УДК 004.032.26

И.А. Ходашинский, Н.Д. Малютин

Модели статических искусственных нейронов. Обзор

Рассмотрены статические искусственные нейроны, в модели которых не входит время в качестве параметра. Для каждой модели приведены функции агрегации и функции активации, указаны достоинства, присущие рассматриваемым моделям нейронов.

Ключевые слова: искусственный нейрон, статическая модель нейрона, функция агрегации, функция активации, комбинированный нейрон, нечеткий нейрон, энергетическая модель нейрона, комплекснозначный нейрон.

В последние годы предметом пристального внимания ученых и инженеров является интеллектуальная электроника, способная воспринимать информацию любой природы. Для обработки такой информации активно используют не только программное обеспечение, но и аппаратные технологии. Искусственная нейронная сеть (ИНС), имитирующая взаимодействие биологических нейронов, является одним из мощных и популярных средств построения интеллектуальных систем, в силу ее способности к обучению и адаптации, а также возможности масштабирования таких систем.

Формально искусственная нейронная сеть – это сеть с конечным числом искусственных (формальных) нейронов, каждый из которых выполняет взвешенное суммирование поступающих на его вход сигналов. Результатом суммирования является промежуточный выходной сигнал, преобразованный активационной функцией (чаще всего нелинейной) в выходной сигнал искусственного нейрона. Наиболее распространёнными являются многослойные однонаправленные сети, сети Кохонена, сети Хопфильда, нейро-нечеткие сети.

ИНС определяется следующими особенностями: топологией сети, функцией активации, алгоритмом обучения, количеством и типом входов/выходов, количеством процессорных элементов (нейронов) и синаптических соединений, количеством слоев и т.д.

ИНС могут быть реализованы как в программном виде, так и в аппаратном и программно-аппаратном исполнении. Несмотря на то, что аппаратная реализация дороже программной, удельный вес таких реализаций в общем объеме технологических разработок растет год от года. Основными достоинствами аппаратной реализации являются скорость исполнения приложений, безопасность и режимы эксплуатации, такие как размеры, вес, энергопотребление.

Возможности ИНС определяются входящими в нее базовыми элементами – нейронами. К настоящему времени специалистами предложено несколько десятков моделей нейронов, которые по своему назначению могут быть классифицированы на 1) модели, воспроизводящие процессы, протекающие в биологическом нейроне, и 2) модели, в которых нейрон рассматривается как устройство обработки информации, предназначенный для решения вычислительных задач. Цель создания моделей первого типа – точное описание работы биологического нейрона. Цель создания моделей второго типа – повышение эффективности решения задач классификации, аппроксимации, прогнозирования, управления и др.

С учетом большого количества разработанных моделей возникают вопросы: какую модель нейрона выбрать и можно ли при построении вычислителя использовать нейроны вместо логических вентилей? можно ли создать библиотеку функций в виде комплекта заготовок, из которых можно конструировать системы более высокого уровня с высоким уровнем параллелизма и отказоустойчивости? будут ли построенные системы эффективнее традиционных вычислителей? могут ли построенные системы быть имитаторами процессов, происходящих в мозге, и служить для изучения самого мозга [1].

В силу ограниченности объема статьи в одной работе ответить на все поставленные выше вопросы не представляется возможным. В работе не рассматриваются модели, описывающие процессы в биологических нейронах. В круг рассмотрения не попали и динамические модели нейронов [2], в частности, спайковые нейроны [3–5], хаотические нейроны [6, 7], нейроны с мемристорными связями [8, 9], пригодные как для моделирования биологических нейронов, так и для нейронов-вычислителей. Целью данной работы является анализ структур и вычислительных возможностей

статических искусственных нейронов, т.е. таких нейронов, в описании, которых отсутствует время как параметр модели.

Обобщенная структура биологического нейрона. В связи с тем, что при рассмотрении моделей искусственных нейронов будут использоваться биологические термины, необходимо рассмотреть упрощенную структуру биологического нейрона. Однако учитывая, что «в природе не существует того, что можно было бы назвать *типичным* нейроном» [10], на рис. 1 приведена обобщенная схема нейрона.

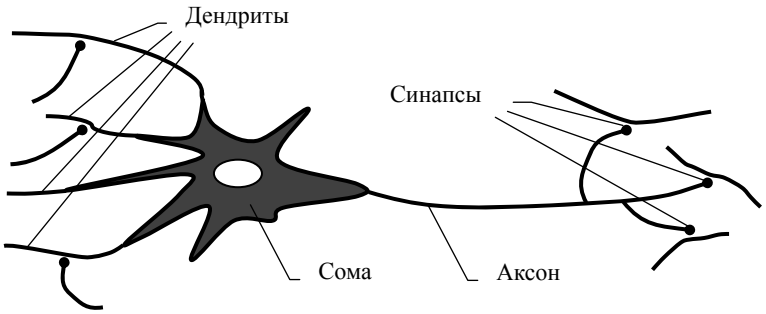

Рис. 1. Схема нейрона

От тела нейрона или сомы отходят ветвящиеся отростки-дендриты, образующие входную поверхность нейрона. От сомы отходит волокно, называемое аксоном, который образует так называемые концевые разветвления. Места контактов концевых утолщений ветвей аксона с другими нейронами называются синапсами. Возбуждение других нейронов изменяет мембранный потенциал дендритов и сомы. Если изменение разности потенциалов превышает некий порог, то возбуждение передается на аксонный холмик, затем в виде импульса (спайка) распространяется по аксону до концевых разветвлений и активизирует синапсы, которые в свою очередь изменяют мембранный потенциал других нейронов. После распространения каждого такого импульса по аксону происходят химические восстановительные процессы – время рефракторного периода, когда аксон не может передавать новый импульс. Изменения разности потенциалов от одного спайка, пришедшего к синапсу, часто могут быть меньше порога. Однако такие изменения могут суммироваться с изменениями, вызванными прошлыми спайками, которые еще не успели затухнуть, и превысить порог [10].

С позиций построения нейровычислителя нейрон необходимо рассмотреть в трех аспектах: обработка, передача и хранения информации. Два первых аспекта рассмотрены выше. Полного представления о механизмах хранение информации в нейроне пока не существует. В работе [11] показано, что запоминание очень сильно зависит от дендритов; например, если во время какого-либо события сома активизирована, а дендриты не активизированы, то долговременное запоминания данного события не происходит.

Простая статическая модель нейрона. Статический искусственный нейрон выполняет простые операции суммирования в отличие от биологического нейрона, который выполняет гораздо более сложные операции. Статическая модель нейрона не учитывает временные задержки, которые влияют на динамику системы. Временные задержки являются неотъемлемыми характеристиками биологических нейронов во время передачи информации. В статических нейронных сетях отсутствуют эффекты синхронной работы или функции частотной модуляции, присущие биологическим нейронам.

Базовая модель данного нейрона содержит входной вектор синаптических весов, функцию агрегации, функцию активации и собственно выход. Такая модель имеет следующее обобщенное описание:

$$y_j = F\left(\Psi_i(w_{ij} x_i) - \theta_j \right),$$

где y_j – выходной сигнал j-го нейрона; x_i – i-й входной сигнал; w_{ij} – вес синаптической связи i-го входа j-го нейрона; Ψ – функция агрегации; F – функция активации (передаточная функция, функция срабатывания); θ_j – порог.

Искусственный нейрон – это устройство, агрегирующее входные сигналы, умноженные на синаптические веса, и применяющее к полученной взвешенной сумме нелинейную активационную

функцию, непрерывную на области определения. Полученный результат является выходом искусственного нейрона (рис. 2).

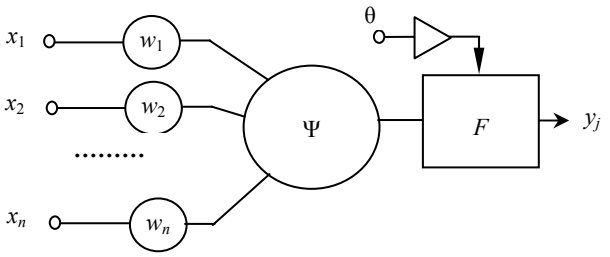

Рис. 2. Модель искусственного нейрона на основе перемножения значений «вход–вес»

Первая модель искусственного нейрона, предложенная в работе [12], имитировала два состояния нейрона «активный-пассивный», реализуя простую пороговую функцию. Состояние нейрона определялось путем вычисления взвешенной суммы состояний нейронов, подключенных к данному нейрону:

$$y_j = \begin{cases} 1, \text{ если } \sum_i w_{ij} x_i > \theta_j; \\ 0, \text{ иначе.} \end{cases}$$

Кроме пороговой функции (функции Хевисайда) в моделях данного типа в дальнейшем стали применяться следующие активационные функции: логистическая функция, сигмоидальная функция, функция Гаусса и др. Нелинейная дифференцируемая функция дает плавный переход от 0 к 1 по мере увеличения активации от минимального до максимального значения.

Комбинированный нейрон. Автор работы [13] в качестве функции агрегации рассматривает суммирование (Σ) либо перемножение (П) и утверждает, что сети с комбинацией суммирующих и перемножающих нейронов в разных слоях эффективнее, чем сети с одним типом нейронов. Сети с комбинированными нейронами намного быстрее обучаются при меньшей либо сопоставимой ошибке. Модели комбинированных нейронов представлены на рис. 3.

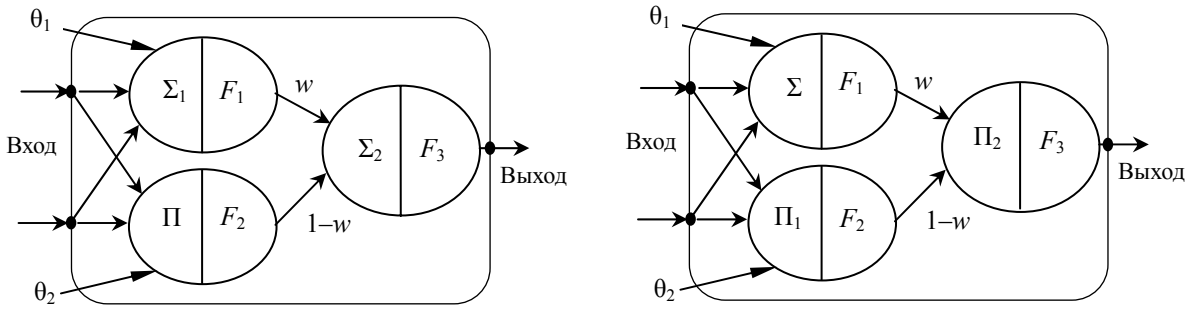

Рис. 3. Модели комбинированных нейронов

В суммирующем нейроне в качестве функции активации в работе [13] предлагается использовать сигмоидальную функцию, а функцию Гаусса – в перемножающем нейроне. Общий выход нейрона определяется функциями двух выходов O_Σ и O_Π с весами w и $1–w$ соответственно. Математически выход j-го комбинированного нейрона суммирующего типа вычисляется следующим образом:

$$y_j = wO_\Sigma + (1-w)O_\Pi,$$

а выход j-го комбинированного нейрона перемножающего типа – по формуле

$$y_j = O_\Sigma^w \cdot O_\Pi^{1-w}.$$

Автор работы [13] отмечает следующие достоинства комбинированных нейронов: 1) меньшее число неизвестных весов; 2) меньшее время обучения; 3) меньший объем обучающих данных; 4) меньшая сложность сети на комбинированных нейронах по сравнению с многослойной традиционной сетью; 5) более гибкая структура.

В работах [14–16] предложены модели нейронов, в которых агрегация основана на концепции обобщенного среднего входных сигналов.

Введенное в работе [17] обобщенное среднее n аргументов $A_1, A_2, \ldots, A_n$, определенных на интервале [0,1], – это функция φ: $[0,1]^n \to [0,1]$ такая, что

$$\varphi(A_1, A_2, \ldots, A_n; r, c_1, c_2, \ldots, c_n) = \left[\sum_{i=1}^{n} c_i A_i^r\right]^{\frac{1}{r}},$$

где r, c_i – действительные числа, $c_i \geq 0$, причем $\sum_{i=1}^{n} c_i = 1$.

Функция агрегации в модели нейронов с обобщенным средним имеет следующий вид:

$$\Psi = \frac{1}{n}\left[\sum_{i=1}^{n} x_i^r\right]^{\frac{1}{r}},$$

где r – обобщающий параметр, меняя который, можно получить различные операции над входными сигналами (таблица).

Обобщающий параметр и соответствующие ему операции

r	Функция агрегации	Операция
$\to +\infty$	$\max_i(x_i)$	Максимум
2	$\frac{1}{n}\left[\sum_{i=1}^{n} x_i^2\right]^{\frac{1}{2}}$	Среднеквадратичное
1	$\frac{1}{n}\sum_{i=1}^{n} x_i$	Среднеарифметическое
$\to 0$	$\left[\prod_{i=1}^{n} x_i\right]^{\frac{1}{n}}$	Среднегеометрическое
-1	$\frac{1}{n}\left[\sum_{i=1}^{n} \frac{1}{x_i}\right]^{-1}$	Гармоническое среднее
$\to -\infty$		Минимум

Решая задачи классификации и аппроксимации, авторы работ [14–16] провели сравнительный анализ многослойных сетей, построенных на основе концепции обобщенного среднего, и многослойных персептронов с традиционными нейронами. Результаты работы авторских сетей превзошли результаты работы многослойных персептронов, подтвердив тем самым перспективность применения данного типа нейронов для решения практических задач.

Нечеткие нейроны. Неоспоримым достоинством искусственных нейронных сетей является их обучаемость, основной недостаток – слабая интерпретируемость, которая легко преодолевается в системах, построенных на основе нечеткой логики [18, 19, 20].

Оба формализма, как нечеткие системы так и нейронные сети, являются параллельными динамическими системами, реализующими функции оценки выходов по заданным входным данным. Важно отметить, что формирование выходов проводится не на основе математической модели, а на основе обучения на ретроспективных данных. В работах [21, 22] доказана эквивалентность определенных типов нечетких систем и нейронных сетей.

Слияние нечеткой логики и нейронных сетей – одно из перспективных направлений исследований в вычислительном интеллекте. Существуют различные технологии синтеза нейро-нечетких сетей. По одной из них нейроны в нейро-нечетких сетях выполняют операции нечеткой логики, такие как нечеткая дизъюнкция, нечеткая конъюнкция, нечеткая импликация, вместо стандартных операций умножения и сложения [23].

Базовая модель нечеткого нейрона во многом схожа с моделью искусственного нейрона на основе перемножения значений «вход–вес». Основные отличия заключается в том, что на вход нейрона поступают нечеткие значения и в качестве функции агрегации используется не суммирование, а специальная нечеткая операция агрегирования. Ниже приведены несколько специфических моделей нечетких нейронов, описанных в работе [24].

Нечеткий нейрон, описываемый логическим уравнением, имитирует нечеткое ЕСЛИ-ТО правило следующего вида:

$$\text{ЕСЛИ } X_{1i} \text{ И } X_{2i} \text{ И } \ldots, \text{ И } X_{ni} \text{ ТО } Y_i,$$

где X_{ji} и Y_i – вход и выход i-го нейрона, описанного i-м правилом.

Такой нейрон может быть представлен нечетким отношение вида

$$R_i = I\,(T\,(X_{1i}, X_{2i}, \ldots, X_{ni}), Y_i),$$

в котором I – функция импликации; T – t-нормальная функция, реализующая операцию нечеткой конъюнкции.

Модель *нечеткого нейрона с четкими входами и четким выходом* приведена на рис. 4.

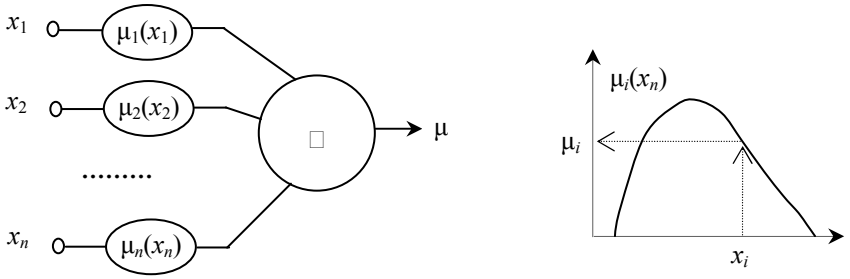

Рис. 4. Модель нечеткого нейрона с четкими входами/выходом

В отличие от предыдущего нейрон данного типа не описывает ЕСЛИ-ТО правило, здесь проводятся сначала операции фаззификации по каждой входной переменной, эти операции подобны синаптическому взвешиванию. Результаты выполнения этих операций подаются на вход оператора агрегации □. Такая операция выполняется на основе t-нормальной (нейрон типа И) или t-конормальной функции (нейрон типа ИЛИ).

Модель *нечеткого нейрона с нечеткими входами и нечетким выходом* приведена на рис. 5. Отличие данного типа нейрона от предыдущего заключается в том, что входы и выход нейрона являются нечеткими термами. Синаптическое взвешивание нечеткого входа основано не на функции принадлежности, а операции модификации входного терма, что приводит к формированию другого нечеткого терма. Схемы модификации могут быть различными, на рис. 5 показана комбинированная схема, включающая сдвиг и изменение формы нечеткого терма.

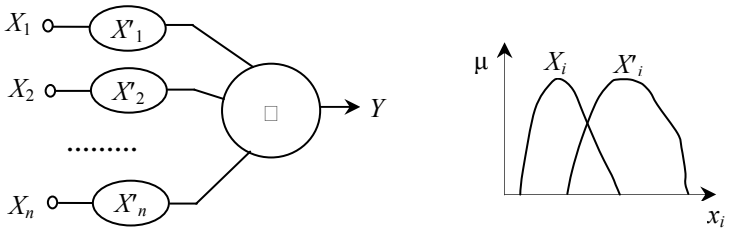

Рис. 5. Модель нечеткого нейрона с нечеткими входами/выходом

Модифицированные входы объединены оператором агрегации, выходом которого является нечеткий терм. Оператор агрегации □ может быть выполнен также либо на основе t-нормальной, либо t-конормальной функции.

В процессе обучения или настройки нечеткий нейрон может, помимо изменения «синаптических весов, менять свою структуру. В нечетких нейронах первого типа могут изменяться правила, функции принадлежности и/или функции импликации и агрегации. В нечетких нейронах второго и третьего типа могут меняться t-нормальные либо t-конормальные функции [24].

Для реализации нечетких систем типа синглтон (систем Такаги–Сугено 0-порядка) в работе [25] предложена нейро-нечеткая сеть, в основе которой лежит нео-нечеткий нейрон, модель которого приведена на рис. 6.

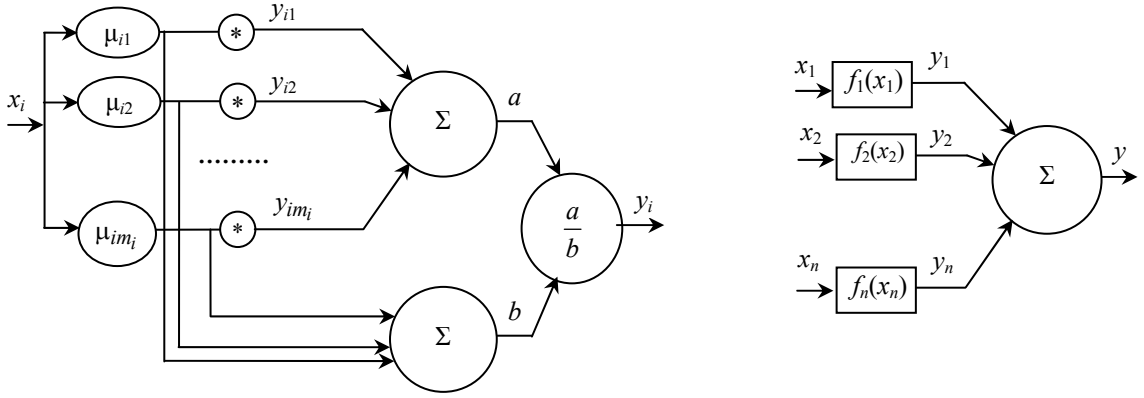

Рис. 6. Модель нео-нечеткого нейрона и структура нео-нечеткой сети

Выход нео-нечеткой сети определяют *n* нейронов [26] по следующей формуле:

$$y = \sum_{i=1}^{n} f_i(x_i) = \sum_{i=1}^{n} y_i(x_i).$$

Значение y_i, вычисляется на основе m_i нечетких правил:

$$y_i = \frac{\sum_{j=1}^{m_i} \mu_{ij} y_{ij}}{\sum_{j=1}^{m_i} \mu_{ij}} = \frac{a}{b}.$$

База правил для вычисления y_i имеет следующий вид:

$$R_i^1: \text{ ЕСЛИ } x_i = A_{i1} \text{ ТО } y_i = y_{i1}$$
$$R_i^2: \text{ ЕСЛИ } x_i = A_{i2} \text{ ТО } y_i = y_{i2}$$
$$\ldots\ldots\ldots\ldots\ldots\ldots\ldots\ldots$$
$$R_i^{m_i}: \text{ ЕСЛИ } x_i = A_{im_i} \text{ ТО } y_i = y_{im_i},$$

где A_{ij} – нечеткий терм, описываемый треугольной функцией принадлежности μ_{ij}.

Модель энергетического искусственного нейрона. Модель энергетического искусственного нейрона предложена в статье [27]. Модель основана на концепции энергии глиальных клеток, которые окружают биологические нейроны, обеспечивают условия для генерации и передачи нервных импульсов и осуществляют часть метаболических процессов самого биологического нейрона.

Энергетическая модель *EAN* описывается следующей семеркой:

$$EAN = <\mathbf{X}, \mathbf{O}, M, I, F, E_{AN}, L_{AN}>,$$

где **X** – вектор входных значений; **O** – вектор выходных значений; $M = M_w \cup M_L$ – двухкомпонентная локальная память, состоящая из долгосрочной и краткосрочной частей; I – интегрированное отображение; F – отображение активации, которое может иметь вид $o = f\left(\sum_{i-1}^{n} w_i x_i - \theta\right)$; E_{AN} – полная энергия текущего нейрона; L_{AN} – обобщенное правило обучения Хебба.

Структура *EAN* модели представлена на рис. 7.

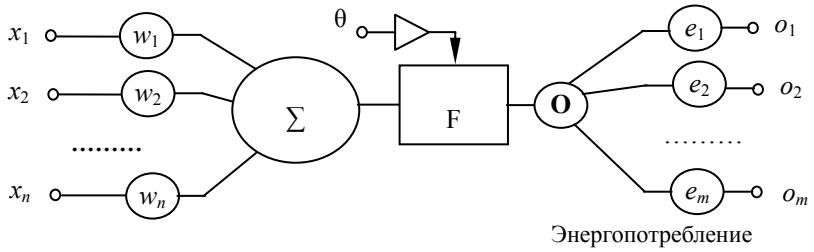

Рис. 7. Структура энергетической модели

Полная энергия нейрона EAN_i определяется как

$$E_{AN}^{(i)} = E_{AN}^{cons(i)} \cup E_{AN}^{surp(i)},$$

в которой первая часть показывает энергопотребление при установлении связи между нейронами, вторая часть указывает на избыточную энергию нейрона**.**

Комплекснозначный нейрон. Существует достаточно много задач, информация для решения которых может быть представлена в виде комплексных чисел [28]. Для решения таких задач применяются комплекснозначные искусственные нейронные сети, в которых входные сигналы, синаптические веса, пороговые значения и выходные сигналы – комплексные числа [29]. Выход *j*-го y_j нейрона вычисляется следующим образом:

$$y_j = F_c\left(\sum_{i=1}^{n} w_{ij} x_i + \theta j\right),$$

где y_j – комплексное значение выходного сигнал *j*-го нейрона; x_i – комплексное значение *i*-го входного сигнала; w_{ij} – комплексное значение веса синаптической связи *i*-го входа *j*-го нейрона; θ_j – ком-

плексное значение порога; F_C – функция активации, как правило, являющаяся суперпозицией действительных и мнимых сигмоид.

Модель многозначного нейрона, предложенного нашим соотечественником Игорем Айзенбергом, основана на принципах многозначной пороговой логики над полем комплексных чисел [30]. Многозначный нейрон выполняет отображение n входов в один выход. Это отображение описывается многозначной (k-значной) функцией от n переменных $F(x_1, \ldots, x_n)$ с n+1 комплекснозначным синаптическим весом:

$$F(x_1,...,x_n) = P(w_0 + w_1x_1 + ... + w_nx_n),$$

значение функции и переменных – комплексные числа, P – функция активации нейрона:

$$P(z) = \exp\left(\frac{i2\pi j}{k}\right), \ \text{if} \frac{2\pi j}{k} \le \arg z < \left[\frac{2\pi(j+)}{k}\right],$$

где i – мнимая единица, $j \in \{0, k-1\}$.

Несигмоидная функция активации в этой модели отображает комплексную плоскость на единичной окружности. Алгоритм обучения в предложенной модели основан на простом линейном правиле коррекции ошибок и не требует вычисления производных. Другим немаловажным достоинством алгоритма является его быстрая сходимость [30].

Заключение. Искусственные нейронные сети могут быть применены для решения сложных инженерных и академических задач. Основные требования, предъявляемые к искусственным нейронным сетям, – невысокая сложность, быстрая сходимость, устойчивость и надежность полученных результатов. Во многом указанные требования обеспечиваются выбором подходящей архитектуры вычислителя – искусственного нейрона. В этой связи, важным являются знания о функциональных возможностях конструкций различных искусственных нейронов.

В настоящей работе рассмотрен лишь отдельный класс искусственных нейронов, в моделях которых не присутствует время. Узость обзора обусловлена ограничениями на объем статьи. В дальнейшем планируется рассмотреть модели динамических искусственных нейронов и подходы к аппаратной реализации нейронных сетей.

Литература

1. Furber S. Neural Systems Engineering / S. Furber, S. Temple // Studies in Computational Intelligence. – Vol. 115. Computational Intelligence: A Compendium. – Berlin: Springer-Verlag, 2008. – P. 763–796.

2. Skocik M.J. On the Capabilities and Computational Costs of Neuron Models / M.J. Skocik, L.N. Long // IEEE Transactions on neural networks and learning systems. – 2014. – Vol. 25. – P. 1474–1483.

3. Gerstner W. Spiking Neuron Models: Single Neurons, Populations, Plasticity / W. Gerstner, G. Kistler. – Cambridge: Cambridge University Press, 2002. – 496 p.

4. Ahmed F.Y.H. Computing with Spiking Neuron Networks A Review / F.Y.H. Ahmed, B. Yusob, H.N.A. Hamed // International Journal of Advances in Soft Computing and its Applications. – 2014. – Vol. 6. – P. 1–21.

5. Kasabov N. Evolving Spiking Neural Networks and Neurogenetic Systems for Spatio- and Spectro-Temporal Data Modelling and Pattern Recognition // WCCI 2012 Plenary/Invited Lectures. LNCS 7311. – Heidelberg: Springer-Verlag: 2012. – P. 234–260.

6. Pasemann F. A Simple Chaotic Neuron // Physica D. – 1997. – Vol. 104. – P. 205–211.

7. Bershadskii A. Chaotic neuron clock / A. Bershadskii, Y. Ikegaya // Chaos, Solitons & Fractals. – 2011. – Vol. 44. – P. 342–347.

8. Starzyk J.A. Comparison of Two Memristor Based Neural Network Learning Schemes for Crossbar Architecture / J.A. Starzyk, Basawaraj // IWANN. – 2013. – Part I, LNCS 7902. – Heidelberg: Springer-Verlag, 2013. – P. 492–499.

9. Wen S. Associative Learning of Integrate-and-Fire Neurons with Memristor-Based Synapses / S. Wen, Z. Zeng, T. Huang // Neural Process Letters. – 2013. – Vol. 38. – P. 69–80.

10. Арбиб М. Метафорический мозг. – М.: Мир, 1976. –296 с.

11. Sheffield M.E.J. Calcium transient prevalence across the dendritic arbour predicts place field properties / M.E.J. Sheffield, D.A. Dombeck // Nature. – 2015. – Vol. 517. – P. 200–204.

12. McCulloch W.S. A logical calculation of the ideas immanent in nervous activity / W.S. McCulloch, W. Pitts // Bull. Math. Biophys. – 1943. – Vol. 5. – P. 115–133.

13. Chaturvedi D.K. Soft Computing Techniques and its Applications in Electrical Engineering // Studies in Computational Intelligence. – Vol. 103. – Berlin: Springer-Verlag, 2008. – 620 p.

14. Yadav R.N. Neural network learning with generalized-mean based neuron model / R.N. Yadav, P.K. Kalra, J. John // Soft Computing. – 2006. – Vol. 10. – P. 257–263.

15. Tripathi B.K. High Dimensional Neurocomputing. – Springer India, 2015. – 179 p.

16. Complex generalized-mean neuron model and its applications / B.K. Tripathi, B. Chandra, M. Singh, P.K. Kalra // Applied Soft Computing. – 2011. – Vol. 11. – P. 768–777.

17. Dyckhoff H. Generalized means as model of compensative connectives / H. Dyckhoff, W. Pedrycz // Fuzzy Sets and Systems. – 1984. – Vol. 14. – P. 143–154.

18. Корниенко И.С. Программно-инструментальный комплекс идентификации нечетких систем / И.С. Корниенко, О.А. Серебренникова, И.А. Ходашинский // Доклады Томского государственного университета систем управления и радиоэлектроники. – 2012. – Т. 1, № 1. – С. 60–64.

19. Ходашинский И.А. Алгоритмы генерации структур двухкритериальных парето-оптимальных нечетких аппроксиматоров / И.А. Ходашинский, И.В. Горбунов, Д.С. Синьков // Доклады Томского государственного университета систем управления и радиоэлектроники. – 2013. – № 1 (27). – С. 135–142.

20. Ходашинский И.А. Биоинспирированные методы параметрической идентификации нечетких моделей / И.А. Ходашинский, П.А. Дудин, А.В. Лавыгина // Доклады Томского государственного университета систем управления и радиоэлектроники. – 2007. – Т. 2. – С. 81–92.

21. Hayashi Y. Approximations between fuzzy expert systems and neural networks / Y. Hayashi, J.J. Buckley // International Journal of Approximate Reasoning. – 1994. – Vol. 10. – P. 63–73.

22. Jang J.S.R. Functional equivalence between radial basis function networks and fuzzy inference systems / J.S.R. Jang, C.T. Sun // IEEE Trans. Neural Networks. – 1993. – Vol. 4. – P. 156–159.

23. Mitra S. Neuro-fuzzy rule generation: survey in soft computing framework / S. Mitra, Y. Hayashi // IEEE Transactions Neural Networks. – 2000. – Vol. 11. – P. 748–768.

24. Gupta M.M. On fuzzy neuron models / M.M. Gupta, J. Qi // Proceedings of International Joint Conference on Neural Networks. – Vol. 2: Seattle. – 1991. – P. 431–436.

25. A neo fuzzy neuron and its applications to system identification and predictions to system behavior / T. Yamakawa, E. Uchino, T. Miki, H. Kusabagi // Proceedings of the International Conference on Fuzzy Logic and Neural Networks. – Vol. 1. – Iizuka, 1992. – P. 477–484.

26. A fast learning algorithm for evolving neo-fuzzy neuron / A.M. Silva, W. Caminhas, A. Lemos, F. Gomide // Applied Soft Computing. – 2014. – Vol. 14. – P. 194–209.

27. A Study on Energy Artificial Neuron Model and Its Applications in Self-growing and Self-organizing Neural Network / H. Liu, X. Ban, Z. Xu, M. Kurihara // Preprints of the 18th IFAC World Congress. – Milano, 2011. – P. 2662–2667.

28. Complex-Valued Neural Networks. Advances and Applications / Edited by A. Hirose. – John Wiley & Sons, Inc.: New Jersey, 2013. – 281 p.

29. Michel H.E. Artificial neural networks using complex numbers and phase encoded weights / H.E. Michel, A.A.S. Awwal // Applied optics. – 2010. – Vol. 49. – P. B71–B82.

30. Aizenberg I. Multilayer feedforward neural network based on multi-valued neurons (MLMVN) and a backpropagation learning algorithm / I. Aizenberg, C. Moraga // Soft Computing. – 2007. – Vol. 11. – P. 169–183.

Ходашинский Илья Александрович
Д-р техн. наук, профессор каф. КИБЭВС ТУСУРа
Тел.: 8 (382-2) 90-01-11
Эл. почта: hodashn@rambler.ru

Малютин Николай Дмитриевич
Д-р техн. наук, профессор, нач. отдела перспективных проектов ТУСУРа
Тел.: 8 (383-2) 52-79-42
Эл. почта: ndm@main.tusur.ru

Hodashinsky I.A., Maljutin N.D.
Static models of artificial neurons. Review

A static neuron model is analyzed in the paper. The static model do not have time as a parameter. We reviewed: simple neuron, generalized-mean neuron, fuzzy neuron, energy artificial neuron, and complex-valued neuron. Aggregation and activation functions are listed for each model as well as the inherent dignity of considered models of neurons is shown.
Keywords: artificial neuron, static model, aggregation function, function activation, simple neuron, generalized-mean neuron, fuzzy neuron, energy artificial neuron, and complex-valued neuron.