

УДК: 004.032.26

Исследование двухнейронных ячеек памяти в импульсных нейронных сетях

М. В. Киселев

Лаборатория робототехники и искусственного интеллекта,
Чувашский государственный университет им. И. Н. Ульянова,
Россия, 428018, г. Чебоксары, Московский проспект, д. 15

E-mail: mkiselev@chuvsu.ru

Получено 15.09.2019, после доработки — 11.12.2019.

Принято к публикации 26.12.2019.

В данной работе изучаются механизмы рабочей памяти в импульсных нейронных сетях, состоящих из нейронов – интеграторов с утечкой и адаптивным порогом при включенной синаптической пластичности. Исследовались относительно небольшие сети, включающие тысячи нейронов. Рабочая память трактовалась как способность нейронной сети удерживать в своем состоянии информацию о предъявленных ей в недавнем прошлом стимулах, так что по этой информации можно было бы определить, какой стимул был предъявлен. Под состоянием сети в данном исследовании понимаются только характеристики активности сети, не включая внутреннего состояния ее нейронов. Для выявления нейронных структур, которые могли бы выполнять функцию носителей рабочей памяти, была проведена оптимизация параметров и структуры импульсной нейронной сети с помощью генетического алгоритма. Были обнаружены два типа таких нейронных структур: пары нейронов, соединенных связями с большими весами, и длинные древовидные нейронные цепи. Было показано, что качественная рабочая память может быть реализована только с помощью сильно связанных нейронных пар. В работе исследованы свойства таких ячеек памяти и образуемых ими структур. Показано, что характеристики изучаемых двухнейронных ячеек памяти легко задаются параметрами входящих в них нейронов и межнейронных связей. Выявлен интересный эффект повышения селективности пары нейронов за счет несовпадения наборов их афферентных связей и взаимной активации. Продемонстрировано также, что ансамбли таких структур могут быть использованы для реализации обучения без учителя распознаванию паттернов во входном сигнале.

Ключевые слова: импульсная нейронная сеть, гомеостатическая синаптическая пластичность, распознавание пространственно-временных паттернов, рабочая память, нейрон – интегратор с утечкой, адаптивный пороговый мембранный потенциал, STDP

Работа выполнена при финансовой поддержке АО «Лаборатория Касперского».

UDC: 004.032.26

Exploration of 2-neuron memory units in spiking neural networks

M. V. Kiselev

Laboratory of robotics and artificial intelligence,
Chuvash state university,
15 Moscovsky pr., Cheboxary, 428018, Russia

E-mail: mkiselev@chuvsu.ru

*Received 15.09.2019, after completion — 11.12.2019.
Accepted for publication 26.12.2019.*

Working memory mechanisms in spiking neural networks consisting of leaky integrate-and-fire neurons with adaptive threshold and synaptic plasticity are studied in this work. Moderate size networks including thousands of neurons were explored. Working memory is a network ability to keep in its state the information about recent stimuli presented to the network such that this information is sufficient to determine which stimulus has been presented. In this study, network state is defined as the current characteristics of network activity only — without internal state of its neurons. In order to discover the neuronal structures serving as a possible substrate of the memory mechanism, optimization of the network parameters and structure using genetic algorithm was carried out. Two kinds of neuronal structures with the desired properties were found. These are neuron pairs mutually connected by strong synaptic links and long tree-like neuronal ensembles. It was shown that only the neuron pairs are suitable for efficient and reliable implementation of working memory. Properties of such memory units and structures formed by them are explored in the present study. It is shown that characteristics of the studied two-neuron memory units can be set easily by the respective choice of the parameters of its neurons and synaptic connections. Besides that, this work demonstrates that ensembles of these structures can provide the network with capability of unsupervised learning to recognize patterns in the input signal.

Keywords: spiking neural network, homeostatic synaptic plasticity, spatio-temporal pattern recognition, working memory, LIF neuron with adaptive threshold, STDP

Citation: *Computer Research and Modeling*, 2020, vol. 12, no. 2, pp. 401–416 (Russian).

The work was supported by Kaspersky Lab.

1. Введение

Взросший в последние два десятилетия интерес к таким нейросетевым парадигмам, как импульсные нейронные сети (ИНС), сверточные нейронные сети и сети глубинного обучения, объясняется мнением многих исследователей в этой сфере, что эти три направления могут послужить потенциальным базисом для прорывных информационных технологий близкого будущего. Особое внимание к первому из этих направлений, ИНС, уделяется потому, что этот класс нейросетевых моделей является самым близким к нейрофизиологической реальности [Gerstner, Kistler, 2002]. Как и нервные клетки мозга, модели нейронов в ИНС обмениваются короткими импульсами фиксированной амплитуды, так называемыми спайками (из-за чего эти нейросети называются еще спайковыми); как и в мозге, распространение спайков по сети происходит не мгновенно, а с определенными задержками, играющими важную роль в процессах обработки информации сетью; аналогично мозгу, ИНС представляет собой ансамбль достаточно простых и работающих полностью асинхронно элементов. Схожие принципы организации позволяют надеяться, что моделируемые на компьютере ИНС смогут столь же успешно справляться с задачей обработки огромных потоков многомодальной информации, как это делает мозг высших млекопитающих. Один из ключевых моментов, делающих ИНС столь привлекательными с этой точки зрения, является то, что они представляют собой нелинейные динамические системы с состоянием высокой размерности. Это дает им возможность обрабатывать информацию, имеющую сложную пространственно-временную структуру, распознавать во входном сигнале динамические паттерны.

Очевидно, что если речь идет о распознавании паттернов, значительно растянутых во времени, очень важной функциональной составляющей ИНС является механизм памяти. Уточним, что здесь имеется в виду так называемая рабочая память, проявляющаяся в виде специфической активности сети, а не долговременная память, являющаяся результатом обучения и зафиксированная в виде весов связей между нейронами и других структурных характеристик сети. Рабочая память необходима, например, затем, чтобы хранить информацию о начале такого длительного паттерна до его завершения, иначе он не будет распознан. Несмотря на функциональную важность механизма рабочей памяти, нейросетевые структуры, способные быть носителем этого механизма, исследованы недостаточно, особенно в привязке к механизму распознавания образов с учителем и без учителя. Очевидно, что запоминаться должна не вся информация о входном сигнале, что почти всегда невозможно, а только некоторые существенные черты этого сигнала, выделенные сетью. Несколько предыдущих работ автора данной статьи были посвящены этому предмету [Kiselev, 2011, 2013, 2020]. Основным недостатком изучавшихся в этих работах реализаций механизма рабочей памяти была низкая информационная емкость. Например, в модели, рассматриваемой в [Kiselev, 2020], для запоминания факта презентации одного из 30 возможных паттернов с достаточной надежностью требовалась сеть, включавшая около 100 000 нейронов. Большинство из предложенных на настоящий момент моделей рабочей памяти основаны на изменении состояний нейронов, например, за счет усложненного механизма синаптической пластичности, включающего логические компоненты, действующие на разных временных шкалах (как, например, в [Fiebig, Lansner, 2016]). Предлагалось несколько вариантов использования двухкомпонентной модели синаптической пластичности для реализации рабочей памяти (в частности, кратковременной синаптической пластичности [Tsodyks et al., 1998]). Например, в пионерской работе [Szatmary, Izhikevich, 2010] кратковременная компонента синаптической пластичности приводила к образованию так называемых полихронных нейронных групп (ПНГ), спонтанная активация которых, вызываемая шумовыми спайками в сети, индицирует недавнее появление во входном сигнале стимула, специфичного для данной ПНГ. Другие подходы используют понятие аттракторов [Lansner et al., 2013], метастабильных состояний сети, хранящих информацию в виде характеристик ее состояния. Дальнейшее развитие этой идеи, так называемые непрерывные аттракторы, рассматривается как возможный механизм запоминания непрерывных числовых величин [Seeholzer et al., 2019]. Проблема недоста-

точной информационной емкости стоит и перед многими моделями этого типа. Еще одним их недостатком является усложненная и труднореализуемая модель синаптической пластичности. Задачей данного исследования является нахождение надежных, емких и простых механизмов рабочей памяти в ИНС, основанных только на активности сети, и лишь долговременной синаптической пластичности.

2. Постановка задачи. Модель нейрона и сети

Современное состояние теории импульсных нейронных сетей таково, что чисто теоретическое изучение очень многих аспектов их свойств и поведения не представляется возможным. Большинство результатов в этой области получается с помощью компьютерного моделирования. Данное исследование в этом смысле не является исключением. Компьютерное моделирование происходит в форме итеративного пересчета состояния сети обычно с помощью многоядерных систем, где каждое процессорное ядро берет на себя задачу пересчета некоторого подмножества сети. Как уже говорилось, ИНС — это наиболее физиологически реалистичные нейросетевые модели. Так как принято считать, что минимальная длительность процессов, связанных с обработкой информации в мозгу, составляет порядка миллисекунды, то обычно один квант времени компьютерного моделирования в таких экспериментах также принимается равным 1 мс.

Процессы в импульсных нейронных сетях протекают в разных временных шкалах. Изменение состояния отдельных нейронов и распространение спайков по межнейронным связям занимают времена порядка миллисекунд или нескольких десятков миллисекунд. Процессы, связанные с обучением, — это достаточно медленные изменения синаптических весов. Характерные времена этих процессов на несколько порядков больше — секунды и более. Предмет данного исследования — это рабочая память — механизм, позволяющий хранить информацию о поступивших в недавнем прошлом на вход сети сигналах. Как уже говорилось во введении, этот вид памяти служит для интеграции отдельных компонентов пространственно-временных образов, разнесенных во времени. Временная шкала этой памяти, сотни миллисекунд, занимает промежуточное положение между быстрыми процессами генерации и распространения спайков и медленными изменениями синаптических весов, реализующими обучение и долговременную память. Очень важна оперативная доступность хранящейся в этой памяти информации. Поэтому этот вид памяти должен реализовываться в виде специфической активности сети.

Для того чтобы обеспечить описываемым экспериментам удобную контролируемость и интерпретируемость, использовался очень простой вид входного сигнала. Потоки спайков, подаваемых на вход сети, генерировались пуассоновскими случайными процессами. Пуассоновский процесс с частотой f Hz — это дискретный случайный процесс генерации спайка, такой, что вероятность сгенерировать спайк в данный квант времени (равный 1 мс) равна $f/1000$. Источником сигнала для сети являются N_I ее *входных узлов*. Каждый узел генерирует пуассоновский сигнал с небольшой частотой f_{noise} , имитирующий шум, всегда присутствующий в реальных сигналах. Кроме того, отдельные группы входных узлов в течение коротких периодов времени генерируют высокочастотный (с частотой $f_{\text{st}} \gg f_{\text{noise}}$) пуассоновский сигнал, соответствующий различным стимулам, которые должны быть запомнены сетью. Все входные узлы разбиты на n_s непересекающихся групп равного размера, так что одной группе соответствует один стимул. Сами стимулы короткие (30 мс), они следуют с периодом 100 мс, каждый очередной стимул выбирается случайно. Схематично вид входного сигнала показан на рис. 1. В описываемых экспериментах $f_{\text{noise}} = 0.1$ Hz, $f_{\text{st}} = 100$ Hz.

Наличие памяти в условиях такого входного сигнала проверяется вполне естественным способом. Если по активности сети, фиксируемой на протяжении очередного 100-миллисекундного периода, можно каким-либо образом определить, какой стимул был подан на сеть в предыдущий период, это и означает, что сеть сохранила («запомнила») информацию о подаваемом стимуле на время порядка 100 мс.




Рис. 1. Схематическая иллюстрация входного сигнала, используемого для оценки качества памяти ИНС (пояснения см. в тексте)

В процессе настоящего исследования было изучено несколько методик описания активности сети. В результате была выбрана самая простая из них: для каждого нейрона считалось количество сгенерированных им спайков в течение каждого периода (длиной 100 мс). Тем самым для сети, состоящей из N нейронов, каждый период описывался N целых чисел. При такой постановке задача оценки качества рабочей памяти сети превращается в задачу построения классификационной модели с N числовыми предикторами и дискретной целевой переменной, принимающей для каждого периода одно из n_s значений — номер стимула, поданного на сети в **предыдущем** периоде. Более сложные методики включали нахождение коррелированной активности нейронов, например подсчет количества пар спайков от двух нейронов, разделенных определенным интервалом времени. Такой подход приводил к огромному росту размерности задачи — количество предикторов становилось равным $N \times N \times d_{\max}$, где d_{\max} — максимальный интервал между спайками. Кроме того, корреляционные тесты, проведенные относительно индивидуальных предикторов такого типа, не показали наличия значимых корреляций между ними и целевой переменной (при условии поправки критического уровня значимости на число независимых тестов), поэтому от этих более сложных методик было решено отказаться.

Как говорилось во введении, было предложено много моделей реализации рабочей памяти в ИНС, однако какие именно нейросетевые структуры наиболее эффективны с этой точки зрения, пока оставалось неясным. Единственным несомненным свойством искомой ИНС является то, что она должна быть рекуррентной; так, рабочая память должна основываться на ее длящейся во времени активности. Поэтому было принято решение исследовать хаотические ИНС, которые могут включать самые разнообразные нейронные структуры, и попытаться выявить те структуры, которые реализуют механизм рабочей памяти. Более точно, ИНС, включающая как возбуждающие, так и тормозные нейроны, организована так, как если бы ее нейроны соответствовали точкам двух- или трехмерной сферы. Время распространения спайков по возбуждающим связям устанавливалось пропорциональным пространственной длине связи. Как во многих работах по моделированию хаотических ИНС [Szatmary, Izhikevich, 2010; Izhikevich, 2006], все тормозные связи были сделаны очень быстрыми (1 мс). Показано, что это препятствует развитию неустойчивости, вызванной наличием большого количества замкнутых нейронных конту-

ров с положительной обратной связью [Ledoux, Brunel, 2011]. Связи между нейронами выбирались случайно, но вероятность выбора зависела от расстояния между нейронами в соответствии с гауссовым законом:

$$p \sim e^{-\frac{(r-r_c)^2}{2s^2}}. \quad (1)$$

Для возбуждающих связей r_c был равен 0, а для тормозных — $r_c \geq 0$.

Таким образом, структура сети определялась следующим набором параметров:

- N — общее количество нейронов;
- R_t — доля тормозных нейронов среди них;
- n_A^+ — количество синапсов, связывающих возбуждающие нейроны и входные узлы (мы будем называть такие синапсы *афферентными*);
- n_A^- — количество афферентных синапсов у тормозных нейронов;
- P^+ — доля возбуждающих нейронов в сети, которые посылают спайки на один нейрон (для всех возбуждающих нейронов это число было одинаковым);
- P^- — то же (для тормозных нейронов);
- r_c — наиболее частая дальность тормозных связей;
- s^+ — разброс дальностей возбуждающих связей (см. (1));
- s^- — разброс дальностей тормозных связей.

В рамки этой модели попадает большой класс самых разнообразных хаотических ИНС.

За основу используемой модели нейрона взят нейрон-пороговый интегратор с уткой, наиболее часто применяемая при изучении больших ИНС модель [Gerstner, Kistler, 2002]. Точнее, использовалась модификация этой модели, включающая адаптивную подстройку порогового потенциала [Gerstner, Kistler, Naud, Paninski, 2014], что в случае рекуррентных сетей необходимо для компенсации роста возбуждения в замкнутых нейронных контурах. Возбуждающие синапсы при получении спайка дают мгновенный и пропорциональный весу синапса вклад в мембранный потенциал нейрона, а тормозные синапсы дают такой же вклад в мембранную проводимость. Таким образом, состояние нейрона в каждый момент времени t описывается его мембранным потенциалом $v(t)$, мембранной проводимостью $c(t)$ и порогом мембранного потенциала $T(t)$. Динамика этих величин подчиняется уравнениям

$$\begin{cases} \frac{dv}{dt} = -\frac{v}{\tau_v} - c(v - U_I) + \sum_{i,j} w_i^+ \delta(t - t_{ij}^+), \\ \frac{dc}{dt} = -\frac{c}{\tau_c} + \sum_{i,j} w_i^- \delta(t - t_{ij}^-), \\ \frac{dT}{dt} = -\frac{T-1}{\tau_T} + \sum_k \hat{T} \delta(t - \hat{t}_k), \end{cases} \quad (2)$$

дополненным условием, что если v становится большим или равным пороговому значению T , то в этот момент нейрон генерирует спайк, а величины v и c устанавливаются в 0. Смысл других величин, входящих в (2), следующий: τ_v — это временная константа приближения мембранного потенциала к 0 вследствие пассивной проводимости мембраны; τ_c — временная константа падения активной тормозной проводимости мембраны; U_I — реверсивный тормозной потенциал (отрицательный потенциал, к которому тормозные синапсы стремятся приблизить значение мембранного потенциала); τ_T — временная константа приближения порогового потенциала к его базовому значению, выбранному равным 1 (этот выбор приводит к тому, что все величины, описывающие веса и потенциалы, являются в сущности безразмерными); w_i^+ — вес

i -го возбуждающего синапса; w_i^- — вес i -го тормозного синапса; t_{ij}^+ — момент времени, в который i -й возбуждающий синапс получил j -й спайк; t_{ij}^- — момент времени, в который i -й тормозной синапс получил j -й спайк; \hat{T} — величина инкремента порогового потенциала нейрона при генерации им спайка; \hat{t}_k — момент генерации нейроном k -го спайка. Не все из этих параметров варьировались в обсуждаемых экспериментах. Некоторые из них должны иметь достаточно точно фиксированные значения. Например, U_I всегда выбирался равным $-0.1\hat{T}$; τ_c , как правило, очень мало (в нашем исследовании оно было равно 1.3 мс).

Еще одним важным компонентом модели является синаптическая пластичность — механизм, позволяющий сети обучаться, самоорганизовываться, формировать внутри себя нейронные структуры, специфически реагирующие на различные свойства входного сигнала. Как и в большинстве подобных исследований, используется модель синаптической пластичности, зависящая от времени генерации спайков (spike timing dependent plasticity — STDP) [Bi, Poo, 1998]. Однако, как и в случае с моделью нейрона, в модель синаптической пластичности должны быть введены поправки гомеостатического характера, которые уравнивали бы различные положительные обратные связи, наличествующие в рекуррентных ИНС. Введение этих поправок приводит к отличиям от классической модели STDP, которые перечислены ниже.

1. Аддитивный закон STDP применяется не к синаптическому весу w , а к монотонно зависящей от него величине, называемой *синаптическим ресурсом* W [Kiselev, 2016; Kiselev, Lavrentyev, 2019]:

$$w = w_{\min} + \frac{(w_{\max} - w_{\min}) \max(W, 0)}{w_{\max} - w_{\min} + \max(W, 0)}.$$

Таким образом, синаптический вес всегда ограничен значениями $[w_{\min}, w_{\max}]$. В данном исследовании w_{\min} всегда выбирался равным 0.

2. Уменьшение синаптического ресурса (LTD — long term depression) на постоянную величину ΔW^- происходит каждый раз, когда на синапс приходит спайк, в то время как правило для увеличения ресурса (LTP — long term potentiation) остается аналогичным стандартному STDP: в момент генерации нейроном спайка ресурсы всех его синапсов увеличиваются на величины $\Delta W^+ \exp\left(-\frac{\Delta t}{\tau_W}\right)$, где Δt — время, прошедшее с момента прихода самого недавнего спайка на данный синапс, а τ_W — константа (в нашем исследовании константы τ_W и τ_v принимались равными).
3. У активных нейронов величина LTP уменьшается. Это достигается тем, что в рассматриваемой модели ΔW^+ не является константой. Она уменьшается на величину d_{LTP} при каждой генерации нейроном спайка (но так, что ΔW^+ не становится отрицательным) и затем линейно растет до его базового значения $\overline{\Delta W^+}$ со скоростью i_{LTP} в миллисекунду. Этот механизм компенсирует очевидную положительную обратную связь: у активных нейронов за счет LTP увеличиваются шансы стать еще более активными.
4. Суммарный синаптический ресурс одного нейрона остается постоянным. Чтобы обеспечить выполнение этого требования, ресурсы всех синапсов умножаются на соответствующую величину (ренормализуются) при каждом акте LTD и LTP.

Таким образом, при приходе спайка на i -й возбуждающий синапс

$$W_j \leftarrow W_j + \begin{cases} -\Delta w^- & \text{для } j = i, \\ \frac{\Delta w^-}{n^+ - 1} & \text{для } j \neq i, \end{cases}$$

где n^+ — число возбуждающих синапсов (в нашем случае все возбуждающие синапсы все нейронов были пластичными), а при генерации спайка самим нейроном

$$W_j \leftarrow W_j + \Delta W^+ \left(\exp\left(-\frac{\Delta t_j}{\tau_W}\right) - \frac{1}{n^+} \sum_k \exp\left(-\frac{\Delta t_k}{\tau_W}\right) \right),$$

$$\Delta W^+ \leftarrow \Delta W^+ - d_{LTP}.$$

Теперь, полностью описав модель нейрона и всей сети, рассмотрим процесс нахождения в ней структур, способных быть носителями механизма рабочей памяти.

3. Нахождение нейронных структур, реализующих рабочую память, с помощью генетического алгоритма

Как уже говорилось, мы рассматриваем задачу нахождения структур ИНС, которые могут реализовывать функцию рабочей памяти как оптимизационную задачу. Оптимизируемыми переменными являются параметры структуры сети, модели нейрона и закона синаптической пластичности, рассмотренные в предыдущем разделе. Исключением являлись два параметра — размер сети N и константа ΔW^+ , задающая общую скорость изменения синаптических весов. Выбор первой из них $N = 3000$ определялся практическими возможностями используемой вычислительной системы (мощный математический сервер, оснащенный четырьмя GPU NVIDIA TITAN Xp) из тех соображений, чтобы время одного вычислительного эксперимента не превышало часа. Это разумное требование, учитывающее то, что в процессе оптимизации приходилось перебирать тысячи комбинаций оптимизируемых параметров. Такой выбор размера сети в значительной степени определил выбор размерности входного сигнала. Чтобы сложность сети и обрабатываемого ей сигнала были соразмерны, необходимо, чтобы количество входных узлов было в несколько раз меньше, чем нейронов в сети. С другой стороны, требуется обеспечить компромисс между количеством разных стимулов и количеством входных узлов, относящихся к одному стимулу. Эти соображения привели к выбору количества стимулов — 30 и количества входных узлов на один стимул — 20, что дает общее количество входных узлов, равное 600. Относительно константы ΔW^+ было установлено, что она не оказывает серьезного влияния на направление динамики синаптических весов, определяя только скорость этого процесса. В силу этого ее значение всегда выбиралось не очень малым — равным 0.1. Кроме того, в законе гомеостатической пластичности важным оказалось отношение величин d_{LTP} и i_{LTP} , а не их индивидуальные значения. Поэтому d_{LTP} был зафиксирован на величине 0.3, а варьировался лишь i_{LTP} . Общее количество оптимизируемых параметров оказалось, таким образом, равным 29.

Опишем, каким образом вычислялся критерий оптимизации для данного набора значений оптимизируемых параметров. В соответствии с этими значениями создается случайная ИНС. Случайная она в том смысле, что общие ее параметры фиксированы, но детальная картина нейронных связей выбирается генератором случайных чисел. Запускается процесс ее эволюции в соответствии с описанными в предыдущем разделе моделями нейрона и синаптической пластичности. В процессе моделирования сети происходит мониторинг значений синаптических весов (именно весов, а не ресурсов!) в ней. Сеть считается достигшей равновесного состояния, если общее изменение весов в расчете на одну итерацию становится меньше некоторой небольшой величины. Если этого не происходит на протяжении 1000 с моделирования, сеть оценивается как плохая (ей присваивается значение критерия, равное 0). После достижения равновесного состояния в течение еще 1000 с (т. е. для 10 000 стимулов) происходит накопление таблицы активности сети. Эта таблица из 10 000 строк и 3000 столбцов содержит количество спайков, которое нейрон номер i ($1 \leq i \leq 3000$) испустил в период предъявления стимула номер j ($1 \leq j \leq 10\,000$). Этой

таблице сопоставляется колонка из 10 000 значений — номеров стимулов, предъявленных сети на предыдущем периоде. На первых 6000 строк строится классификационная модель, где 3000 столбцов таблицы рассматриваются как предикторы, а столбец номеров стимулов — как целевая переменная. Эта модель тестируется на оставшихся 4000 строк. Количество правильно классифицированных строк и принимается за значение критерия оптимизации.

Требовалось решить вопрос о том, какой метод выбрать для создания классификационной модели. Он должен работать с очень многомерными данными, большим количеством целевых классов и строить классификационные модели без априорной информации о виде искомой зависимости. Поэтому, например, эксперименты с линейными классификационными моделями были неудачными. В результате был выбран метод, как раз и созданный для работы в этих условиях, а именно «случайный лес» (random forest) [Breiman, 2001]. Этот метод создает большой ансамбль голосующих деревьев решений. Большой размер этого ансамбля обеспечивает робастность классификации в условиях очень многомерных данных. Было показано, что данный метод дает приемлемые результаты даже для экстремального соотношения между количеством предикторов и количеством наблюдений [Moorthy, Mohamad, 2011].

Другой важный вопрос — какой алгоритм применить в данной оптимизационной задаче — решается с гораздо большей степенью определенности. В условиях многомерной оптимизации с большим количеством дискретных переменных и с дискретным критерием оптимизации, где плохо работают градиентные методы, хорошо себя зарекомендовал метод генетических алгоритмов [Fogel, 1998]. Генетические алгоритмы давно успешно применяются для оптимизации параметров нейронных сетей (см., например, обзор этих методик в [Panchal, Ganatra, 2012]), поэтому и в данном исследовании был применен этот метод. Основные параметры примененного генетического алгоритма следующие: размер популяции — 300, вероятность мутации одного индивида — 0.5, уровень элитизма — 10 %. Алгоритм останавливался, когда в 3 последовательных поколениях не было прогресса критерия оптимизации. Первоначальная область поиска в пространстве оптимизируемых параметров выбиралась максимально широкой (но, разумеется, в рамках разумных значений), чтобы минимизировать риск получения неоптимального решения. Дополнительно проверялось, не расположено ли найденное решение на границе этой области поиска.

Результаты описанной оптимизационной процедуры рассмотрены в следующем разделе.

4. Анализ результатов поиска структур ИНС, реализующих рабочую память, с помощью генетического алгоритма

Оптимизация свойства рабочей памяти у описанной в предыдущем разделе ИНС с помощью генетического алгоритма привела к нахождению ИНС, активность которой позволяла определить, какой стимул был предъявлен ей перед текущим стимулом, с точностью 93.85 %. Этот результат с уверенностью свидетельствует, что достаточно надежный механизм рабочей памяти может формироваться и в относительно небольших ИНС, состоящих из нескольких тысяч нейронов.

Этот результат был достигнут на 12-м поколении генетического алгоритма. Процесс роста точности по поколениям показан на рис. 2. Общее время счета составило около 12 дней.

Так как ИНС, созданные с одними и теми же параметрами, но имеющие разную детальную картину связей между нейронами, могут давать разную ошибку классификации, была измерена вариабельность ошибки для 10 сетей с одинаковым набором параметров. Стандартное отклонение ошибки оказалось равным 2 %. Это означает, что уже на 6-м поколении был фактически достигнут окончательный результат.

Анализ результата оптимизации включал три шага. Первый шаг состоял в определении важных и неважных параметров модели с точки зрения цели оптимизации. Беря за основу полученную оптимальную сеть, мы варьировали ее параметры, определяя, какое изменение параметров не снижает точности классификации более чем на 4 %. На втором шаге мы выясняли,

не было ли в процессе оптимизации обнаружено каких-то ИНС с существенно отличными от ИНС-победителя параметрами, также обладающими достаточно качественной памятью (в качестве пороговой точности брались 50 %). Наконец, на третьем шаге ИНС-победитель и ее возможные альтернативы детально изучались с целью понимания механизмов, лежащих в основе памяти.

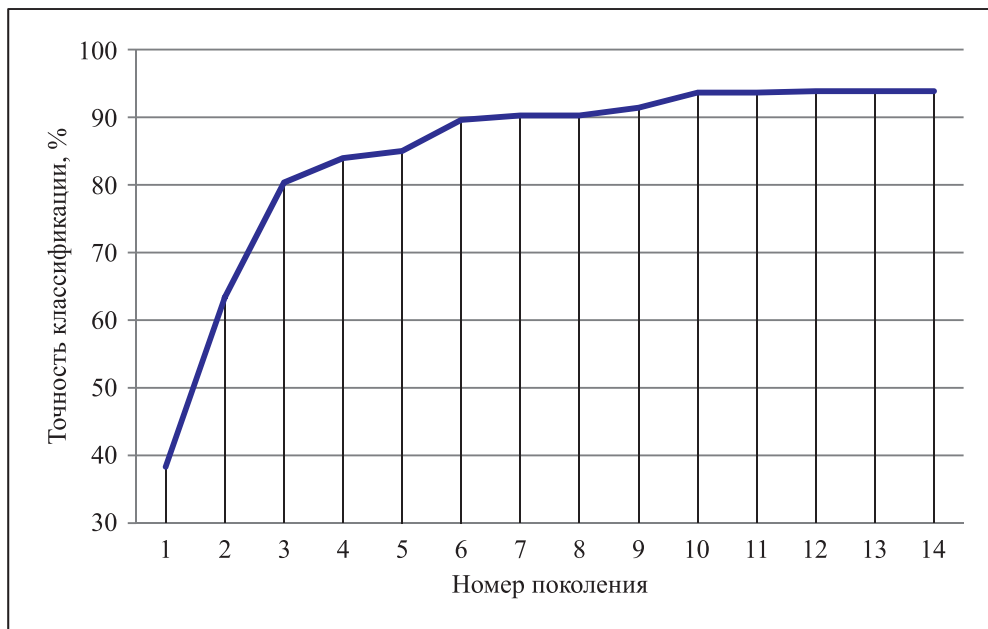


Рис. 2. Рост точности классификации стимулов по поколениям ИНС, оптимизируемых генетическим алгоритмом

Главный результат, полученный на первом шаге, заключался в том, что для обретения ИНС свойства рабочей памяти совершенно не требуется наличие тормозных нейронов. Для ИНС с долей тормозных нейронов, равной 0, точность практически не падала (92.1 %). Таким образом, примерно четверть всех оптимизируемых параметров, которые связаны с тормозными нейронами, оказываются не важными. Также не было важно, расположены нейроны на двух- или трехмерной сфере. Влияющие параметры и степень их вариабельности суммированы в таблице 1.

Параметры в таблице объединены цветом фона, отображающим их важность и свойство сети, которое они регулируют. Первая группа относится к рекуррентным связям в сети. Мы видим, что в лучшей сети нейроны связаны друг с другом сильными единичными связями, причем так, что связываются только близкие нейроны. Вторая группа определяет свойства афферентных связей, задавая общий уровень возбуждения сети внешним сигналом. Очевидно, что величины параметров этой группы определяются не столько свойствами сети, сколько свойствами внешнего сигнала. Например, сумма афферентных весов нейрона должна быть тем больше, чем слабее входной сигнал. Очевидно также, что для более интенсивного входного сигнала должно быть уменьшено значение ΔW^- , чтобы избежать излишнего подавления синапсов. Величина же n_A^+ есть результат компромисса. При очень большом его значении реакция всех нейронов на любой входной сигнал будет очень похожей, что затруднит распознавание паттернов. Но распознавания будет сложно достичь и при очень малом значении n_A^+ , так как не будет нейронов, связанных с достаточным количеством входных узлов, относящихся к одному паттерну. Третья группа параметров, как мы увидим ниже, определяет длительность рабочей памяти. Наконец, гомеостатический параметр i_{LTP} обеспечивает устойчивость динамики весов в рекуррентных сетях с высокой частотой генерации спайков.

Таблица 1. Диапазоны значений параметров ИНС, обеспечивающих формирование в ней механизма рабочей памяти

Обозначение	Смысл параметра	Исследуемый диапазон	Оптимальный диапазон
s^+	Средняя дальность возбуждающих связей	0.001–0.3	< 0.01
P^+	Количество связей «нейрон–нейрон» у одного нейрона	1–100	1
w_{\max}	Максимальное значение веса неафферентных синапсов	0.1–10	2.5–2.9
n_A^+	Количество афферентных синапсов	3–100	54–68
$w_{0,A}$	Начальное значение веса афферентных синапсов	0.03–0.3	0.036–0.06
$w_{\max,A}$	Максимальное значение веса афферентных синапсов	0.03–1	0.19–0.22
ΔW	Уменьшение синаптического ресурса при получении спайка	0.0001–0.1	0.011–0.014
τ_T	Время релаксации порога мембранного потенциала	0.1–3 с	0.12–0.3 с
\hat{T}	Инкремент порога мембранного потенциала	0.01–3	0.038–0.05
$1/i_{LTP}$	Время восстановления LTP после генерации спайка	1–30 мс	< 2.2 мс
τ_v	Время релаксации мембранного потенциала	3–30 мс	11–20 мс
w_0	Начальное значение веса неафферентных синапсов	0.01–0.1	0.044–0.167

На втором шаге исследовались все протестированные наборы оптимизируемых параметров, которые дали точность более 50 %. Разумеется, эти точки пространства значений параметров образуют большой плотный кластер около точки-победителя. Нашей задачей было выяснить, нет ли в этом пространстве еще каких-нибудь кластеров, кроме этого основного. При их наличии они бы указывали на возможность реализации механизма рабочей памяти несколькими разными механизмами, пусть и отличающейся эффективностью. Однако применение статистического алгоритма многомерной кластеризации, основанного на плотности точек [Kiselev et al., 1999] (который был выбран, так как не требует априорного задания количества кластеров и проверяет статистическую значимость результатов кластеризации), верифицированного другими методами кластеризации (алгоритмы K-средних и expectation maximization), не показало наличия нескольких разделенных между собой кластеров как в пространстве всех оптимизируемых параметров, так и в его различных подпространствах. Единственным исключением оказалось распределение величины s^+ (рис. 3).

На нем обращает внимание наличие небольшого числа ИНС с очень далекими межнейронными связями. При этом распределение остальных параметров не отличается значимо от основной группы ИНС. Интерпретация этому факту будет дана на следующем шаге анализа, чья цель — достичь детального понимания реализации механизма рабочей памяти в ИНС.

Анализ величин, приведенных в таблице 1, дает достаточно простую картину структуры оптимальной ИНС. У каждого нейрона имеется лишь одна входная связь от другого нейрона. При этом длины этих связей очень маленькие — все нейроны связаны лишь с их ближайшими соседями. Это приводит к тому, что типичная нейронная структура в такой ИНС — это связанные друг с другом взаимными связями пары нейронов, которые в некоторых случаях могут давать еще короткие линейные ответвления. Небольшой фрагмент такой сети показан на рис. 4.

Изучение файла мониторинга сети показывает, что все межнейронные связи быстро (за 200–300 с) становятся очень сильными — их веса делаются близкими w_{\max} .




Рис. 3. Распределение дальности межнейронных связей для ИНС с точностью классификации стимулов более 50 %




Рис. 4. Пример конфигурации межнейронных связей в небольшом фрагменте сети: результат генетического алгоритма. Выделены двухнейронные ячейки памяти

Механизм рабочей памяти работает следующим образом. В процессе обучения без учителя нейроны обучаются избирательно реагировать на определенные стимулы. Если один из нейронов, входящих в пару, срабатывает, реагируя на распознаваемый им стимул, он вызывает срабатывание второго нейрона в паре, так как они связаны очень сильной связью. В свою очередь, это вызывает повторное срабатывание первого и так далее. Однако этот процесс не длится бесконечно. При каждом срабатывании нейрона порог его возбудимости повышается. В конце концов он становится таким большим, что даже спайк, пришедший на единственный сильный синапс нейрона, не приводит к генерации спайка. Генерация спайков парой прекращается. Более того, в течение определенного времени, пока порог возбуждения не снизится к величине, близкой его базовому значению, эта нейронная пара в принципе не может генерировать спайки, так как возбуждение от афферентных синапсов относительно слабо (рефрактерный период).

Таким образом, активность какой-либо пары свидетельствует о том, что в недавнем прошлом сети был предъявлен распознаваемый этой парой стимул. Строго говоря, индикатор того, что данный стимул был именно в прошлом, а не в текущий момент, — это прекращение активности пары, а не сама ее активность. Такая модель рабочей памяти подтверждается анализом ошибок классификации. Более 90 % ошибок приходится на случаи, когда один и тот же стимул предъявляется два раза подряд. Из-за явления рефрактерности те пары, которые распознали первое предъявление стимула, уже не могут распознать его второй раз.

Наконец, чтобы выделить обсуждаемый механизм рабочей памяти в чистом виде, была построена ИНС с точно такими же характеристиками, что и рассмотренная выше оптимальная ИНС, но в которой все нейроны намеренно объединены в пары. Было обнаружено, что эта модификация не приводит к значимому изменению результата (точность 91.2 %).

Осталось объяснить, за счет чего качественное обучение без учителя распознаванию стимулов достигается без участия тормозных нейронов, что считается необходимым для обеспечения разнообразия распознаваемых стимулов [Maass, 2000]. Отчасти это можно объяснить конкурентным характером механизма синаптической пластичности (когда один синапс усиливается, остальные ослабляются). Однако главный вклад дает интересный специфический для рассматриваемых сильно связанных пар механизм. Допустим, в силу первоначальной флуктуации афферентных связей один из нейронов пары имеет больше, чем у других нейронов, связей с входами, относящимися к одному стимулу. Соответственно, этот нейрон распознает данный паттерн и заставляет это делать второй нейрон в паре. Но у второго нейрона нет этой аномалии — у него немного связей с данной группой входных узлов. Однако из-за действия нашей модификации закона пластичности усиливаются именно они (а остальные ослабляются). Так как этих усиливаемых синапсов мало, то второй нейрон делается даже еще более высокоселективным, чем первый, хотя без такой конфигурации связей у него вообще не было бы шансов распознать данный стимул. Вообще, процесс настройки весов является весьма чувствительным для формирования памяти. Так, если в ИНС, составленной из пар нейронов, все межнейронные связи сразу сделать очень сильными и непластичными, точность распознавания резко снизится до 77 %.

Отметим, что в этой схеме принципиальную роль играет гомеостатический закон пластичности, снижающий эффект LTP у высокоактивных нейронов. LTP позволяет нейронам научиться специфически реагировать на какой-то определенный паттерн, поэтому оно должно работать только в самом начале активности ячейки памяти — пока длится запоминаемый стимул. Если продлить его действие на весь период активности, то синаптические веса будут меняться под действием спайков, не имеющих никакого отношения к запоминаемому стимулу, что разрушило бы результат обучения.

После интерпретации реализации рабочей памяти в рассмотренной оптимальной ИНС становится понятным, каким образом память, хотя и плохого качества, реализуется в сетях с большими значениями s^+ , о которых говорилось выше. В этих сетях носителями рабочей памяти являются длинные ветвящиеся цепи нейронов, соединенных сильными связями. Память длится, пока по цепи передается сигнал. Очевидно, что такой механизм проигрывает механизму, основанному на нейронных парах, во всем (что и проявляется в результатах оптимизации). В одном акте запоминания каждый нейрон участвует ровно один раз, поэтому считывание такой памяти проблематично. Длительность рабочей памяти ограничивается длиной этих нейронных «деревьев», а в хаотической сети не может быть большого количества разных таких ансамблей с достаточно длинным путем от корня к вершине. Хуже и информационная емкость — один большой древовидный ансамбль кодирует появление лишь одного стимула.

Описанный результат можно трактовать как весомый довод в пользу утверждения, что в ИНС из нескольких тысяч нейронов, описываемых моделью LIF с адаптивным порогом и рассмотренным выше законом синаптической пластичности, единственный надежный механизм рабочей памяти может быть основан лишь на сильно связанных нейронных парах (с той оговоркой, что рассматривается только случай частотного кодирования сигнала, когда точное расположение спайков на временной оси несущественно). Свойства этих структур чуть подробнее рассмотрим в следующем разделе.

5. Свойства сильно связанных нейронных пар

Выявленные с помощью генетического алгоритма двухнейронные носители рабочей памяти легко поддаются теоретическому анализу. Основными их параметрами являются w_{\max} (вес межнейронной связи), l (время прохождения спайка по этой связи), τ_T (временная константа падения порога мембранного потенциала), \hat{T} (инкремент порога мембранного потенциала). Нетрудно видеть, что:

- частота генерации спайков активной ячейкой памяти равна $1/2l$;
- так как за время активности ячейки порог ее нейронов повышается на \hat{T} за период $2l$ и при этом все время экспоненциально стремится к 1 с постоянной времени τ_T , то длительность памяти равна примерно $-\tau_T \ln \left(1 - \frac{2l(w_{\max} - 1)}{\tau_T \hat{T}} \right)$;
- длительность рефрактерного периода составляет порядка τ_T .

Как уже говорилось, для того, чтобы распознавание запоминаемых стимулов было устойчивым, необходимо, чтобы нейроны в активных парах были пластичны только в течение времени порядка длительности стимула τ . С начала активности пары пластичность ее нейронов падает со скоростью $\frac{d_{LTP}}{2l} - i_{LTP}$. Следовательно, должно выполняться требование $\frac{\Delta W^+}{\frac{d_{LTP}}{2l} - i_{LTP}} \sim \tau$.

Таким образом, мы видим, что двухнейронные ячейки памяти обладают предсказуемыми и хорошо управляемыми свойствами.

6. Заключение

В работе исследованы нейронные структуры, которые могут отвечать за реализацию механизма рабочей памяти в относительно небольших (включающих тысячи нейронов) ИНС, состоящих из пластичных нейронов — пороговых интеграторов с утечкой и адаптивным порогом. При этом ставилось условие, что информация о свойствах входного сигнала должна храниться в такой памяти (в отличие от постоянной долговременной памяти) исключительно в виде активности сети, а не в ее структуре (весах связей и т. д.). Поиск нейронных ансамблей, способных сохранять информацию о внешнем сигнале на протяжении времени, существенно большего, чем характерное время изменения мембранного потенциала, производился с помощью генетического алгоритма, оптимизирующего точность отложенного распознавания подаваемых на вход сети паттернов. Оптимизируемыми переменными при этом были параметры модели нейрона, законов синаптической пластичности, а также структурные характеристики сети. В результате этой численной оптимизации было обнаружено, что носителями рабочей памяти в ИНС рассматриваемого вида могут быть лишь два типа нейронных структур: пары нейронов, взаимно связанные мощными возбуждающими связями, и длинные древовидные нейронные цепи, также образуемые возбуждающими связями с большими весами. Однако второй тип структур сильно проигрывает первому практически по всем показателям, связанным с качеством памяти, и поэтому не может рассматриваться как надежный носитель кратковременной памяти.

Были изучены свойства обнаруженных двухнейронных ячеек памяти. Было показано, что их параметры достаточно просто управляются характеристиками входящих в них нейронов и межнейронных связей. Продемонстрировано, что ансамбли таких структур обладают, кроме того, достаточно высокой селективностью по отношению к разным входным сигналам и способностью к обучению без учителя даже в отсутствие структурных элементов, обычно применяемых для этой цели (таких как латеральные тормозные связи). Тем не менее для применения изучаемых нейронных пар для распознавания пространственно-временных образов в реали-

стичных условиях требуется разработать схемы включения этих ячеек в более сложные нейросетевые конфигурации, что и является предметом дальнейших исследований в рамках данного проекта. В рамках следующей фазы проекта будет, в частности, изучена масштабируемость полученных результатов на большее количество распознаваемых стимулов (при сохранении или увеличении числа входных узлов).

Все описанные в данной работе вычислительные эксперименты и их обработка проводились с помощью созданной автором библиотеки и набора утилит для моделирования больших ИНС ArNI/CC v. 2.2. Вычисления проводились на имеющихся в распоряжении автора компьютере с двумя GPU NVIDIA GTX TITAN X, компьютере с двумя GPU NVIDIA GTX 680, а также на мощном математическом сервере с четырьмя GPU NVIDIA TITAN Xp, предоставленном АО «Лаборатория Касперского».

Список литературы (References)

- Bi G. Q., Poo M. M.* Synaptic modifications in cultured hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell type // *Journal of Neuroscience*. — 1998. — Vol. 18, No. 24. — P. 10464–10472.
- Breiman L.* Random Forests // *Machine Learning*. — 2001. — Vol. 45, No. 1. — P. 5–32.
- Fiebig F., Lansner A.* A Spiking Working Memory Model Based on Hebbian Short-Term Potentiation // *The Journal of Neuroscience*. — 2016. — Vol. 37, No. 1. — P. 83–96.
- Fogel D. B.* (ed.) *Evolutionary Computation: The Fossil Record*. — N.Y.: IEEE Press, 1998.
- Gerstner W., Kistler W.* *Spiking Neuron Models. Single Neurons, Populations, Plasticity*. — Cambridge University Press, 2002.
- Gerstner W., Kistler W., Naud R., Paninski L.* *Neuronal Dynamics: From Single Neurons to Networks and Models of Cognition*. — Cambridge University Press, 2014.
- Izhikevich E.* Polychronization: Computation With Spikes // *Neural Computation*. — 2006. — Vol. 18. — P. 245–282.
- Kiselev M.* Chaotic Spiking Neural Network Connectivity Configuration Leading to Memory Mechanism Formation // Kryzhanovsky B., Dunin-Barkowski W., Redko V., Tiumentsev Y. (eds.) *Advances in Neural Computation, Machine Learning, and Cognitive Research III. NEUROINFORMATICS 2019. Studies in Computational Intelligence*. — Vol. 856. — Springer, Cham, 2020. — https://doi.org/10.1007/978-3-030-30425-6_47
- Kiselev M.* Rate Coding vs. Temporal Coding — Is Optimum Between? // *Proceedings of IJCNN-2016*. — 2016. — P. 1355–1359.
- Kiselev M.* Self-Organization Process in Large Spiking Neural Networks Leading to Formation of Working Memory Mechanism // Rojas I., Joya G., Cabestany J. (eds.) *Proceedings of IWANN*. — 2013, LNCS. — Vol. 7902, Part I. — P. 510–517.
- Kiselev M.* Self-organized Short-Term Memory Mechanism in Spiking Neural Network // *Proceedings of ICANNGA*. — 2011. — Part I, Ljubljana. — P. 120–129.
- Kiselev M. V., Ananyan S. M., Arseniev S. B.* LA — a Clustering Algorithm with an Automated Selection of Attributes, which is Invariant to Functional Transformations of Coordinates // *Proceedings of 3rd European Symposium on Principles of Data Mining and Knowledge Discovery PKDD'99 in: Lecture Notes in Artificial Intelligence*. — Vol. 1704. — Springer, 1999. — P. 366–371.
- Kiselev M., Lavrentyev A.* A Preprocessing Layer in Spiking Neural Networks — Structure, Parameters, Performance Criteria // *Proceedings of IJCNN-2019*. — 2019. — Paper N-19450.
- Lansner A., Marklund P., Sikström S., Nilsson L.-G.* Reactivation in Working Memory: An Attractor Network Model of Free Recall // *PLoS ONE*. — 2013. — Vol. 8, No. 8. — P. e73776. — <https://doi.org/10.1371/journal.pone.0073776>

- Ledoux E., Brunel N.* Dynamics of networks of excitatory and inhibitory neurons in response to time-dependent inputs // *Front Comput Neurosci.* — 2011. — Vol. 5, No. 25. — doi:10.3389/fncom.2011.00025
- Maass W.* On the computational power of winner-take-all // *Neural computation.* — 2000. — Vol. 12, No. 11. — P. 2519–2535.
- Moorthy K., Mohamad M. S.* Random forest for gene selection and microarray data classification // *Bioinformatics.* — 2011. — Vol. 7, No. 3. — P. 142–146. — DOI:10.6026/97320630007142
- Panchal G., Ganatra A.* Optimization of Neural Network Parameter using Genetic Algorithm. — Lambert Academic Publishing, 2012.
- Seeholzer A., Deger M., Gerstner W.* Stability of working memory in continuous attractor networks under the control of short-term plasticity // *PLoS Computational Biology.* — 2019. — Vol. 15, No. 4. — P. e1006928. — <https://doi.org/10.1371/journal.pcbi.1006928>
- Szatmary B., Izhikevich E.* Spike-Timing Theory of Working Memory // *PLoS Computational Biology.* — 2010. — Vol. 6, No. 8. — P. e1000879.
- Tsodyks M., Pawelzik K., Markram H.* Neural networks with dynamic synapses // *Neural Computation.* — 1998. — No. 10. — P. 821–835.