания связей на элементах сети.

А.7. Эти связи используются для извлечения сигналов из памяти РНС.

А.8. Обработанные в нейронной сети СЕИ уровня $k+1$ преобразуются обратно в соответствующие объединенные выборки СЕИ k -го уровня.

А.9. Эти выборки используются для формирования результатов обработки сигналов в РНС.

Согласно А.1, за счет повышенных порогов возбуждения нейронов на уровне $k+1$ по сравнению с k -м уровнем физически можно осуществлять пространственно-временное компрессионное кодирование выборок из последовательностей СЕИ. СЕИ, сформированные на уровне $k+1$, продвигаются по сети синхронно с СЕИ k -го уровня, между ними формируются и сохраняются обратные связи. Однако для того, чтобы СЕИ $k+1$ уровней смогли восстановить соответствующие выборки на k -м уровне, необходимо выполнение следующего условия. Требуется наличие нейронов уровня $k+1$ с более высокими амплитудами генерируемых выходных импульсов, чем у нейронов уровня k . Это вполне согласуется с наличием в биологическом мозгу слоев нейронов со своими характеристиками порогов возбуждения и формируемых импульсов.

В целом поданные в РНС последовательные СЕИ представляются в виде других последовательных СЕИ в соответствии с предварительно заданными правилами связывания и трансформации с учетом обратных

результатов. Результаты связывания и трансформации запоминаются на элементах сети. При этом в РНС преобразование одних последовательных СЕИ в другие осуществляется путем трансформации их нейронами в зависимости от результатов связывания входных единичных образов и состояний нейронов. В качестве результатов обработки используются управляющие СЕИ на выходе РНС после обратного преобразования в соответствующие им исходные сигналы. Предлагаемый метод можно пояснить схемой обработки сигналов, приведенной на рисунке 4. Согласно этой схеме за счет реализуемых в РНС пространственных сдвигов сигналов при передаче от слоя к слою СЕИ на всех уровнях продвигаются синхронно слева направо. При восходящем преобразовании СЕИ формируются также связи, обеспечивающие возможность обратной трансформации. Как в РНС с обычными импульсными нейронами, так и в РНС с умными нейронами, учитывается приоритетность сильных связей, сохраняющих логическую структуру сетей. Однако при использовании умных нейронов их состояния на каждый момент времени характеризуются не скалярами, а векторами. Кроме этого в РНС на умных нейронах помимо расширенных возможностей по трансформации и запоминанию сигналов, присутствуют возможности по управлению переходами с одного уровня на другой в зависимости от содержания обрабатываемой информации.

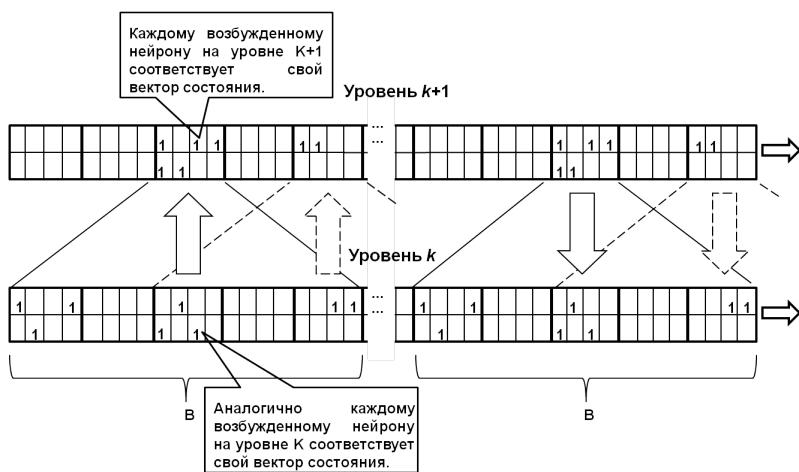


Рис. 4. Схема преобразования в РНС пересекающихся выборок из последовательности СЕИ k -го уровня в последовательность СЕИ $k+1$ уровня и наоборот: В – длина сворачиваемых (разворачиваемых) выборок; 1 – признак возбужденного умного нейрона

Присутствует также возможность временного отрыва высокоуровневой обработки сигналов от обработки на нижних уровнях. Это позволяет на высоких уровнях решать творческие задачи без прерывания обработки на нижних уровнях.

5. Механизмы мышления ИНМ. Поясним возможные механизмы мышления ИНМ на примере ее обобщенной структуры, показанной на рисунке 5, где $D1/\mathcal{E}1, \dots, Dn/\mathcal{E}n$ – управляемые датчики (Д) информации, совмещенные с эффекторами (Э); $1, \dots, 2n-1$ – информационные сигналы с датчиков; $2, \dots, 2n$ – сигналы о состоянии датчиков, совмещенных с эффекторами.

Согласно рисунку 5 предусматривается преобразование различных видов сигналов внешнего мира в информационные последовательные совокупности единичных импульсов (СЕИ) с учетом управляющих СЕИ с выхода сети. Такое преобразование реализуется в блоках Д/Э. Также в этих блоках сигналы об их состоянии перед подачей в РНС преобразуются в дополнительные последовательные СЕИ. В зависимости от управляющих воздействий на блоки Д/Э могут восприниматься различные информационные сигналы.

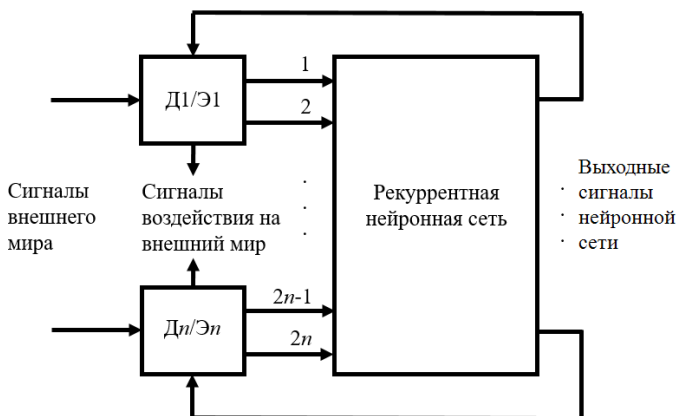


Рис. 5. Обобщенная структура интеллектуальной нейросетевой машины

Сигналы внешнего мира относительно ИНМ могут сдвигаться в пространстве и во времени, поворачиваться, изменяться по частотам и фазам, другим параметрам. От управляющих воздействий может изменяться положение и характеристики самих датчиков, совмещенных с эффекторами, а также самой ИНМ. Управление датчиками информации может быть осуществимо сначала путем

слежения за сигналами внешнего мира, их поведением, а в дальнейшем, согласно правилам сканирования пространства, в интересах преследуемых целей.

Для дальнейших пояснений принципов мышления ИНМ рассмотрим с учетом рисунков 2(б) и 5 одноуровневую обработку пары последовательностей СЕИ на канальном уровне РНС (рисунок 6).




Рис. 6. Вариант логической структуры РНС на канальном уровне: 1 – каналы продвижения по сети СЕИ; 2 – управляемые ассоциативные взаимодействия СЕИ и отдельных импульсов

Обозначим поступающие в РНС информационные последовательные СЕИ как SSP^a , а последовательные СЕИ, отражающие результаты управляющих воздействий на датчики, совмещенные с эффекторами, в виде SSP^c . Связывание этих двух последовательностей СЕИ в РНС можно представить в виде (5):

$$\left\{ \begin{array}{l} SSP^c \\ \otimes \\ SSP^a \end{array} \right\} = \left\{ \begin{array}{l} SSP_1^c, SSP_2^c, \dots, SSP_n^c \\ \otimes \otimes \otimes \otimes \otimes \\ SSP_1^a, SSP_2^a, \dots, SSP_n^a \end{array} \right\}, \quad (5)$$

где \otimes – знаки связывания обрабатываемых совокупностей единичных импульсов. При простом обучении $SSP_1^a, SSP_2^a, \dots, SSP_n^a$ и $SSP_1^c, SSP_2^c, \dots, SSP_n^c$ связываются друг с другом при продвижении по

сети. Совокупностям $SSP_1^c, SSP_2^c, \dots, SSP_n^c$ единичных импульсов в сети ставятся в соответствие информационные СЕИ, обозначенные как $SSP_1^a, SSP_2^a, \dots, SSP_n^a$. Заметим, что на начальном этапе формирование управляющих воздействий на блоки Д/Э нейросетевой машины осуществляется из информационных СЕИ. Нейросетевая машина учится отслеживать изменения сигналов внешнего мира. Например, при смещении или повороте наблюдаемого машиной объекта для отслеживания его действий изменяются положение датчиков, с помощью которых объект воспринимается. Устанавливается однозначное соответствие между изменениями сигналов внешнего мира и воздействиями на блоки Д/Э. После такого обучения, если кратковременно прервать поступление в РНС информационных СЕИ, но оставить воздействия $SSP_1^c, SSP_2^c, \dots, SSP_i^c, SSP_{i+1}^c, SSP_{i+2}^c, \dots, SSP_n^c$, то состояние сети до момента ассоциативного вызова из ассоциативной памяти недостающих информационных СЕИ представимо в виде (6):

$$\left\{ \begin{array}{l} SSP_1^c, SSP_2^c, \dots, SSP_i^c, SSP_{i+1}^c, SSP_{i+2}^c, \dots, SSP_n^c \\ \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \\ \emptyset, \emptyset, \dots, \emptyset, SSP_{i+1}^a, SSP_{i+2}^a, \dots, SSP_n^a \end{array} \right\}, \quad (6)$$

\emptyset – знаки пустых множеств (пустых СЕИ).

После ассоциативного вызова сигналов из памяти РНС с трансформацией из одной формы в другую, в зависимости от управляющих $SSP_1^c, SSP_2^c, \dots, SSP_i^c$, получаем (7):

$$\left\{ \begin{array}{l} SSP_1^c, SSP_2^c, \dots, SSP_i^c, SSP_{i+1}^c, SSP_{i+2}^c, \dots, SSP_n^c \\ \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \\ SSP_1^b, SSP_2^b, \dots, SSP_i^b, SSP_{i+1}^a, SSP_{i+2}^a, \dots, SSP_n^a \end{array} \right\}, \quad (7)$$

где $SSP_1^b, SSP_2^b, \dots, SSP_i^b$ – результат обработки. Формируя разные виды управляющих $SSP_1^c, SSP_2^c, \dots, SSP_i^c$, при обрабатываемых $SSP_{i+1}^a, SSP_{i+2}^a, \dots, SSP_n^a$, можно не только вызывать из памяти связанные сигналы, но и осуществлять интеллектуальное

оперирование ими в памяти, эквивалентное обработке в управляемых датчиках, совмещенных с эффекторами, и реальным действиям. Следует отметить, что управляющие воздействия могут формироваться также с преследованием других целей обработки информации в РНС. На самом низком уровне в качестве таких целей может выступать минимизация расходов энергии на поддержание устойчивого функционирования сети при внешних воздействиях.

Для случая, когда все входы РНС закрыты, но в сети обрабатываются поступившие сигналы, имеет место состояние (8):

$$\left\{ \begin{array}{l} \emptyset, \emptyset, \dots, \emptyset, \quad SSP_{i+1}^c, SSP_{i+2}^c, \dots, SSP_n^c \\ \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \otimes \\ \emptyset, \emptyset, \dots, \emptyset, \quad SSP_{i+1}^a, SSP_{i+2}^a, \dots, SSP_n^a \end{array} \right\}. \quad (8)$$

Относительно этого состояния в обученной сети могут вызываться из памяти как информационные, так и СЕИ, отражающие результаты управляющих воздействий на датчики, совмещенные с эффекторами. Они могут продолжать последовательности $SSP_{i+1}^c, SSP_{i+2}^c, \dots, SSP_n^c$ и $SSP_{i+1}^a, SSP_{i+2}^a, \dots, SSP_n^a$. Аналогичным образом в памяти РНС осуществимо воспроизведение предшествующих сигналов с возможностью интеллектуального оперирования ими в зависимости от управляющих воздействий.

Рассмотрим теперь механизмы мышления искусственного мозга, связанные с операциями над временем. Ответим на вопросы, как можно ускорять, или замедлять время обработки событий в искусственном мозгу при условии, что передача сигналов внутри РНС осуществляется с одной и той же скоростью.

Чтобы ответить на эти вопросы вернемся к совместной обработке сигналов внешнего мира от датчиков и о состояниях последних, отражающих результаты управляющих воздействий. При отслеживании сигналов внешнего мира, изменяющихся с различной скоростью, можно получать соответствующие им результаты управляющих воздействий. При последующем вызове ими с различной скоростью информационных сигналов (в виде СЕИ) из ассоциативной памяти РНС осуществимо ускорение или замедление обработки событий. Изменение скорости такого вызова эквивалентно сжатию или растяжению последовательностей управляющих СЕИ. Формируя управляющие воздействия в сжатом виде, и осуществляя ими

ассоциативный вызов сигналов из памяти в направлении входа или выхода сети, можно оперативно обращаться к будущему или прошлому.

Учитывая это, можно утверждать, что предлагаемая интеллектуальная нейросетевая машина обладает смоделированными функциями мышления. Она способна реализовывать интеллектуальные операции в своей памяти над различными СЕИ, образами и понятиями, а также над временем.

Для того чтобы эта машина могла успешно проявлять свои интеллектуальные возможности необходимо следующее. В составе ИНМ должны присутствовать подсистемы управления датчиками, совмещенными с эффекторами, отслеживающие (повторяющие) поведение воспринимаемых сигналов (их источников). Такая машина должна связывать на элементах РНС сигналы о внешнем мире с выходах блоков Д/Э с сигналами об состоянии этих блоков, несущими информацию о реализованных преобразованиях над сигналами внешнего мира. В этом случае между сигналами внешнего мира и реализуемыми над ними преобразованиями устанавливается однозначное соответствие. РНС должна обеспечить полноценное связывание и трансформирование обрабатываемых сигналов без потерь информации о соответствующих исходных воздействиях. Это достижимо построением РНС на основе рассмотренных выше новых моделей умных импульсных нейронов с обширной внутренней памятью и новым способом ассоциативного обращения к памяти.

6. Схемные решения и результаты моделирования. Для подтверждения результативности и преимуществ предложенных моделей и методов интеллектуальной нейросетевой обработки информации проводилось их моделирование.

6.1. Схема и результаты моделирования умного нейрона. Учитывая предложенные теоретические решения, схему функционирования умного нейрона можно представить в виде рисунка 7. Согласно рисунку 7 эта схема состоит из пяти блоков. Для проверки условия (1) в первом блоке в качестве моделируемой поверхности нейрона можно использовать сетку из обычных резисторов (рисунок 8).

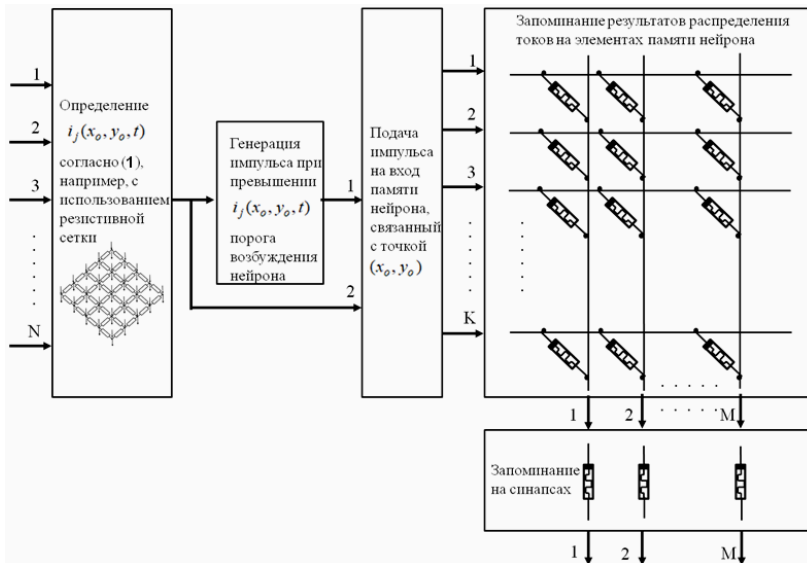


Рис. 7. Схема функционирования «умного» нейрона с реализацией внутренней памяти на мемристорах

На входы этой сетки поступают сигналы от z -х нейронов. В качестве интересующих выходов сетки используют один или несколько выходов, удовлетворяющий условию (1).




Рис. 8. Резистивная сетка, моделирующая принимающую поверхность умного нейрона

Для подтверждения справедливости сформулированных научных положений проводилось компьютерное моделирование. Сначала проверялась возможность умных нейронов реализовывать различные функции с использованием предложенного нового метода ассоциативного обращения к их внутренней памяти. В интересах этого распределение токов от отдельных воздействий на поверхности умных нейронов аппроксимировали двумерным нормальным законом. Рассматривался случай поступления на отдельно взятый нейрон трех воздействий, соотнесенных со своими точками приложения к поверхности нейрона. Результаты суммарных распределений токов по поверхности нейрона в соответствии с (1) отражены на рисунке 9.




Рис. 9. Примеры распределения суммарных токов на поверхности принимающего нейрона при возбуждающих воздействиях, приложенных к трем разным точкам: а, б, в, г) распределения при различных координатах этих точек приложения

Согласно рисунку 9 получаемые распределения существенно зависят, как от точек приложения воздействий на нейрон, так и уровней этих воздействий. В случае большого разноса точек приложения воздействий (рисунок 9(а)) в явном виде просматриваются три максимума. При сближении этих точек (рисунок 9(б, в, г)) картина

меняется. Однако во всех случаях согласно (1) можно выделить точку с наибольшим максимумом со своими координатами. Причем координаты этого максимума могут не совпадать с координатами ни с одной из исходных точек. При превышении этого максимума порога возбуждения нейрона, он срабатывает. Относительно точки срабатывания формируется и передается к выходам нейрона по своим внутренним путям единичный заряд. На выходах нейрона получаем конкретное распределение токов с учетом пространственно-энергетических характеристик воздействий на нейрон и внутренней памяти.

Поясним это на простом примере. Допустим, что воздействия на нейрон в двух точках отражает поступление на него сигналов, соотнесенных, например, с числами A и B . Третье воздействие F со своей точкой приключения несет информацию о реализуемой с этими числами операции. Тогда при одних и тех же A и B в зависимости от управления F на выходах умного нейрона будут формироваться разные распределения токов. Этим распределениям могут быть поставлены в соответствие конкретные результаты выполняемых операций. В частности если $A = 8$, а $B = 2$ и $F = A + B$, то получаемое распределение токов на выходе нейрона соответствует числу 10.

В случае $F = \log_B A$ имеем распределение, соотнесенное с числом 3. Аналогично могут выполняться не только арифметические, но и другие различные по содержанию операции над сигналами. Таким образом, обученный нейрон в зависимости от управляющих воздействий может реализовывать различные трансформации над обрабатываемыми информационными сигналами, а группы параллельных нейронов – различные групповые трансформации, в том числе связанные с поворотами сигналов, их сдвигами, сжатием, расширением и другими действиями. Последовательности групп параллельных нейронов, в том числе с обратными связями, могут реализовывать последовательные трансформации над сигналами в соответствии управляющими воздействиями. Это, в некоторой мере, эквивалентно преобразованиям сигналов по программе.

6.2. Результаты ассоциативного вызова сигналов из памяти РНС с умными и традиционными импульсными нейронами. Сравнивались возможности рекуррентных импульсных нейронных сетей с умными нейронами и традиционными их моделями по запоминанию сигналов и ассоциативному вызову их из памяти. Рассматривался случай обработки в РНС сигналов с высокой корреляцией. Особенность такой обработки при использовании

традиционных нейронов в том, что в РНС формируется много альтернативных связей, мешающих как запоминанию, так и корректному извлечению сигналов из памяти. В качестве РНС выступала двухслойная сеть со структурой, подобной рисунку 2(б). Число нейронов в каждом слое сети равнялось 1890 единиц. Слои РНС за счет пространственных сдвигов СЕИ при передаче от слоя к слою разбивались на логические поля размером 6×7 нейронов. Используемые умные нейроны, в отличие от традиционных импульсных моделей, были способны различать по четыре типа пространственно-энергетических воздействий (условно имели по четыре пространственно разнесенных точки приложения входных воздействий). Обе РНС одинаково обучались. На входы РНС последовательно подавались одинаковые последовательности СЕИ в виде изображений букв. Буквы представлялись совокупностями единичных импульсов (образов) с количеством от 8 до 12 единиц. Изображения различных букв имели пересечения по единичным образам. Обучение сводилось к прогону по сети этих последовательностей и запоминание их. Проводимости (веса) цепей передачи сигналов в РНС определялись согласно (2), (3). После этого оценивалась эффективность ассоциативного вызова сигналов из памяти РНС с умными и традиционными нейронами после одного и того же числа тактов работы. Полученные результаты сведены в таблицы 1, 2.

Таблица 1. Эффективность ассоциативного вызова сигналов из памяти РНС с одинаковым уровнем усиления вызывающих сигналов

Тип РНС и приращения показателей	Эксперимент 1		Эксперимент 2		Эксперимент 3		Эксперимент 4	
	N/S	S/(S+N)	N/S	S/(S+N)	N/S	S/(S+N)	N/S	S/(S+N)
РНС с традиционными импульсными нейронами	0.258	0.795	0.267	0.789	0.388	0.720	0.519	0.659
РНС с умными нейронами	0.217	0.821	0.143	0.875	0.167	0.857	0.171	0.854
Приращения (I)	-0.041	0.026	-0.124	0.086	-0.221	0.137	-0.348	0.195
I%	-15.891	3.270	-46.442	10.900	-56.959	19.028	-67.052	29.590

Таблица 2. Эффективность ассоциативного вызова сигналов из памяти РНС с разными уровнями усиления вызывающих сигналов

Тип РНС и приращения показателей	Эксперимент 5		Эксперимент 6		Эксперимент 7		Эксперимент 8	
	N/S	S/(S+N)	N/S	S/(S+N)	N/S	S/(S+N)	N/S	S/(S+N)
РНС с традиционными импульсными нейронами	0.310	0.760	0.310	0.760	0.419	0.705	0.419	0.705
РНС с умными нейронами	0.190	0.840	0.107	0.903	0.190	0.840	0.107	0.903
Приращения (I)	-0.120	0.080	-0.203	0.143	-0.229	0.135	-0.312	0.198
%	-38.709	10.526	-65.484	18.816	-54.654	19.149	-74.463	28.085

Эксперименты различались количеством тактов работы РНС, на которых анализировались состояния нейронов. В таблицах приняты обозначения: N , S – число ложных и истинных импульсов (единичных образов), вызываемых из ассоциативной памяти РНС. Из анализа таблиц 1, 2 видно, что РНС с умными нейронами существенно превосходят сети с традиционными импульсными нейронами. При этом усиление ассоциативного вызова сигналов из памяти РНС позволяет получать более высокие оценки.

6.3. Результаты восстановления обрабатываемых сигналов РНС с умными нейронами, представляемыми группами обычных импульсных моделей. Проводились также другие эксперименты по ассоциативной обработке сигналов в РНС, подтверждающие реализуемость предложенных решений с умными нейронами. Рассматривался случай, когда умные нейроны представлялись в слоях РНС группами обычных импульсных нейронов. В РНС с числом нейронов в слоях по 3150 единиц каждый умный нейрон моделировался 42 обычными импульсными нейронами. Умный нейрон был эквивалентен одному логическому полю (6×7 нейронов), на которые разбивались слои РНС. За счет этого каждый слой РНС сводился к 75 умным нейронам. В каждой группе обычных импульсных нейронов, моделирующих умный нейрон, одновременно мог возбуждаться только один нейрон. Такая схема также предусматривала соответствующее кодирование входных сигналов. Для рассматриваемого случая примеры состояния первого слоя РНС при решении задачи восстановления СЕИ, отсутствующих в середине обрабатываемой последовательности, приведены на рисунке 10.

Заметим, что результат восстановления на рисунке 10(б) полностью соответствует эталонному варианту (рисунок 10(в)), за исключением разницы в пространственных сдвигах СЕИ при продвижении вдоль слоев.

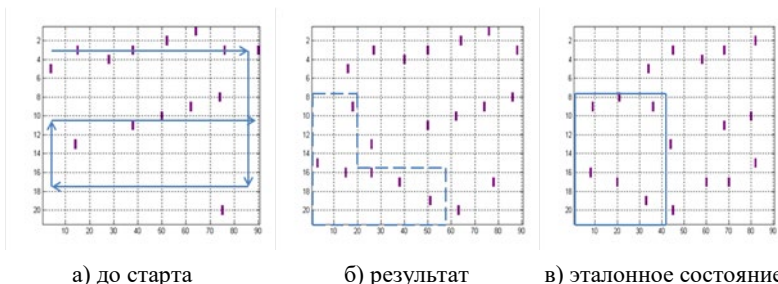


Рис. 10. Примеры состояния первого слоя РНС при восстановлении сигналов

Стрелки на рисунке 10(а) отражают схему продвижения СЕИ вдоль слоев. В данном примере за каждым пространственно соотнесенным единичным импульсом закреплялось свое событие. В рассматриваемом примере такими событиями выступали закодированные последовательные слова обрабатываемых текстов.

6.4. Результаты моделирования сложных преобразований сигналов в памяти РНС с умными нейронами. Проводились эксперименты по реализации интеллектуальных операций над сигналами в памяти РНС. Использовалась двухслойная РНС с умными нейронами с той же схемой продвижения СЕИ вдоль слоев, что и на рисунке 2(б). Число умных нейронов в каждом слое сети составляло 3150 единиц. За счет пространственных сдвигов СЕИ каждый слой сети разделялся на 75 логических полей с размерами 6x7 нейронов. Эти поля дополнительно делились на два подполя по 3x3 нейронов и подполя 6x4 нейронов. В эксперименте задействовались только подполя 3x3 умных нейронов, различающих по четыре типа пространственно-энергетических воздействий (имеющих по четыре пространственно-разнесенных точки приложения входных сигналов). Во время обучения РНС закодированные информационные сигналы и соответствующие им управляющие воздействия подавались на свои входные подполя. При прохождении по сети информационных сигналов и управляющих воздействий между ними устанавливались связи. После обучения в нейронную сеть вводились управляющие воздействия, которые успешно вызывали связанные с ними информационные сигналы. Заметим, что каждому управляющему воздействию соответствует своя операция действий над обрабатываемыми сигналами. Пример такого вызова информации приведен на рисунках 11 и 12.

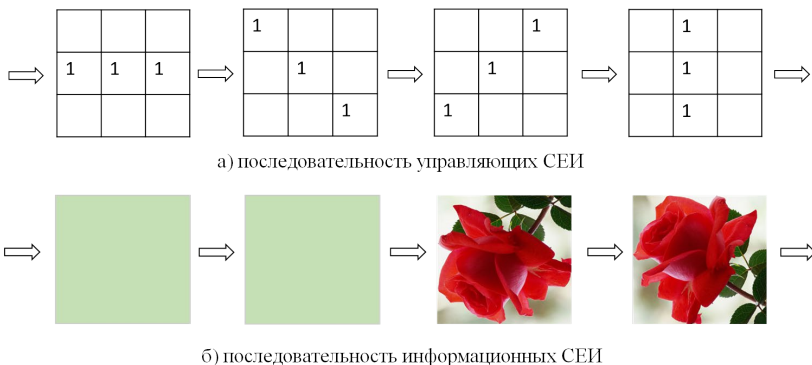


Рис. 11. Примеры последовательностей управляющих и информационных СЕИ, обрабатываемых в РНС до начала вызова информации из памяти

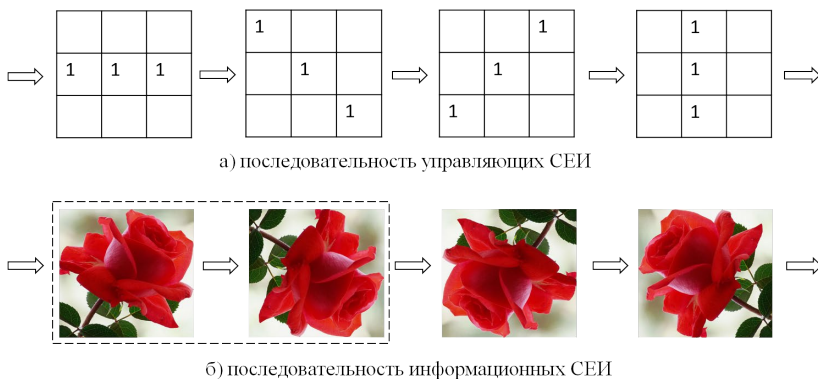


Рис. 12. Результат ассоциативного вызова информации из памяти РНС в соответствии с управляющими воздействиями

Для наглядности отражения результатов на рисунках 11 и 12 информационные СЕИ заменены на соответствующие им исходные образы. Это могут быть и другие образы, например, изображения букв, лиц, птиц. Промежуточные результаты работы сети при передаче СЕИ от слоя к слою здесь не показаны. Из рисунков 11, 12 видно, что каждой управляющей СЕИ соответствует своя операция действий над обрабатываемыми образами. В соответствии с рисунком 11(б) в РНС введены два образа розы (справа), а за ними – два пустых образа, которые формируются при прерывании воздействия информационных сигналов на сеть. Однако на интервале такого прерывания в сеть поступили две управляющих СЕИ (слева на рисунке 11(а)), которые ассоциативно вместе с присутствующими информационными СЕИ

вызывают из памяти РНС на рисунке 12(б) (слева) новые образы розы. Таким образом, формируя различные управляющие последовательности СЕИ внутри РНС, можно оперировать информационными образами, которые в ней активны, и вызывать из памяти новые связанные с ними сигналы. В этом примере рассмотрена реализация внутри сети операций вращения. Также внутри РНС согласно предложенным в разделе 5 механизмам мышления ИНМ могут реализовываться пространственные сдвиги и другие операции. Заметим, что человек, наблюдая за любым материальным объектом, может мысленно его переместить, повернуть, наклонить. Это также может делать ИНМ.

Для обеспечения устойчивого извлечения сигналов из памяти РНС производилось усиление вызывающих сигналов в направлении входа сети с учетом числа возбужденных нейронов. Этот случай вполне адекватно отражает возможности различных интеллектуальных операций над сигналами, если установлены соответствующие ассоциативные связи при обработке сигналов внешнего мира согласно схеме на рисунке 5.

7. Заключение. Предложены новые принципы функционирования ИНМ с функциями мышления. Согласно этим принципам ИНМ, чтобы научиться реализовывать интеллектуальные операции с сигналами, образами и понятиями в искусственном мозгу, должна уметь подражать событиям во внешнем мире. Кроме этого в искусственном мозгу необходимо иметь механизмы управления его деятельностью, обусловленные некоторыми мотивами. Искусственный мозг ИНМ должен обладать широкими возможностями по связыванию, трансформированию и запоминанию сигналов. Внутренняя память умных нейронов искусственного мозга должна превышать память на синапсах.

Разработана модель умного импульсного нейрона, как базового элемента перспективных ИНМ, с существенно расширенными функциями по интеллектуальной обработке информации. Эту модель можно рассматривать как полноценный ассоциативный процессор с внутренней памятью с новым методом обращения к ней по содержанию обрабатываемой информации.

Предложено формировать искусственный мозг ИНМ на основе многоуровневых РНС, наделенных логическими структурами и использующих в качестве базовых элементов умные импульсные нейроны.

Раскрыт метод, позволяющий осуществлять многоуровневую ассоциативную обработку информации в РНС с возможностью

восстановления результатов обработки в соответствующей им исходной форме.

Выявлены механизмы, позволяющие наделять ИНМ функциями мышления. В искусственном мозгу должны связываться и запоминаться сигналы внешнего мира и воздействия, отражающие операции над этими сигналами. В этом случае ИНМ с использованием управляющих сигналов может ассоциативно вызывать из памяти информационные сигналы с их различными трансформациями (преобразованиями). Также информационными сигналами, в зависимости от их содержания, можно вызывать из ассоциативной памяти ИНМ соответствующие им управляющие воздействия на внешний мир с различной скоростью.

Результаты компьютерного моделирования подтверждают результативность и преимущества предложенных решений по сравнению с известными подходами.

Предложенные решения позволяют устранить разрыв между интеллектуальной обработкой физических сигналов и символических представлений. Эти решения могут быть востребованы при создании перспективных программно и аппаратно реализуемых ассоциативных процессоров, мыслящих нейросетевых машин, умных роботов для решения широкого спектра трудно формализуемых творческих прикладных задач.

Литература

1. Тьюринг А. Может ли машина мыслить? С приложением статьи Дж. фон Неймана «Общая и логическая теория автоматов». Перевод с английского Ю.А. Данилова. М.: Физ.-Мат. Лит., 1960. 112 С.
2. Мышление – Большой энциклопедический словарь. URL: <https://gufo.me/dict/bes/МЫШЛЕНИЕ> (дата доступа 05.04.2024).
3. Velankar M.R., Mahalle P.N., Shinde G.R. Machine Thinking: New Paradigm Shift. In: Cognitive Computing for Machine Thinking. Innovations in Sustainable Technologies and Computing. 2024. pp. 43–53.
4. Malsburg C. Toward understanding the neural code of the brain. Biological Cybernetics. 2021. vol. 115. no. 5. pp. 439–449.
5. Yamakawa H. The whole brain architecture approach: accelerating the development of artificial general intelligence by referring to the brain. Neural Networks. 2021. vol. 144. pp. 478–495.
6. Haykin S. Neural Networks and Learning Machines, third ed., Prentice Hall, New York. 2008. URL: <http://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf> (дата доступа 24.04.2024).
7. Kotseruba I., Tsotsos J. 40 years of cognitive architectures: core cognitive abilities and practical applications. Artificial Intelligence Review. 2020. vol. 53. no. 1. pp. 17–94.
8. Dormehl L. Thinking machine: The Quest for Artificial Intelligence – and Where It's Taking Us Next. Penguin, 2017. 209 p.

9. Takano S. *Thinking Machines. Machine Learning and Its Hardware Implementation.* Academic Press, 2021. 306 p.
10. Hawkins J., Blakeslee S. On intelligence. *Brown Walker*, 2006. 174 p.
11. Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*. 2018. vol. 308. pp. 194–204.
12. Hawkins J., Ahmad S. Hierarchical temporal memory including HTM cortical learning algorithms. Hosted at Numenta.org. 2011. 68 p.
13. Spoerer C.J., McClure, P., Kriegeskorte, N., 2017. Recurrent convolutional neural networks: a better model of biological object recognition. *Frontiers in psychology*. 2017. vol. 8. DOI: 10.3389/fpsyg.2017.01551.
14. Patrick M., Adekoya A., Mighty A., Edward B. Capsule networks – a survey. *Journal of King Saud University – Computer and Information Sciences*. 2022. vol. 34(1). pp. 1295–1310.
15. Yang G., Ding F. Associative memory optimized method on deep neural networks for image classification. *Information Sciences*. 2020. vol. 533. pp. 108–119.
16. Yang J., Zhang L., Chen C., Li Y., Li R., Wang G., Jiang S., Zeng Z. A hierarchical deep convolutional neural network and gated recurrent unit framework for structural damage detection. *Information Sciences*. 2020. vol. 540. pp. 117–130.
17. Ma T., Lv S., Huang L., Hu S. HiAM: A hierarchical attention based model for knowledge graph multi-hop reasoning. *Neural Networks*. 2021. vol. 143. pp. 261–270.
18. Grossberg S. Adaptive resonance theory: how a brain learns to consciously attend, learn, and recognize a changing world. *Neural Networks*. 2013. vol. 37. pp. 1–47.
19. Khowaja S., Lee S.L. Hybrid and hierarchical fusion networks: a deep cross-modal learning architecture for action recognition. *Neural Computing and Applications*. 2020. vol. 32. no. 14. pp. 10423–10434.
20. Saha S., Gan Z., Cheng L., Gao J., Kafka O., Xie X., Li H., Tajdari M., Kim H., Liu W. Hierarchical deep learning neural network (HiDeNN): an artificial intelligence (AI) framework for computational science and engineering. *Computer Methods in Applied Mechanics and Engineering*. 2021. vol. 373. DOI: 10.1016/j.cma.2020.113452.
21. Yang M., Chen L., Lyu Z., Liu J., Shen Y., Wu Q. Hierarchical fusion of common sense knowledge and classifier decisions for answer selection in community question answering. *Neural Networks*. 2020. vol. 132. pp. 53–65.
22. Wolfgram P., Wolff C., Lucke J., Malsburg C. A recurrent dynamic model for correspondence-based face recognition. *Journal of Vision*. 2008, vol. 8(7). no. 34. pp. 1–18. DOI: 10.1167/8.7.34.
23. Han Y., Huang G., Song S., Yang L., Wang H., Wang Y. Dynamic neural networks: a survey. *arXiv:2102.04906v4*. 2021. pp. 1–20.
24. Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*. 2020. vol. 32. no. 18. pp. 14885–14897.
25. Osipov V., Kuleshov S., Zaytseva A., Levonevskiy D., Miloserdov D. Neural network forecasting of news feeds. *Expert systems with applications*. 2021. vol. 169. DOI: 10.1016/j.eswa.2020.114521.
26. Osipov V., Kuleshov S., Miloserdov D., Zaytseva A., Aksenov A. Recurrent Neural Networks with Continuous Learning in Problems of News Streams Multifunctional Processing. *Informatics and Automation*. 2022. vol. 21. no. 6. pp. 1145–1168.
27. Osipov V., Osipova M. Method and device of intellectual processing of information in neural network, Patent RU2413304. 2011.
28. Osipov V. Method for intelligent multi-level information processing in neural network, Patent RU2737227. 2020.

29. He J., Yang H., He L., Zhao L. Neural networks based on vectorized neurons. *Neurocomputing*. 2021. vol. 465. pp. 63–70.
30. Deng C., Litany O., Duan Y., Poulenard A., Tagliasacchi A., Guibas L. Vector neurons: a general framework for SO(3)-Equivariant networks. arXiv:2104.12229v1. 2021. pp. 1–12.
31. Kryzhanovsky B., Litinskii L., Mikaelian A. Vector-Neuron Model of Associative Memory. *IEEE International Joint Conference on Neural Networks*. 2004. vol. 2. pp. 909–914.
32. Tuszyński J.A., Friesen D.E., Freedman H., Sbitnev V.I., Kim H., Santelices L., Kalra A., Patel S., Shankar K., Chua L.O. Microtubules as Sub-Cellular Memristors. *Scientific Reports*. 2020. vol. 10(1). DOI: 10.1038/s41598-020-58820-y.
33. Bicanski A., Burgess N. Neural vector coding in spatial cognition. *Nature Reviews Neuroscience*. 2020. vol. 21. pp. 453–470.
34. Rvachev M. V. Neuron as a reward-modulated combinatorial switch and a model of learning behavior. *Neural Networks*. 2013. vol. 46. pp. 62–74.
35. Осипов В.Ю. Векторные свойства и память нейронов. Сборник тезисов XXIV съезда физиологического общества им. И.П. Павлова. 2023. С. 586–587.
36. Sardi S., Vardi R., Sheinin A., Goldental A., Kanter I. New types of experiments reveal that a neuron functions as multiple independent threshold units. *Scientific Reports*. 2017. vol. 7(1). DOI: 10.1038/s41598-017-18363-1.

Осипов Василий Юрьевич — директор, Санкт-Петербургский институт информатики и автоматизации Российской академии наук, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук. Область научных интересов: математическое моделирование, интеллектуальные системы, нейронные сети, информационная безопасность. Число научных публикаций — 170. osipov_vasily@mail.ru; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)323-0366.

Поддержка исследований. грант Российского научного фонда № 23 19 20081 и Санкт-Петербургского научного фонда.

V. OSIPOV
**INTELLIGENT NEURAL NETWORK MACHINE WITH
THINKING FUNCTIONS**

Osipov V. Intelligent Neural Network Machine with Thinking Functions.

Abstract. In recent years, interest in artificial intelligence based on neural network approaches has grown significantly. A number of significant scientific results have been obtained that have found wide application in practice. Generative adversarial neural network models, neural network transformers, and other solutions have attracted much attention. Obvious progress has been achieved in neural network recognition and image generation, text and speech processing, event forecasting, and control of processes that are difficult to formalize. However, it has not yet been possible to endow neural network machines with thinking. All results obtained using neural network machines can be attributed to solutions based on various types of signal binding without full control of their processing processes. Typical representatives of such machines are ChatGPT. The capabilities for intelligently operating various signals in known neural network machines are very limited. Among the main reasons for such limitations, one should highlight the imperfection of the basic principles of neural network information processing used. The properties of neurons have long been considered in a simplified manner. This was due to both gaps in the field of biological research and the lack of opportunities to build large neural networks on complex neuron models. In recent years the situation has changed. New ways to implement large neural networks have emerged. It has also been established that even individual neurons can have extensive internal memory and implement various functions. However, many mechanisms of neuron functioning and their interactions still remain unclear. The issues of controlled associative access to the internal memory of neurons have been little studied. These shortcomings significantly hinder the creation of thinking neural network machines. The object of research in the article is the process of intelligent neural network information processing. The subject of research: principles, models, and methods of such processing. The goal is to expand the functionality of neural network machines to solve difficult-to-formalize creative problems through the development of new principles, models, and methods of intelligent information processing. In the interests of achieving this goal, the operating principles of intelligent neural network machines are clarified, and new models and methods of neural network information processing are proposed. A new model of a pulse neuron is revealed as a basic element of such machines. It is recommended to form the artificial brain of neural network machines in the form of multilayer neural networks endowed with logical structures with neurons of different parameters. A new method of multi-level intelligent information processing in neural network machines based on smart impulse neurons is proposed. The mechanisms of thinking of neural network machines, and the underlying functions of intellectual operation of images and concepts in neural network memory are explained. Simulation results are presented that confirm the validity of the proposed solutions.

Keywords: neural network machine, intelligence, thinking functions, smart neurons, signal transformation.

References

1. Turing A. Can a Machine Think? With the attached article by J. Von Neumann. General and Logical Theory of Automaton. Moscow: State Publishing House Physical and Mathematical Literature, 1960. 112 p.

2. Myshlenie – Bol'shoj enciklopedicheskij slovar' [Thinking is a great encyclopedic dictionary]. Available at: <https://gufo.me/dict/bes/МЫШЛЕНИЕ> (accessed 05.04.2024).
3. Velankar M.R., Mahalle P.N., Shinde G.R. Machine Thinking: New Paradigm Shift. In: Cognitive Computing for Machine Thinking. Innovations in Sustainable Technologies and Computing. 2024. pp. 43–53.
4. Malsburg C. Toward understanding the neural code of the brain. *Biological Cybernetics*. 2021. vol. 115. no. 5. pp. 439–449.
5. Yamakawa H. The whole brain architecture approach: accelerating the development of artificial general intelligence by referring to the brain. *Neural Networks*. 2021. vol. 144. pp. 478–495.
6. Haykin S. *Neural Networks and Learning Machines*, third ed., Prentice Hall, New York. 2008. Available at: <http://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf> (accessed 24.04.2024).
7. Kotseruba I., Tsotsos J. 40 years of cognitive architectures: core cognitive abilities and practical applications. *Artificial Intelligence Review*. 2020. vol. 53. no. 1. pp. 17–94.
8. Dormehl L. *Thinking machine: The Quest for Artificial Intelligence – and Where It's Taking Us Next*. Penguin, 2017. 209 p.
9. Takano S. *Thinking Machines. Machine Learning and Its Hardware Implementation*. Academic Press, 2021. 306 p.
10. Hawkins J., Blakeslee S. *On intelligence*. Brown Walker, 2006. 174 p.
11. Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*. 2018. vol. 308. pp. 194–204.
12. Hawkins J., Ahmad S. Hierarchical temporal memory including HTM cortical learning algorithms. Hosted at Numenta.org. 2011. 68 p.
13. Spoerer C.J., McClure, P., Kriegeskorte, N., 2017. Recurrent convolutional neural networks: a better model of biological object recognition. *Frontiers in psychology*. 2017. vol. 8. DOI: 10.3389/fpsyg.2017.01551.
14. Patrick M., Adekoya A., Mighty A., Edward B. Capsule networks – a survey. *Journal of King Saud University – Computer and Information Sciences*. 2022. vol. 34(1). pp. 1295–1310.
15. Yang G., Ding F. Associative memory optimized method on deep neural networks for image classification. *Information Sciences*. 2020. vol. 533. pp. 108–119.
16. Yang J., Zhang L., Chen C., Li Y., Li R., Wang G., Jiang S., Zeng Z. A hierarchical deep convolutional neural network and gated recurrent unit framework for structural damage detection. *Information Sciences*. 2020. vol. 540. pp. 117–130.
17. Ma T., Lv S., Huang L., Hu S. HiAM: A hierarchical attention based model for knowledge graph multi-hop reasoning. *Neural Networks*. 2021. vol. 143. pp. 261–270.
18. Grossberg S. Adaptive resonance theory: how a brain learns to consciously attend, learn, and recognize a changing world. *Neural Networks*. 2013. vol. 37. pp. 1–47.
19. Khowaja S., Lee S.L. Hybrid and hierarchical fusion networks: a deep cross-modal learning architecture for action recognition. *Neural Computing and Applications*. 2020. vol. 32. no. 14. pp. 10423–10434.
20. Saha S., Gan Z., Cheng L., Gao J., Kafka O., Xie X., Li H., Tajdari M., Kim H., Liu W. Hierarchical deep learning neural network (HiDeNN): an artificial intelligence (AI) framework for computational science and engineering. *Computer Methods in Applied Mechanics and Engineering*. 2021. vol. 373. DOI: 10.1016/j.cma.2020.113452.
21. Yang M., Chen L., Lyu Z., Liu J., Shen Y., Wu Q. Hierarchical fusion of common sense knowledge and classifier decisions for answer selection in community question answering. *Neural Networks*. 2020. vol. 132. pp. 53–65.

22. Wolfrum P., Wolff C., Lucke J., Malsburg C. A recurrent dynamic model for correspondence-based face recognition. *Journal of Vision*. 2008, vol. 8(7). no. 34. pp. 1–18. DOI: 10.1167/8.7.34.
23. Han Y., Huang G., Song S., Yang L., Wang H., Wang Y. Dynamic neural networks: a survey. arXiv:2102.04906v4. 2021. pp. 1–20.
24. Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*. 2020. vol. 32. no. 18. pp. 14885–14897.
25. Osipov V., Kuleshov S., Zaytseva A., Levonevskiy D., Miloserdov D. Neural network forecasting of news feeds. *Expert systems with applications*. 2021. vol. 169. DOI: 10.1016/j.eswa.2020.114521.
26. Osipov V., Kuleshov S., Miloserdov D., Zaytseva A., Aksenov A. Recurrent Neural Networks with Continuous Learning in Problems of News Streams Multifunctional Processing. *Informatics and Automation*. 2022. vol. 21. no. 6. pp. 1145–1168.
27. Osipov V., Osipova M. Method and device of intellectual processing of information in neural network, Patent RU2413304. 2011.
28. Osipov V. Method for intelligent multi-level information processing in neural network, Patent RU2737227. 2020.
29. He J., Yang H., He L., Zhao L. Neural networks based on vectorized neurons. *Neurocomputing*. 2021. vol. 465. pp. 63–70.
30. Deng C., Litany O., Duan Y., Poulencard A., Tagliasacchi A., Guibas L. Vector neurons: a general framework for SO(3)-Equivariant networks. arXiv:2104.12229v1. 2021. pp. 1–12.
31. Kryzhanovskiy B., Litinskii L., Mikaelian A. Vector-Neuron Model of Associative Memory. *IEEE International Joint Conference on Neural Networks*. 2004. vol. 2. pp. 909–914.
32. Tuszyński J.A., Friesen D.E., Freedman H., Sbitnev V.I., Kim H., Santelices L., Kalra A., Patel S., Shankar K., Chua L.O. Microtubules as Sub-Cellular Memristors. *Scientific Reports*. 2020. vol. 10(1). DOI: 10.1038/s41598-020-58820-y.
33. Bicanski A., Burgess N. Neural vector coding in spatial cognition. *Nature Reviews Neuroscience*. 2020. vol. 21. pp. 453–470.
34. Rvachev M. V. Neuron as a reward-modulated combinatorial switch and a model of learning behavior. *Neural Networks*. 2013. vol. 46. pp. 62–74.
35. Osipov V.Yu. [Vector properties and memory of neurons] Vektornye svoystva i pamjat' neyronov. *Sbornik tezisov XXIV s'ezda fiziologicheskogo obshchestva im. I.P. Pavlova Collection of abstracts of the XXIV Congress of the Physiological Society named after. I.P. Pavlova*. 2023. pp. 586–587. (In Russ.).
36. Sardi S., Vardi R., Sheinin A., Goldental A., Kanter I. New types of experiments reveal that a neuron functions as multiple independent threshold units. *Scientific Reports*. 2017. vol. 7(1). DOI: 10.1038/s41598-017-18363-1.

Osipov Vasily — Director, St. Petersburg Institute of Informatics and Automation of the Russian Academy of Sciences, St. Petersburg Federal Research Center of the Russian Academy of Sciences. Research interests: mathematical modeling, intelligent systems, neural networks, information security. The number of publications — 170. osipov_vasily@mail.ru; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)323-0366.

Acknowledgements. This research is supported by the Russian Science Foundation No. 231920081 and the St. Petersburg Science Foundation.