

ОБЗОРЫ АКТУАЛЬНЫХ ПРОБЛЕМ

Нелинейная динамика и машинное обучение рекуррентных спайковых нейронных сетей

О.В. Масленников, М.М. Пугавко, Д.С. Шапин, В.И. Некоркин

Описаны основные результаты в области построения и анализа рекуррентных спайковых нейронных сетей для моделирования функциональных сетей мозга. Приведены ключевые термины и определения из области машинного обучения. Представлены основные подходы к построению и исследованию спайковых и частотных нейронных сетей, обучаемых выполнять конкретные когнитивные функции. Описаны современные аппаратные нейроморфные системы, имитирующие обработку информации мозгом. Обсуждаются принципы нелинейной динамики, которые позволяют выявлять механизмы выполнения нейронными сетями целевых задач.

Ключевые слова: искусственные нейронные сети, нелинейная динамика, машинное обучение, спайковые нейроны, моделирование когнитивных функций

PACS numbers: 07.05.Mh, **84.35.+i**, 87.19.L –DOI: <https://doi.org/10.3367/UFNr.2021.08.039042>

Содержание

1. Введение (1089).
 2. Основы машинного обучения (1090).
 - 2.1. Три компонента машинного обучения.
 - 2.2. Модели нейронов.
 3. Рекуррентные нейронные сети в задачах моделирования функциональных свойств сетей мозга (1093).
 4. Спайковые нейронные сети (1098).
 - 4.1. Резервуарные вычисления.
 - 4.2. Нейроинженерная концепция.
 5. Аппаратные нейроморфные системы (1102).
 - 5.1. Нейроморфные системы Neurogrid и Braindrop.
 - 5.2. Нейроморфные системы BrainScaleS и SpiNNaker.
 - 5.3. Система TrueNorth.
 - 5.4. Система Loihi.
 - 5.5. Система "Алтай".
 - 5.6. Система Tianjic.
 6. Заключение (1106).
- Список литературы (1108).

1. Введение

Использование методов нелинейной динамики для исследования процессов в нейронных структурах мозга имеет достаточно длительную историю и восходит к пионерским работам английских электрофизиологов Э. Ходжкина и Э. Хаксли в области проводимости нервных импульсов. К настоящему времени в этом направлении достигнут значительный прогресс. По-

строены нелинейные динамические модели многих типов нейронов, изучена динамика как различных ансамблей, состоящих из сравнительно небольшого числа взаимодействующих нейронов, так и больших нейроморфных систем [1–6].

В журнале *Успехи физических наук* тематика, связанная с применением подходов нелинейной физики к исследованию динамических процессов в мозге и нейронных ансамблях, получила освещение в целом ряде обзоров [7–18]. В последние годы на передний край нейродинамики выдвинулись задачи моделирования когнитивных и функциональных свойств работающего мозга [19–21]. В частности, возрастающий интерес к этой тематике связан с созданием систем искусственного интеллекта, воспроизводящих ключевые свойства естественного интеллекта [22, 23]. Для решения таких задач требуется построение новых динамических моделей, которые могли бы воспроизводить, во-первых, сложную иерархическую организацию, а во-вторых, пластичность нейронных структур: их состав и внутрискруктурные и междискруктурные связи изменяются в зависимости от наличия или отсутствия информационных входов.

К настоящему времени в области динамического моделирования сложились два подхода [24, 25]. В рамках одного из них, так называемого *нисходящего*, модели оперируют модами мозговой активности — интегральными переменными, имитирующими высокоуровневые процессы в мозге [20]. В другом, *восходящем*, подходе к моделям нейронных структур, способным воспроизводить высшие функции мозга, приходят начиная с моделей отдельных нейронов за счёт реалистического описания межнейронных и междискруктурных связей [25, 26].

Ясно, что биологически релевантные модели обоих подходов должны основываться на экспериментальных данных. При экспериментальном изучении мозга нейро-

О.В. Масленников^(*), М.М. Пугавко, Д.С. Шапин, В.И. Некоркин
Федеральный исследовательский центр
Институт прикладной физики РАН,
ул. Ульянова 46, 603950 Нижний Новгород, Российская Федерация
E-mail: ^(*) olmaov@ipfran.ru

Статья поступила 1 июня 2021 г.,
после доработки 13 августа 2021 г.

физиологами регистрируется активность нейронов в состоянии покоя субъекта или при выполнении им определённой задачи. Для построения модели, опирающейся на экспериментальные данные, возможны два пути. Первый путь — это моделирование, основанное на данных, когда восстанавливается динамическая система, которая производит временные ряды, количественно близкие с экспериментально зарегистрированными. Второй путь — моделирование, основанное на решаемых поведенческих задачах, когда в ходе эксперимента регистрируются данные о преобразовании сенсорных входов в определённые моторные выходы и задача состоит в восстановлении динамической системы, производящей аналогичные преобразования входов в выходы [27].

Современные методы исследования мозга: позитронно-эмиссионная томография (ПЭТ), электроэнцефалография (ЭЭГ), магнитоэнцефалография (МЭГ), спектроскопия в ближней инфракрасной области (фБИКС), обладающие высоким временным разрешением, и магнитно-резонансная томография (МРТ), имеющая хорошее пространственное и удовлетворительное временное разрешение, — позволили сформировать огромные базы данных.

Однако непосредственное использование экспериментальных данных в динамических моделях представляет собой чрезвычайно сложную задачу. Сейчас для выхода из этой противоречивой ситуации стали активно использоваться компьютерные технологии машинного обучения для нахождения скрытых закономерностей преобразования входных сигналов в выходные [28–31]. В этом направлении, на наш взгляд, особенно перспективным выглядит построение и обучение моделей на основе *рекуррентных спайковых нейронных сетей* [32–36]. Модели данного типа имеют аналогии с сетями мозга в двух существенных аспектах. *Рекуррентная архитектура*, свойственная большинству отделов головного мозга, характеризуется наличием петель обратной связи, что позволяет сети не только испытывать непосредственное влияние входных стимулов, но и откликаться на собственное поведение в прошлом. *Спайковая динамика*, т.е. способность генерировать потенциалы действия, или спайки, — одно из важнейших свойств нейронов, лежащее в основе межнейронной коммуникации и обработки больших объёмов данных. В результате обучения такой сети получается динамическая система, которую, с одной стороны, можно исследовать численно с различными входными данными и при различных внешних условиях, а с другой стороны — анализировать методами нелинейной динамики. Изучение таких нейронных сетей представляет также большой интерес для зарождающейся в настоящее время отрасли микроэлектроники, связанной с созданием специализированных нейрочипов и нейропроцессоров [37–39]. Предполагается, что такие устройства благодаря заложенным в них принципам работы нейронных структур мозга будут эффективны при решении не только традиционных задач распознавания и кодирования, но и когнитивных и поведенческих задач.

Наш обзор посвящён именно этой перспективной тематике. В разделе 2 даются основные понятия в области машинного обучения, необходимые для дальнейшего изложения. В разделе 3 приведены примеры моделирования функциональных и когнитивных свойств структур мозга с помощью рекуррентных нейронных сетей. Вопросы моделирования спайковых сетей рассмотрены в

разделе 4. Основные достижения в области построения искусственных нейроморфных систем описаны в разделе 5. В заключении (раздел 6) приводятся основные выводы и обсуждаются дальнейшие перспективные направления.

2. Основы машинного обучения

Машинное обучение — обширная область современной науки, и в настоящем обзоре не ставится цель охватить все аспекты данного направления [22, 40]. В данном разделе рассматриваются только ключевые понятия и алгоритмы машинного обучения, необходимые для дальнейшего изложения основных результатов по их применению в построении рекуррентных спайковых нейронных сетей для моделирования функциональных свойств сетей мозга.

2.1. Три компонента машинного обучения

Процедура построения искусственной нейронной сети, моделирующей функциональные свойства сетей мозга, обычно включает в себя следующие этапы. Во-первых, исследуемое нейробиологическое явление формулируется в виде целевой функции, преобразующей определённым образом входные стимулы в выходные. Во-вторых, инициализируется базовая искусственная нейронная сеть, учитывающая известные анатомические аспекты биологического прототипа. В-третьих, происходит обучение сети, т.е. настройка её параметров, после чего модель становится способной по входным стимулам генерировать выходные отклики качественно или даже количественно схожим образом с генерацией таковых в реальной системе. Обученная сеть представляет собой динамическую систему, которую можно исследовать методами нелинейной динамики, находя популяционные механизмы выполняемой функции преобразования входных сигналов в выходные отклики.

Таким образом, при разработке любой искусственной нейронной сети требуется определить три ключевых компонента: 1) целевую функцию или задачу обучения; 2) архитектуру сети, т.е. структуру связей между нейронами; 3) алгоритм обучения, т.е. правила, по которым изменяются весовые коэффициенты сети.

2.1.1. Задача обучения. Современные системы машинного обучения можно разделить по типу решаемой задачи на три основных класса: контролируемое обучение (обучение с учителем), неконтролируемое обучение (обучение без учителя), обучение с подкреплением [41]. В рамках настоящего обзора затрагиваются в основном вопросы, касающиеся первого класса, однако в этом разделе кратко опишем также особенности двух других.

Контролируемое обучение. В задаче контролируемого обучения есть два множества векторов: входные $\mathbf{x}^{(i)}$, $i = 1, \dots, M$, и целевые $\mathbf{z}_{\text{targ}}^{(i)}$. Каждому вектору первого множества ставится в соответствие вектор из второго множества, т.е. весь набор данных состоит из сопоставленных пар "вход–целевой выход" $\{\mathbf{x}^{(i)}, \mathbf{z}_{\text{targ}}^{(i)}\}$. Искусственная нейронная сеть осуществляет преобразование входов в выходы $F: \mathbf{x} \rightarrow \mathbf{z}$. В общем виде задача обучения состоит в настройке параметров сети, которые обозначим $\boldsymbol{\theta}$, таким образом, чтобы в ответ на некоторый входной стимул $\mathbf{x}^{(i)}$ сеть генерировала выход $\mathbf{z}^{(i)} = F(\mathbf{x}^{(i)}, \boldsymbol{\theta})$, максимально приближенный к целевому сигналу $\mathbf{z}_{\text{targ}}^{(i)}$, т.е. $\mathbf{z}^{(i)} \approx \mathbf{z}_{\text{targ}}^{(i)}$. Другими словами, в процессе

обучения минимизируется значение функции ошибки $E = 1/M \sum_i E(\mathbf{z}^{(i)}, \mathbf{z}_{\text{targ}}^{(i)})$, где $E(\mathbf{z}^{(i)}, \mathbf{z}_{\text{targ}}^{(i)})$ — количественная мера различия целевого сигнала $\mathbf{z}_{\text{targ}}^{(i)}$ и выхода $\mathbf{z}^{(i)}$. С этой целью исходный набор данных обычно делится на два неравных множества: большее — тренировочное — и меньшее, включающее в себя оставшиеся данные, — валидационное. Минимизация ошибки нейронной сети проводится на векторах тренировочного множества, после чего качество обучения, т.е. величина ошибки, оценивается на данных из валидационного множества.

В задаче классификации изображений, например, вход — это изображение, представленное в виде вектора, содержащего информацию о цвете отдельных пикселей, а целевой выход — это вектор, задающий класс, которому принадлежит изображённый объект. В задачах когнитивной нейронауки целевым выходом может быть определённый поведенческий акт, выполняемый животным при заданных условиях, определяющих вход. Например, в задаче перцептивного принятия решения эксперимент ставится таким образом, что испытуемое животное, воспринимающее с монитора изображения случайно движущихся точек, должно определить, вправо или влево преимущественно движется ансамбль точек, нажав одну из двух кнопок. На языке искусственных нейронных сетей эта задача может быть сформулирована следующим образом: на вход в каждый момент времени подаётся вектор, содержащий координаты движущихся точек, а целевым выходом является знак средней скорости движения ансамбля.

Обучение с подкреплением. В задачах обучения с подкреплением агент взаимодействует с окружающей средой, состояние которой описывается переменной $\mathbf{s}_t$ в момент времени t . В натурных экспериментах в качестве среды может выбираться также виртуальный лабиринт. Агент, взаимодействуя со средой, получает наблюдение $\mathbf{o}_t$, производит действие $\mathbf{a}_t$, меняющее состояние среды на новое $\mathbf{s}_{t+1}$, и получает за это вознаграждение или подкрепление, описываемое скалярной величиной r_t . Например, искусственный агент движется в виртуальном лабиринте, в качестве наблюдений $\mathbf{o}_t$ принимает зрительные образы в виде пиксельных изображений, совершает действия $\mathbf{a}_t$ по перемещению в лабиринте и получает подкрепление, если ему удаётся найти выход из лабиринта. Цель состоит в совершении последовательности подходящих действий с учётом прошлых и настоящих наблюдений таким образом, чтобы максимизировать суммарное подкрепление $\sum_t r_t$. Во многих классических задачах обучения с подкреплением наблюдения $\mathbf{o}_t$ совпадают с состояниями среды $\mathbf{s}_t$, т.е. содержат полную информацию о среде.

Теория обучения с подкреплением применяется в нейронауке для исследования задач принятия решений. С её помощью анализируют, как поведение агента адаптируется со временем к изменяющимся условиям и какие нейрональные механизмы лежат в основе определённого ценностного поведения. Применение искусственных нейронных сетей делает глубокое обучение с подкреплением ещё более гибким и позволяет в принципе моделировать большинство задач, которые ставятся в эксперименте над лабораторными животными, поскольку последние практически всегда обучаются выполнять определённые команды через поощрения [42, 43].

Неконтролируемое обучение. В случае обучения без учителя сеть только принимает входные стимулы $\mathbf{x}^{(i)}$, а

функция ошибки задаётся в зависимости от входов и параметров сети $E(\mathbf{z}^{(i)}, \boldsymbol{\theta})$. К неконтролируемому обучению относятся задачи нахождения скрытых структур и паттернов в неразмеченных данных, например задача кластеризации (группирование входов в различные кластеры) или редукции размерности.

2.1.2. Архитектура сетей. На сегодняшний момент разработаны многочисленные типы архитектуры нейронных сетей, включая многослойные сети глубокого обучения, свёрточные, сети с длительной краткосрочной памятью, рекуррентные, гибридные и т.д. Здесь мы опишем два базовых типа архитектуры: многослойные сети прямого распространения и рекуррентные сети, которые используются при моделировании функциональных свойств сетей мозга. В первых передача данных по нейронам идёт в одном направлении — от входов к выходам, во вторых присутствуют обратные связи, поэтому данные могут многократно возвращаться в исходные нейроны.

Сети прямого распространения. Многослойные сети прямого распространения являются наиболее часто встречающимся типом структуры сетей в области машинного обучения и представляют собой последовательность слоёв, внутри каждого из которых нейроны не связаны между собой. Сеть, как правило, имеет входной и выходной слои, а также один или более внутренних или глубоких слоёв. Обработка входного стимула происходит последовательно начиная с входного слоя; нейроны предыдущего слоя направлены связаны с нейронами последующего. Таким образом, активация нейронов проходит послойно от входного слоя до выходного. Базовый тип сети прямого распространения состоит из N слоёв нейронов, при этом нейроны l -го слоя получают входы с нейронов $(l-1)$ -го слоя и посылают выходы на $(l+1)$ -й слой:

$$\mathbf{r}^{(1)} = \mathbf{x}, \quad (1)$$

$$\mathbf{r}^{(l+1)} = \sigma(\mathbf{W}^{(l)} \mathbf{r}^{(l)} + \mathbf{b}^{(l)}), \quad 1 < l < N, \quad (2)$$

$$\mathbf{z} = \mathbf{W}^{(N)} \mathbf{r}^{(N)} + \mathbf{b}^{(N)}, \quad (3)$$

где $\mathbf{x}$ — входной стимул, $\mathbf{r}^{(l)}$ — активность нейронов в l -м слое, $\mathbf{W}^{(l)}$ — матрица связей от нейронов l -го слоя к нейронам $(l+1)$ -го слоя, $\mathbf{z}$ — выходной отклик. Функция активации $\sigma(\dots)$ преобразует взвешенную сумму входов с предыдущего слоя в выходной отклик последующего слоя. Выход всей сети $\mathbf{z}$ считается через выходные связи $\mathbf{W}^{(N)}$. Параметры $\mathbf{b}^{(l)}$ и $\mathbf{b}^{(N)}$ — векторы смещения для нейронов глубоких и выходного слоёв соответственно.

Рекуррентные сети. Важный класс искусственных нейронных сетей — рекуррентные сети, которые благодаря наличию обратных связей могут обрабатывать данные во времени. В базовой модели рекуррентной нейронной сети активность нейронов $\mathbf{r}_t$ в момент t определяется внешними стимулами $\mathbf{x}_t$, поступающими через матрицу входных связей $\mathbf{W}_x$, и матрицей рекуррентных связей $\mathbf{W}_r$:

$$\mathbf{r}_t = \sigma(\mathbf{W}_x \mathbf{x}_t + \mathbf{W}_r \mathbf{r}_{t-1} + \mathbf{b}_r). \quad (4)$$

Выход сети $\mathbf{z}_t$ определяется через матрицу выходных связей $\mathbf{W}_z$:

$$\mathbf{z}_t = \mathbf{W}_z \mathbf{r}_t + \mathbf{b}_z. \quad (5)$$

Рекуррентная нейронная сеть может быть развёрнута во времени и представлена в виде особой формы многослойной сети прямого распространения, в котором t -й слой получает входы с $(t - 1)$ -го слоя и дополнительно из входного слоя $\mathbf{x}_t$.

2.1.3. Алгоритм обучения. Основным алгоритмом обучения в классе задач контролируемого обучения — стохастический градиентный спуск. Для сети прямого распространения алгоритм обратного распространения ошибки можно описать следующим образом. При прямом проходе сети для каждого нейрона вычисляется вход $\mathbf{x}$, равный взвешенной сумме выходов элементов предыдущего слоя. Затем вычисляется нелинейная функция, значение которой даёт выход данного нейрона. Эта процедура происходит послойно, начиная с входного слоя и продолжается далее, проходя через глубокие слои, вплоть до выходного слоя. Сравнение выхода сети с целевым значением позволяет вычислить функцию ошибки E . При обратном проходе на каждом глубоком слое вычисляются частные производные от функции ошибки E по выходам всех элементов в слое. Каждая такая производная представляет собой взвешенную сумму частных производных функции ошибки по суммарным входам предыдущего слоя.

Таким образом, для настройки весовых коэффициентов алгоритм обучения вычисляет вектор градиента ошибки, компоненты которого показывают, на сколько возрастёт или уменьшится ошибка, если немного увеличить тот или иной вес. Вектор параметров $\boldsymbol{\theta}$ затем модифицируется в направлении, противоположном градиенту ошибки $\partial E / \partial \boldsymbol{\theta}$. Поскольку оценивать ошибку по всей выборке обучения вычислительно затратно, часто ошибка вычисляется по минивыборке — некоторому малому числу $K \ll M$ случайно выбранных элементов $\{\mathbf{x}^{(k)}\}$ с индексами k из набора $\mathbb{B} = \{k_1, \dots, k_K\}$:

$$E_{\text{batch}} = \frac{1}{K} \sum_{k \in \mathbb{B}} E(\mathbf{z}^{(k)}, \mathbf{z}_{\text{targ}}^{(k)}). \quad (6)$$

Для уменьшения ошибки модифицируемые параметры $\boldsymbol{\theta}$ изменяются в направлении, противоположном градиенту, на величину, пропорциональную так называемой скорости обучения η ($\eta > 0$):

$$\Delta \boldsymbol{\theta} = \eta \frac{\partial E}{\partial \boldsymbol{\theta}}. \quad (7)$$

Обычно модифицируются параметры $\mathbf{W}$ и $\mathbf{b}$:

$$\mathbf{W}^{\text{new}} = \mathbf{W} - \eta \nabla_{\mathbf{W}} E(\mathbf{W}, \mathbf{b}), \quad \mathbf{b}^{\text{new}} = \mathbf{b} - \eta \nabla_{\mathbf{b}} E(\mathbf{W}, \mathbf{b}), \quad (8)$$

а остальные, называемые гиперпараметрами, инициализируются и не меняются в процессе обучения. Ключевое условие для вычисления градиента ошибки — это дифференцируемость функций активации $\sigma(\dots)$ (см. (2), (4)).

2.2. Модели нейронов

2.2.1. Статические нейроны. В традиционных искусственных нейронных сетях базовым элементом является статический нейрон, т.е. элемент без собственной динамики, представляющий собой функцию активации. На его вход подаётся взвешенная сумма выходов $z_i =$

$= \sum_j w_{ij} y_j$ с других нейронов, а сам он осуществляет нелинейное преобразование, и на выходе мы имеем значение $y_i = f(z_i)$. В качестве нелинейной функции широко распространены различные виды сигмоид, гиперболический тангенс $f(z) = \tanh z$, логистическая функция $f(z) = 1/[1 + \exp(-z)]$ или кусочно-линейная функция ReLu (так называемый, линейный выпрямитель, представленный в виде $f(z) = \max(0, z)$). Нейроны такого типа в составе рекуррентных сетей иногда называют частотными, поскольку значение переменной трактуется как средняя частота следования спайков, хотя генерации самих спайков в модели не происходит [44–46]. Сеть из N таких нейронов может быть описана уравнениями в непрерывном времени:

$$\tau \frac{dx_i}{dt} = -x_i + \sum_{j=1}^N J_{ij} \phi(x_j), \quad i = 1, 2, \dots, N, \quad (9)$$

где x_i — переменные, описывающие активность соответствующего нейрона, $\phi(x)$ — средняя частота нейрона, определяемая как нелинейная функция его активности; структура связей описывается матрицей смежности J_{ij} , τ — константа времени. Динамика в сетях статических нейронов проявляется в случае именно рекуррентных сетей, поскольку наличие обратных связей задаёт динамическую систему даже в отсутствие активности в отдельных узлах-нейронах. Напротив, в многослойных сетях глубокого обучения, состоящих из статических нейронов, процесс послойной передачи активации происходит вне временного измерения. Именно поэтому в задачах, требующих обработки информации, представленной в виде сменяющихся друг друга во времени пакетов, используют рекуррентные нейронные сети. Обзор задач, решение которых основано на использовании рекуррентных сетей статических нейронов, приведён в разделе 3.

2.2.2. Динамические нейроны. К динамическим моделям нейронов относятся все системы в виде дифференциальных уравнений или точечных отображений, которые описывают изменение активности отдельного нейрона во времени [14, 47]. Данные системы включают в себя модели типа Ходжкина–Хаксли, Моррис–Лекара, ФитцХью–Нагумо, Хиндмарша–Роуза и др. Однако в целях моделирования функциональных свойств сетей мозга чаще всего применяют упрощённые спайковые модели, такие как нейроны накопление–сброс. Это класс позволяющих описывать генерацию потенциалов действия, или спайков, моделей, который включает ряд различных модификаций: прежде всего, традиционный нейрон накопление–сброс с утечкой [48], квадратичный [49, 50], экспоненциальный [51] нейрон накопление–сброс, тета-нейрон [52] и адаптивный экспоненциальный нейрон [53]. Общее для указанного класса моделей упрощение состоит в том, что в них пренебрегается формой потенциала действия, а каждый спайк является событием, определяемым только моментом его появления. Динамика мембранного потенциала нейрона накопление–сброс с утечкой описывается дифференциальным уравнением первого порядка:

$$\tau_m \frac{dv_i}{dt} = v_0 - v_i + RI(t), \quad i = 1, \dots, N, \quad (10)$$

где v_i — переменная, описывающая напряжение мембраны нейрона, τ_m — константа времени. По достиже-

нии переменной порогового значения потенциала v_{thr} в момент t_f (при условии $dv/dt|_{t=t_f} > 0$) происходят генерация спайка и сброс к потенциалу переустановки v_0 (часто предполагается $v_0 = 0$). Применение спайковых моделей в рекуррентных нейронных сетях обсуждается в разделе 4.

3. Рекуррентные нейронные сети в задачах моделирования функциональных свойств сетей мозга

Рекуррентные нейронные сети, в отличие от сетей прямого распространения, характеризуются тем свойством, что каждый нейрон может получать входные сигналы от любого другого нейрона в сети. Таким образом, на активность нейронов в данный момент влияет не только внешний стимул, но и состояние сети в течение целого временного интервала в прошлом. В вычислительной нейронауке рекуррентные сети используются для моделирования функциональных свойств сетей мозга, связанных с моторными или когнитивными процессами. Тот факт, что такие сети могут выступать в качестве моделей нейронных структур мозга, обосновывается их анатомией и физиологией, поскольку выходные связи большинства кортикальных нейронов служат входами для других нейронов коры, т.е. типичные кортикальные популяции рекуррентны по своей структуре [54]. Более того, динамика искусственных рекуррентных сетей во многих аспектах воспроизводит спонтанную активность, наблюдаемую в мозге [55].

Обучение искусственных рекуррентных нейронных сетей происходит на специфических задачах, дизайн которых основан на проводимых нейробиологами экспериментальных работах с животными. Как правило, в таких экспериментах изучаются свойства нейронных популяций мозга, лежащих в основе выполнения различных когнитивных или двигательных задач. Выполняемая в ходе эксперимента испытуемым животным задача формализуется в виде целевой функции, преобразующей входные стимулы в требуемые выходные отклики. Затем задаётся искусственная нейронная сеть, структура которой может выбираться с учётом анатомических особенностей. Далее методами машинного обучения [40, 56] настраиваются параметры этой сети для выполнения целевого преобразования входов в выходы.

Такая постановка задачи представляет собой новую методологию получения сетевых моделей, альтернативную преобладавшему в течение длительного времени подходу, при котором построение математической модели функциональной нейронной сети целиком опиралось на интуицию исследователя. Однако полученная в ходе обучения искусственная сеть представляет собой "чёрный ящик" с заранее не известным механизмом, отвечающим за выполнение им целевых задач [57]. Анализ обученной рекуррентной сети, своего рода её обратная инженерия, может пролить свет на механизмы той или иной функции на уровне как отдельных нейронов, так и популяционной активности.

Заметим, что результирующую нейронную сеть можно исследовать методами нелинейной динамики и теории сложных сетей [58–61]. В частности, можно выявлять в многомерном фазовом пространстве особые траектории, отвечающие выполнению той или иной функции, анализировать распределение весов, кластеризацию связей, наличие модулей в структуре обученной сети [62].

Кроме того, для лучшего сравнения биологической и искусственной нейронных сетей последнюю часто анализируют методами, аналогичными используемым при анализе экспериментальных нейрофизиологических данных. Например, распространены методы редукции размерности, такие как анализ главных компонент с целью выявления в многомерном пространстве данных низкоразмерных подпространств, в проекции на которые дисперсия данных сохраняется в большей степени. Для выявления причинно-следственных связей между структурой сети и её функциями как в эксперименте, так и в соответствующей модели может быть стимулирована или подавлена активность определённой группы нейронов либо могут быть нарушены связи между отдельными нейронами или нейронными ансамблями.

Рассмотрим вначале задачу, связанную с обучением рекуррентной сети частотных нейронов производить на выходе целевой пространственно-временной паттерн. Соответствующая система, схематически представленная на рис. 1а, состоит из слоя входных нейронов, собственно рекуррентной сети и слоя выходных нейронов. Данная модель описывает процесс генерации двигательных и других ритмически скоординированных ритмов нейронными сетями моторной и премоторной коры мозга.

Система частотных нейронов описывается уравнением

$$\dot{\mathbf{x}} = -\mathbf{x} + \mathbf{A}\mathbf{r} + \mathbf{U}\mathbf{z} + \mathbf{V}\mathbf{y}, \quad (11)$$

где $\mathbf{x} \in \mathbb{R}^N$ — вектор состояний узлов нейронной сети, которые определяют частоты их активности посредством функции активации $\sigma(x) = \tanh x$: $\mathbf{r} = [r_j] = [\sigma(x_j)]$. Матрица $\mathbf{A} \in \mathbb{R}^{N \times N}$ определяет структуру рекуррентных связей, матрица $\mathbf{V} \in \mathbb{R}^{N \times L}$ — веса входных связей, матрица $\mathbf{U} \in \mathbb{R}^{N \times M}$ — обратных связей (L, M — размерности входного и выходного векторов соответственно). Вход сети задаётся вектором $\mathbf{y} \in \mathbb{R}^L$, выход сети $\mathbf{z} \in \mathbb{R}^M$ определяется через матрицу выходных связей $\mathbf{W} \in \mathbb{R}^{N \times M}$:

$$\mathbf{z} = \mathbf{W}\mathbf{r}. \quad (12)$$

Заметим, что система (11) описывает динамику сети в непрерывном времени, в отличие от дискретной формы (4). Кроме того, рекуррентная нейронная сеть на рис. 1а относится к классу так называемых систем резервуарных вычислений, которые характеризуются тем, что, в отличие от общего случая (4), в них осуществляется обучение только выходных весов $\mathbf{W}$. За счёт наличия обратных связей модификация выходных связей приводит к перестройке эффективной топологии на уровне всей рекуррентной сети.

Показано, что рекуррентная нейронная сеть вида (11) может обучаться автономной генерации различных выходных паттернов в отсутствие входных сигналов ($\mathbf{y} = 0$). Например, на рис. 1б, в показаны целевая пространственно-временная активность выходных нейронов и соответствующая динамика нейронов рекуррентной сети, обученной воспроизводить на выходе данный целевой паттерн. В многомерном фазовом пространстве после обучения возникает устойчивый предельный цикл, проекция которого в пространство трёх главных компонент приведена на рис. 1г. Заметим, что точки изменения направления траектории, показанные на рис. 1г различным




Рис. 1. (В цвете онлайн.) (а) Схема обучаемой рекуррентной нейронной сети. (б) Пример целевого пространственно-временного паттерна, который сеть генерирует на выходе после успешного обучения. (в) Соответствующая динамика нейронов рекуррентной сети, лежащая в основе автономной генерации указанного паттерна. (г) Проекция многомерной активности нейронной сети в пространство трёх главных компонент. (д) Аналогичная проекция при выполнении сетью задачи преобразования коротких входных стимулов в выходные отклики на соответствующем выходном элементе. (Модифицированный рисунок из статьи [58].)

цветом, соответствуют пикам активности выходных нейронов на рис. 1б, отображённой тем же цветом.

При наличии входных сигналов нейронная сеть (11) может осуществлять различные целевые преобразования, моделирующие простейшие типы сенсорно-моторной передачи информации. Применение нелинейно-динамического подхода также позволяет в этом случае установить механизмы таких преобразований. Например, пусть целевая задача состоит в том, чтобы сеть при получении короткого воздействия с одного из входных нейронов ($y_k > 0$, $y_j = 0$, $j \neq k$) вырабатывала отклик с заданными продолжительностью и формой лишь на соответствующем выходном нейроне ($z_k > 0$). Оказывается, что тогда после обучения сеть демонстрирует нерегулярную активность, как и до обучения, однако поступление входных стимулов приводит к выходу фазовой траектории в метастабильные области, проекции которых в пространство трёх главных компонент показаны различными цветами на рис. 1д. Переходная динамика в данных областях является квазирегулярной, поэтому функционально сеть демонстрирует целевые отклики на выходе.

Далее рассмотрим примеры применения рекуррентных нейронных сетей для моделирования когнитивных функций, изучаемых в экспериментах. В работе [63] описан эксперимент, в ходе которого обезьяна обучается принимать решение, анализируя зрительный стимул, с учётом так называемого контекстного сигнала. Животное наблюдает на экране перемещающиеся случайным образом точки, часть из которых движется в одном на-

правлении (вправо или влево), а остальные — в другом. Кроме того, часть точек окрашена в красный цвет, оставшиеся — в зелёный. От испытания к испытанию меняются соотношение цветов и преобладающее направление движения, помимо того, в каждом испытании предъявляется контекстный сигнал, сообщающий, какое задание должно выполнить животное. Если появляется жёлтый квадрат, то необходимо определить направление движения большей части точек саккадным (т.е. быстрым синхронным) движением глаз в соответствующую сторону; если появляется синий крест, то надо аналогичным образом определить преобладающий цвет (рис. 2а).

Во время проведения эксперимента регистрируется активность нейронов в префронтальной коре головного мозга, которые демонстрируют сложные паттерны активности. При анализе экспериментальных данных обнаружено, что, хотя на уровне динамики отдельных нейронов практически невозможно разделить влияние входных стимулов или решения на выходе, на уровне популяционной активности можно разделить влияние различных аспектов входной информации и различные принятые решения. Установлено, что в многомерной активности нейронов отражаются обе характеристики зрительного стимула (т.е. цвет и направление движения) независимо от контекста. Таким образом, сообщение контекстного сигнала отфильтровывает нерелевантную информацию не в более ранних отделах мозга, как считалось ранее, а в нейронных популяциях самой коры.

Для выявления механизма решения описанной задачи на уровне популяционной активности префронтальной




Рис. 2. (В цвете онлайн.) (а) Схема экрана со зрительными стимулами при проведении эксперимента. (б) Схема модельной рекуррентной нейронной сети. (в) Траектории модельной системы при двух контекстах и различной интенсивности входных стимулов в проекции на оси выбора, цвета и движения. (г) Схема аттракторов рекуррентной нейронной сети. (Модифицированный рисунок из статьи [63].)

коры авторами была построена модель в виде рекуррентной нейронной сети (рис. 2б), обученной выполнять преобразование входов в выходы, качественно аналогичное происходящему в эксперименте. Динамика сети описывается системой уравнений вида (4), (5). В ходе каждого испытания нейроны модельной сети получают на вход два независимых зашумлённых сигнала, имитирующих сенсорные ощущения о преимущественных соответственно цвете и направлении движения облака точек. Также сеть получает контекстный вход в виде двумерного вектора, соответствующий контекстному сигналу в эксперименте, который сообщает сети, что именно надо определить: цвет или направление движения (рис. 2б). После обучения сеть в ответ на входящие стимулы сообщает своё решение, генерируя бинарный отклик (+1 или -1 на выходе). На языке модельной сети это означает, что выходной отклик информирует о том, положительно или отрицательно среднее за время испытания значение сигнала с того входа, на который указывает контекстный вход.

Анализ активности рекуррентной нейронной сети после обучения выявил, что в многомерном пространстве можно выделить оси выбора, цвета и направления движения и в проекции на трёхмерное подпространство,

определённое этими осями, динамика модели качественно воспроизводит ключевые свойства нейрофизиологических данных из эксперимента (рис. 2в). Во-первых, в процессе получения на вход сенсорных сигналов происходит своего рода накопление свидетельств в пользу одного из двух альтернативных решений. При этом траектория популяционного отклика совершает движение вдоль оси выбора. Во-вторых, чем выше значения сигналов цвета и направления движения, тем дальше траектории отходят от оси выбора вдоль соответствующих осей. В-третьих, направление осей выбора, цвета и направления движения инвариантны относительно контекстного входного сигнала. В-четвёртых, траектории при различных контекстах пространственно изолированы друг от друга. Такое поведение системы определяется возникшими в ходе обучения особыми траекториями фазового пространства.

Авторы установили, что в фазовом пространстве рекуррентной нейронной сети образуются две линии устойчивых состояний равновесия, каждая из которых направлена вдоль оси выбора. Появление одной из этих двух линий зависит от контекста, и обе они никогда не возникают одновременно. При действии входного сигнала траектория удаляется от соответствующей линии, при-




Рис. 3. (В цвете онлайн.) (а) Схема экрана со зрительными стимулами при проведении эксперимента по категоризации зрительных стимулов. (б) Схема разделения зрительных стимулов на две категории. (в) Этапы эксперимента и соответствующие особые точки фазового пространства. (г) Особые точки и траектории фазового пространства модельной системы при восприятии двух зрительных стимулов с задержкой и принятии решения о совпадении/несовпадении их категорий. (Модифицированный рисунок из статьи [64].)

чём тем дальше, чем сильнее в среднем входной сигнал. Для фиксированного контекста движение траектории после окончания действия входного стимула происходит в направлении, определяемом вектором выбора, который в свою очередь ортогонален направлению нерелевантного входа. Направления линий устойчивых состояний равновесия и направления векторов выбора определяются соответственно правым и левым старшими собственными векторами линеаризованной в окрестности состояний равновесия системы (рис. 2в).

Таким образом, применение модельной рекуррентной нейронной сети в данной задаче позволило выявить неизвестный ранее механизм контекстно зависимого принятия решения, при котором один и тот же входной сигнал в одном контексте обрабатывается, а в другом игнорируется.

В работе [64] построена рекуррентная нейронная сеть для моделирования задачи категоризации зрительных стимулов, получаемых с задержкой. В прототипных экспериментах [65, 66] обезьянам последовательно предъявлялись зрительные стимулы: сначала стимул фиксации (в течение 500 мс), затем испытательный стимул (в течение 650 мс), период задержки (1000 мс), тестовый стимул (650 мс) (рис. 3а). Стимул фиксации — жёлтое пятно на экране, испытательный и тестовый стимулы задаются набором точек, которые могут двигаться в случайно выбранном направлении в интервале от 0 до 360°. Все используемые стимулы были разделены на две категории с помощью заранее выбранной границы (рис. 3б). Испытуемые животные обучались сообщать о совпадении категорий испытательного и тестового стимула нажатием рычага.

В модельной системе [64] рекуррентная сеть, задаваемая системой (4), (5), получает сигналы со слоя входных нейронов, активность которых кодирует направление движения точек на экране; подмножество нейронов сети посылает связи на два выходных элемента, активность

которых сигнализирует о соответствии либо о несовпадении категорий первого и второго входных стимулов. Анализируя динамику рекуррентной нейронной сети после обучения, авторы [64] выяснили механизм категоризации зрительных стимулов (рис. 3в, г). В начале испытания траектория находится в устойчивом состоянии равновесия (серый косой крест); после предъявления входного стимула траектория покидает его окрестность в направлении одного из состояний, соответствующих той или иной категории (красный и синий кружки) (рис. 3г). Далее во время интервала задержки происходит переход в окрестность устойчивых или седловых точек, соответствующих двум категориям (красная и синяя звёзды). Действие второго стимула приводит траекторию в окрестность одного из двух состояний равновесия, соответствующих совпадению и несовпадению категорий стимулов. Качественно подобные метастабильные состояния и переходы между ними можно выявить на основе анализа многомерных нейрофизиологических данных, снимаемых в эксперименте с нейронов коры испытуемых обезьян [64]. Таким образом, рекуррентная нейронная сеть позволяет выявить особенности популяционной динамики, отражающие всю цепочку этапов выполнения описанной комплексной задачи.

В работе [67] изучался вопрос о том, какие механизмы нейронной активности лежат в основе способности контролировать скорость выполнения моторных и когнитивных функций. В ходе эксперимента обезьяне демонстрировали визуальные стимулы: круг в центре экрана и квадрат ниже (рис. 4а). Испытуемое животное направляло взгляд на круг, а квадрат сообщал о необходимости нажать кнопку под экраном. В каждом испытании одна фигура была окрашена в синий или красный цвет, а другая — в белый. Цветная фигура обозначала целевое действие: круг соответствовал требованию совершить саккадное движение глаз, а квадрат — нажать кнопку. Цвет обозначал желаемый временной интервал: красный соот-




Рис. 4. (В цвете онлайн.) (а) Схема эксперимента [67]. (б) Структура модели в виде рекуррентной нейронной сети. (в) Профили активности отдельных нейронов после обучения. (г) Проекция активности в пространство трёх главных компонент. (Модифицированное изображение из статьи [67].)

ветствовал 800 мс, а синий — 1500 мс. Четыре различных условия испытаний обозначены как ГД, ГК, ЛД, ЛК (Г и Л обозначают глаз и лапу, Д и К — длинный и короткий интервалы). После периода задержки (варьировался в интервале 500–1500 мс) на экране справа или слева от центра появлялась на короткое время цель для саккадного движения глаз. После ещё одной задержки кратковременная кольцеобразная вспышка вокруг квадрата и круга сигнализировала о начале контрольного интервала, в течение которого обезьяна должна совершить целевое действие — саккадную фиксацию взгляда или нажатие кнопки. Чтобы получить вознаграждение, животное должно менять длительность этого действия в соответствии с целевым значением, обозначенным цветом. Одновременно проводилась регистрация электрической активности нейронов медиальной лобной коры.

Описанная постановка эксперимента позволяет анализировать свойства нейронной активности, отвечающие контролю длительности временных интервалов при совершении двигательных актов. Исследуя популяционный отклик нейронов, авторы обнаружили, что средняя спайковая частота имеет временной профиль, ширина которого меняется в соответствии с целевой длительностью контрольного интервала.

Для нахождения механизма контроля длительности временных промежутков авторы [67] построили модель в виде рекуррентной нейронной сети (4), (5), состоящей из 200 нейронов (рис. 4б). В сеть поступает два скалярных входа: один — контекстный, величина которого определяет длительность целевого интервала, другой — короткий прямоугольный стимул, сигнализирующий о начале интервала, в течение которого активность целевого выхода должна монотонно возрастать вплоть до достижения определённого порога за время, равное целевому интервалу. Анализ активности обученной сети показал, что модель качественно воспроизводит ключевые явления, обнаруженные в эксперименте. На уровне отдельных

нейронов профили их откликов имеют сложные разнообразные формы и меняют свою ширину в соответствии с целевой длительностью (рис. 4в). Более того, скорость популяционной динамики является определяющим фактором длительности продуцируемого на выходе отклика. Авторы [67] провели анализ свойств объектов фазового пространства сети, отвечающих такому поведению (рис. 4г). Установлено, что образуются два множества устойчивых состояний равновесия: F_{init} , соответствующее началу испытания, и $F_{terminal}$ — соответствующее его окончанию. Контекстный стимул инициализирует состояние сети в окрестности состояния равновесия F_{init} , затем входной прямоугольный стимул выводит траекторию из его бассейна притяжения, и траектория релаксирует в окрестность состояния устойчивого равновесия $F_{terminal}$ со скоростью, определяемой величиной контекстного входного стимула. Последний влияет на положение точек F_{init} и $F_{terminal}$ вдоль называемого многообразием входного стимула направления, определяемого вектором входных весов. В то же время веса рекуррентной сети задают направление (так называемое рекуррентное многообразие), вдоль которого движутся траектории между начальным и конечным состояниями.

Представленный подход успешно применяется для построения рекуррентных нейронных сетей, моделирующих другие когнитивные функции, связанные с рабочей памятью [27, 69, 70], сравнения характеристик входных стимулов [71, 72], принятия решения в зависимости от изменений в окружающей среде и контекстных сигналов [67, 73–77]. Как правило, искусственная сеть для приведённых примеров обучается на одной специфической задаче, что позволяет выявить динамические механизмы реализации определённой функции. Такая постановка является сильным упрощением по отношению к биологическим сетям, которые в процессе функционирования одновременно выполняют целый ряд различных задач.




Рис. 5. (В цвете онлайн.) (а) Схема рекуррентной нейронной сети, выполняющей 20 различных когнитивных задач. (б) После обучения в структуре сети выделяются кластеры, каждый из которых специализирован для выполнения одной или нескольких задач. По вертикальной оси — список задач, по горизонтали — нейроны, упорядоченные для лучшей визуализации кластеров. Различным цветом показана средняя активность каждого нейрона при выполнении сетью определённой задачи. (Модифицированное изображение из статьи [68].)

В работе [68] построена рекуррентная нейронная сеть вида (4), (5), обученная выполнять 20 различных когнитивных функций, таких как рабочая память, принятие решения после временной задержки или при наличии контекстного сигнала, сравнение и категоризация сенсорных стимулов. Данные функции характерны при решении задач, выполняемых экспериментальными животными, при одновременной регистрации активности нейронов головного мозга.

При решении каждой задачи сеть получает входы трёх типов: сигнал фиксации, содержательные стимулы и вход, определяющий задачу (рис. 5а). Сигнал фиксации задаёт этапы выполнения задачи, т.е. определяет, когда сеть должна "воспринимать" информацию со входов (сигнал фиксации при этом принимает положительное значение), а когда сеть должна генерировать на выходе отклик (при обнулении сигнала фиксации). Содержательные входы представлены стимулами двух модальностей, каждый из них задаётся кольцом входных элементов, кодирующим одномерную круговую переменную, такую как направление движения или цвет. Вход, определяющий задачу, задаётся вектором, состоящим из нулей и одной единицы, положение которой информирует сеть о том, какой задаче она обучается в данном испытании или какую из задач должна выполнить после обучения. Выходы сети — это выход фиксации, цель которого — повторить ход входного сигнала фиксации, и группа моторных элементов, отклик которых определяет направление и интенсивность отклика сети. Обучение сети, при котором настраивались все веса сети (входные, рекуррентные и выходные), проводилось при случайном переключении целевых когнитивных задач. Анализ сети после обучения показал, что в ней формируются группы нейронов — кластеры, специализированные выполнять определённый класс когнитивных задач (рис. 5б). Кроме установленной функциональной специализации авторы обнаружили другой принцип организации работы сети — композиционность, состоящую в том, что сложная задача может быть решена на основе её разбиения на более простые задачи, которым сеть уже обучена ранее.

Суммируя, отметим, что описанные рекуррентные нейронные сети, моделирующие выполнение когнитивных функций, позволяют выявить ряд важных динамических механизмов, лежащих в основе решаемых прототипными нейронными популяциями задач. Все приведён-

ные примеры основаны на моделях так называемых частотных нейронов [78, 79]. Данный факт отражает предположение о том, что кодирование внешних сигналов и передача информации между отдельными нейронными подсистемами осуществляются с помощью частотного кода. Однако большое число экспериментальных фактов свидетельствует, что частотное кодирование не единственно возможное в нервной системе и существенно важную роль играет не только частота, но и конкретные моменты появления элементарных динамических событий в виде коротких импульсов или спайков, возникающих при достижении напряжением нейронной мембраны порога возбуждения. Искусственные нейронные сети, в которых моделируется сам факт генерации нейронами потенциалов действия, называются спайковыми. Различным аспектам применения именно спайковых нейронных сетей в моделировании функциональных свойств сетей мозга посвящён раздел 4.

4. Спайковые нейронные сети

Несмотря на то что в целом ряде задач нейронауки удалось добиться результатов, опираясь на стандартные приёмы машинного обучения (базовая архитектура в виде рекуррентных нейронных сетей, стохастический градиентный спуск в качестве метода обучения), для дальнейшего прогресса как в указанных областях, так и в построении нейроморфных систем искусственного интеллекта следующего поколения требуется учёт биологически релевантных аспектов.

Одним из факторов, отличающих поведение биологических нейронов от поведения искусственных нейросетей глубокого обучения, является способность генерировать потенциалы действия, или спайки. Почти четверть века назад в работе [80] спайковые сети были охарактеризованы как искусственные нейронные сети третьего поколения, в отличие от сетей первого поколения (перцептроны на основе нейронов Мак-Калок–Питтса) и второго поколения (глубокие сети на основе сигмоидных и других подобных нелинейных функций активации), к которому относится большинство современных систем машинного обучения [81].

Отметим, что сегодня не существует окончательного понимания того, какую роль играют спайки в осуществлении головным мозгом своих функций. Имеются ар-

гументы, свидетельствующие как в пользу того, что в обработке информации важна средняя частота следования спайков, так и в пользу того, что ключевую роль играют моменты появления отдельных спайков. Поэтому в области моделирования спайковых нейронных сетей используются различные гипотезы и взгляды на роль спайковой активности. В области машинного обучения одним из мотивов применения спайковых сетей является аспект энергоэффективности, поскольку генерация разреженных спайковых кодов требует меньших энергозатрат, чем обработка непрерывных переменных в традиционных глубоких нейросетях.

Стоит отметить, что большинство используемых сегодня нейросетей глубокого обучения имеет статические входы и производит статические выходы. Даже в случае обработки видеоизображения свёрточной нейронной сетью происходят кадрирование на отдельные статические снимки и распознавание объектов на каждом из них. Иными словами, в таких системах нет времени как физической переменной, которая является аргументом входных и выходных сигналов, а также модельных нейронов и синапсов. В спайковых нейронных сетях, напротив, время заложено уже на уровне динамики отдельных нейронов, и обработка входных сигналов естественным образом осуществляется как неавтономное воздействие на динамическую систему.

Подвляющее большинство работ в данном направлении связано с конверсией глубоких нейросетей в спайковые [81–83], что предполагает масштабирование и нормализацию параметров неспайковой нейронной сети, обученной выполнять определённые задачи, с тем чтобы результирующая спайковая сеть производила то же самое преобразование входов в выходы. Однако развиваются и подходы, изначально ориентированные на спайковую динамику искусственных нейронов. Спайковые нейронные сети разрабатываются как для решения традиционных задач машинного обучения, так и для построения систем, моделирующих задачи нейронауки [33–36]. На основе спайковых нейронов построены многослойные сети прямого распространения, применяемые для моделирования сенсорных систем низкого уровня, в частности, в зрении [84, 85], обонянии или тактильных ощущениях [86]. Рекуррентные спайковые нейронные сети использовались, например, для исследования нейронной обработки информации, связанной с формированием ассоциативной [87, 88] или рабочей [89–91] памяти. Спайковые сети с рекуррентными связями также используются для моделирования и анализа наблюдаемых в мозге явлений, которые возникают в результате сложной динамики сетей со взаимными связями, таких как сетевые колебания [92, 93] или сетевая мультистабильность [94], для моделирования конкуренции между нейронами или нейронными популяциями [95–97] и различных процессов, сопровождающих принятие решений [98].

Для моделирования функциональных свойств нейронных спайковых популяций в терминах нисходящего подхода применяются различные методы, среди которых можно выделить резервуарные вычисления и методы, основанные на нейроинженерной концепции. В данных методах предполагается, что целевое поведение системы априори известно и обучение рекуррентной сети спайковых нейронов происходит с различными ограничениями на уровень биологической детализации моделей. Рассмотрим каждый из указанных подходов подробнее.

4.1. Резервуарные вычисления

Резервуарные вычисления возникли в качестве альтернативного метода обучения рекуррентных сетей, с помощью которого удаётся избежать трудностей, связанных с их обучением [99–104]. В типичной реализации резервуарная сеть состоит из рекуррентной сети с фиксированной топологией (резервуара) и набора выходных (считывающих) нейронов. Обычно последние получают только прямые однонаправленные связи из резервуара, хотя в некоторых моделях обратная связь от выходных нейронов в резервуар также учитывается. Тем не менее желаемый выходной сигнал из сети получается путём обучения исключительно связей между нейронами резервуара и считывающими нейронами. Такой подход значительно упрощает обучение в резервуарных сетях.

Резервуар можно рассматривать как структуру, выполняющую отображение входов в многомерный вектор активности нейронов, принадлежащих сети. Каждый компонент этого вектора отражает влияние, которое конкретные нейроны могут оказывать на выходные единицы. Структура связей внутри резервуара обычно случайная и фиксированная. Наличие устойчивых внутренних состояний резервуара не является необходимым для получения устойчивых выходных данных, поскольку переходные внутренние состояния могут быть преобразованы считывающими нейронами в устойчивые выходные сигналы за счёт высокой размерности динамической системы. Кроме того, состояния резервуара и переходы между ними не требуют настройки под конкретную задачу. Последнее означает, что один и тот же достаточно большой общий резервуар может использоваться для решения множества различных задач.

Концепция резервуарных вычислений первоначально была предложена в контексте неспайковых искусственных нейронных сетей [99–101]. Позднее метод был адаптирован для спайковых сетей в рамках концепции так называемых машин жидких состояний [102, 105]. Резервуарные вычисления со спайковыми нейронами успешно применялись для таких задач, как распознавание произнесённого слова, пространственно-временная классификация спайковых паттернов, прогнозирование движения, генерация моторных паттернов и управление движением [106–110]. Для целей моделирования функциональных свойств применение спайковых нейронных сетей расширено на основе метода FORCE.

Метод уменьшенной и контролируемой ошибки первого порядка FORCE [46] расширяет подход резервуарных вычислений за счёт настройки низкоранговой компоненты рекуррентной весовой матрицы, возникающей вследствие петли обратной связи. Структура спайковой сети (рис. 6а), обучаемой этим методом, аналогична системам описанным в разделе 3 резервуарных вычислений, схематически изображённых на рис. 1а. Отличие состоит в том, что динамика нейронов задаётся уравнениями, явным образом описывающими спайковые события. В качестве моделей спайковых нейронов часто берутся нейроны накопления – сброс (10), а также могут браться модели с адаптивным порогом возбуждения, модели Ижикевича, Курбажа – Некоркина, тета-нейроны.

Установлено, что спайковые рекуррентные сети могут служить резервуаром, способным обучаться задачам, связанным с автономной и стимул-индуцированной генерацией разнообразных пространственно-временных паттернов. Например, сеть спайковых нейронов, демон-




Рис. 6. (В цвете онлайн.) (а) В методе FORCE спайковая нейронная сеть характеризуется, во-первых, фиксированными сильными весами, которые индуцируют хаотическую динамику сети (синий цвет). Во-вторых, к весовой матрице с элементами ω_{ij} добавляется компонента, значения элементов которой определяются в процессе обучения (красный цвет). В методе FORCE требуется, чтобы выходной сигнал $\hat{x}(t)$ оценивался с помощью целевого $x(t)$; $e(t)$ — сигнал ошибки. (б–в) Динамика спайковой нейронной сети до и после обучения задаче автономной генерации гармонического целевого сигнала: (б, в) спайковая активность сети идентичных нейронов до обучения и её проекция в пространство трёх главных компонент; (г, д) активность сети и проекция в пространство трёх главных компонент после обучения автономной генерации гармонического целевого сигнала. (е) Использование спайковой нейронной сети для хранения и воспроизведения паттерна, отвечающего пению птиц. Серия импульсов, построенных из положительной части синусоидального осциллятора с периодом 20 мс, применяется для моделирования цепи возбуждения выходного сигнала от проекционных нейронов ядра аркопаллия RA (Robust nucleus of the Arcopallium) (структура мозга птиц) в HVC (High Vocal Center) (гиперстриатум, структура мозга птиц). Эти нейроны соединяются с нейронами в RA и запускают пение. Метод FORCE использовался для обучения сети из 1000 нейронов Ижикевича для воспроизведения спектрограммы 5-секундной аудиозаписи пения зебрового зяблика; nXIIts — трахеосирингеальный отдел двенадцатого ядра (tracheosyringeal division of the twelfth nucleus), структура мозга птиц; HDTs (high-dimensional temporal signal) — высокоразмерный сигнал; HVC chain — стимулы, генерируемые в HVC. (Модифицированный рисунок из статей [34, 59].)

стрирующая нерегулярную активность до обучения (рис. 6б, в), за счёт настройки выходных весов способна поддерживать воспроизведение гармонического сигнала на выходе (рис. 6г, д), образуя при этом в фазовом пространстве устойчивую инвариантную кривую.

На рисунке 6е приведён пример спайковой нейронной сети, обученной с помощью метода FORCE воспроизводить пение птиц (в виде спектрограммы), записанное у взрослого зебрового зяблика. Певческое поведение этих птиц обусловлено двумя основными ядрами головного мозга: HVC и RA. Нейроны, проецирующие связи из RA в HVC, образуют цепочку спайковой активности, и каждый нейрон в RA срабатывает только один раз в определённое время в ходе песенного исполнения. Эта цепочка спайков передаётся в модуль RA и активирует его. Каждый нейрон в RA генерирует бёрсты в несколько точно определённых моментов во время воспроизведения пес-

ни. Затем нейроны RA проецируют связи в нижние моторные ядра, которые стимулируют голосовые мышцы.

4.2. Нейроинженерная концепция

Нейроинженерная концепция состоит из трёх принципов, используемых для описания нейронных вычислений: 1) представление, 2) преобразование, 3) динамика.

Принцип представления заключается в том, что активность нейронной популяции кодирует динамику некоторой векторной переменной. Кодирование осуществляется за счёт того, что разные нейроны имеют различные амплитудно-частотные характеристики, т.е. частота их спайков по-разному зависит от величины входного тока, определяемого кодируемой переменной. Кроме того, измеряя спайковую активность нейронной популяции, можно декодировать переменную с помощью линейного преобразования.

5. Аппаратные нейроморфные системы

Под термином "нейроморфные системы" понимается специализированное аппаратное оборудование, осуществляющее вычисления, которые имитируют принципы обработки информации в биологических нейронных популяциях [116, 117]. Такие вычисления принято называть нейроморфными. В настоящее время данное понятие часто применяется в более узком смысле к спайковым нейронным сетям. С точки зрения теории информации и компьютерных вычислений аппаратные архитектуры, основанные на спайковых нейронах, осуществляют функциональные преобразования входов в выходы, вычисляемые по Тьюрингу, т.е. могут быть реализованы на машине Тьюринга. В отличие от традиционных ЭВМ, нейроморфные архитектуры направлены на реализацию специально предназначенных для спайковых сетей алгоритмов, которые осуществляют распараллеленные вычисления, редкие в пространстве и времени, благодаря чему потребляется значительно меньшая мощность [118].

Число работ, посвящённых разработке нейроморфных систем, использующих принципы функционирования биологических нейронных сетей, существенно возросло за последние десятилетия; например, в недавнем обзоре [37] проанализировано более 3000 публикаций. Нейроморфные вычисления стали применяться в самых различных устройствах — это связано с тем, что развитие центральных процессорных систем с архитектурой фон Неймана подходит к своему пику вычислительной мощности [119]. Предполагается, что развитие нейроморфных устройств, в которых заложены основные принципы работы нейронных сетей мозга, такие как спайковая динамика и синаптическая пластичность, и которые имеют сопоставимое число нейронов и приближённую к реальности топологию связей, приведёт к росту способности самоорганизации, обучения и выполнения различных классов задач.

Отметим, что на сегодня нейроморфные системы реализуются с использованием различных технологий, например, оптических (фотонных), оптоэлектронных, спинтронных и др., но более всего распространена полупроводниковая технология, поскольку она развивается относительно дольше и интенсивнее остальных и поэтому является наиболее унифицированной для создания больших интегральных схем самых различных типов и применений. Специализированные для приложений полупроводниковые интегральные схемы (в англоязычной литературе — Application-Specific Integrated Circuit, ASIC), решающие специфический класс задач, имеют уникальную, характерную только для них архитектуру, в этом смысле нейроморфные системы относятся именно к такому типу полупроводниковых устройств, поскольку они обладают структурой, схожей со структурой живых биологических нейронных сетей. Естественно, разработчики стараются реализовать все свойства спайковых нейронных сетей, в принципе способные повысить эффективность вычислений и уменьшить энергозатраты при реализации по современным микроэлектронным технологиям [120].

Однако очевидно, что уже разработанные на сегодняшний день системы пока не обладают плотностью размещения нейроморфных элементов и связей, а также энергоэффективностью, сопоставимыми с таковыми нейронных сетей мозга. И это не случайно, поскольку при

переносе физико-химического строения нейронов и архитектуры биологических нейронных сетей на полупроводниковую (и любую другую микро- и нано-электронную) парадигму невозможен в связи с множеством ограничений.

Например, биологические нейронные сети обладают трёхмерной (3D) архитектурой связей, расположенной в пространстве, а полупроводниковые кристаллы, на которых размещаются интегральные схемы, имеют планарную структуру с ограниченной площадью, и при очень большом количестве элементов схемы (сопоставимым с числом нейронов и связей между ними в мозге человека) их размещение является очень сложной и не всегда выполнимой задачей. Несмотря на то что попытки разработать полупроводники, связанные между собой в трёх направлениях, предпринимаются начиная с 1970-х годов [121], полупроводниковые 3D-технологии пока существуют лишь в единичных экземплярах.

Ещё одной сложностью является реализация асинхронной многоадресной коммуникации ("от одного ко многим"), часто возникающей в системах с параллельной архитектурой, в том числе нейроморфных. Фактически подобная связь должна позволять отдельным элементам или подсистемам целой системы функционировать (т.е., например, генерировать спайки в случае нейроморфных сетей или проводить вычисления для традиционных многопроцессорных систем), не дожидаясь выполнения каких-либо задач остальными элементами или подсистемами. Однако на сегодня подходящей для любой сложной сети асинхронной связи, реализованной на аппаратно-алгоритмическом уровне в непрерывном времени (не дискретизированной по тактовым отсчётам), в общем виде не существует. Имеется лишь ограниченное число соответствующих исследований [122], хотя в некоторых нейроморфных системах, о которых речь пойдёт ниже, например TrueNorth от IBM, такая связь на уровне взаимодействия подсистем уже реализована.

Ещё одна ключевая задача при построении нейроморфной системы — это реализация межэлементных связей, которые в биологических нейронных сетях осуществляются через синаптический контакт — микроскопическую щель между двумя нейронами. Известно, что синапсы бывают двух типов: электрические и химические (в частности, в мозге человека преобладают последние) — и, как предполагается, именно разнообразные свойства химических синапсов, включая синаптическую пластичность, приводят к способности мозга к обучению и хранению информации (памяти). Здесь возникают трудности создания искусственных синапсов с идеальными синаптическими свойствами, и разработчикам вновь приходится решать проблему реализации химических процессов с помощью полупроводниковых или каких-либо других технологий.

В свою очередь должны быть решены проблемы по разработке характеристик искусственных синапсов, таких как динамический диапазон (соотношение между максимальной и минимальной проводимостью синапсов), количество состояний (дискретизация по значению), линейность обновления веса (что позволяет изменить синаптический вес до желаемого значения в процессе обучения), способность удержания весового значения (обеспечивающая длительное хранение данных), циклическую выносливость изменения весовых значений (синаптические веса многократно подстраиваются во время обуче-

ния и соответственно должна быть возможность физической перезаписи состояния). Например, в [123] приводятся примеры использования относительно новых сегнетоэлектрических полевых транзисторов (Ferroelectric Field-Effect Transistor — Fe FET) и органических электрохимических транзисторов (Organic Electrochemical Transistor — ОЕСТ) для реализации искусственных синапсов.

Отметим, что реализация в нейроморфных системах различных свойств биологических нейронных сетей связана со многими ограничениями, обусловленными не только технологическими особенностями микроэлектроники, но и экспериментальными данными и фундаментальными представлениями о свойствах самих биологических сетей и составляющих их компонентов. Таким образом, реализация нейроморфной системы сводится к поиску оптимального решения при достижении компромисса между несколькими факторами: биологической релевантностью системы, технологическими возможностями и преследуемыми целями (т.е. тем, что в итоге должна "уметь" построенная система).

В настоящее время до конца не ясно, насколько полное биологическое сходство ведёт к улучшению конечных возможностей нейроморфной системы, тем не менее очевидно, что чем выше сходство, тем существенно большими будут технологические затраты. Важную роль в этом вопросе играют теоретические и численные исследования динамики функционирования нейроморфных сетей, позволяющие сделать оптимальный выбор достаточно адекватных моделей нейронов и синаптических контактов, которые при построении нейроморфной системы позволят соблюсти баланс между биологической релевантностью и её конечными свойствами и возможностями. Тем не менее даже в рамках современных представлений и технологических возможностей становится очевидным, что нейроморфные сети по сравнению с традиционными процессорными системами более эффективны в решении задач распознавания (изображений, звуков, идентификации газов и др.), прогнозирования временных рядов, а также при решении когнитивных задач.

В разделах 5.1–5.6 рассмотрим примеры нескольких наиболее известных крупных проектов построения нейроморфных систем в виде аппаратных устройств.

5.1. Нейроморфные системы Neurogrid и Braindrop

Исследователями из Стэнфордского университета создано два класса нейроморфных устройств. Первый представляет собой смешанную аналого-цифровую систему Neurogrid, которая может симулировать в реальном времени сети, состоящие из нескольких миллионов спайковых нейронов и нескольких миллиардов синаптических соединений [124]. Neurogrid состоит из 256×256 аналоговых нейронов, изготовленных на 180-нанометровой комплементарной структуре металл–оксид–полупроводник (КМОП) (Complementary Metal–Oxide–Semiconductor — CMOS) для создания ядра Neurocore. Чтобы построить полную систему Neurogrid, 16 чипов Neurocore размещаются на плате и выстраиваются в древовидную структуру. Пример практического применения системы Neurogrid приведён в работе [125], где описан шарнирный робот с тремя степенями свободы, контролируемый Neurogrid. Робот, способный выполнять произвольные движения в трёхмерном пространстве, управляет пером, прикасающимся к поверхности.

Второй проект, называемый Braindrop [126], построен, так же как и Neurogrid, на основе смешанного аналого-цифрового дизайна. Однако, в отличие от Neurogrid, Braindrop разработан для программирования на высоком уровне абстракции. Braindrop использует нейроморфную концепцию в качестве теоретической базы для вычислений, которые определяются как связанные нелинейные динамические системы, а для синтеза систем и оборудования используется автоматизированная процедура. Braindrop производится по 28-нанометровой технологии с использованием полностью обеднённого кремния на изоляторе (Fully-Depleted Silicon-On-Insulator, FD SOI) и объединяет 4096 нейронов на одном чипе Braindrop. Несколько ядер Braindrop будут интегрированы для создания более крупного чипа Brainstorm.

5.2. Нейроморфные системы BrainScaleS и SpiNNaker

Нейроморфные системы BrainScaleS и SpiNNaker разработаны в рамках европейского проекта Human Brain Project (HBP) [127]. BrainScaleS — это нейроморфная система смешанного аналого-цифрового типа, разработанная совместными усилиями исследовательских групп, в том числе из Гейдельбергского университета и Технического университета Дрездена [128, 129]. Технология интеграции, разработанная для BrainScaleS, позволяет использовать 20-сантиметровую пластину для крупномасштабной нейроморфной системы, включающей до 180 тыс. нейронов и 40 млн синапсов. Система BrainScaleS построена путём реализации множества аналоговых нейронных цепей и их синапсов в структуре, называемой ядром аналоговой сети (Analog Network Core — ANC). ANC изготовлено с использованием 180-нанометровой структуры CMOS для создания нейронной сети с большим количеством входных аналоговых сигналов (High Input Count Analog Neural Network — HICANN). 352 чипа HICANN размещаются на одной пластине.

Продолжает разрабатываться второе поколение системы BrainScaleS-2 [130], использующее более сложную модель нейрона, нелинейные преобразования в дендритах, а также другие функции. Также добавлена возможность использовать систему в режиме многослойной сети прямого распространения и для построения свёрточных нейронных сетей без спайков. Эта функция позволяет одновременно комбинировать в BrainScaleS-2 как спайковые нейроны, так и многослойные сети неспайковых нейронов в одном эксперименте.

В рамках проекта HBP исследователи из Манчестерского университета работают над цифровой нейроморфной системой SpiNNaker [131]. В системе SpiNNaker имитируются спайковые нейронные сети в режиме реального времени за счёт соединения более 1 млн ARM-процессоров, которые позволяют моделировать 1 млрд нейронов с биологически реалистичным числом связей (1000–10000 синапсов на нейрон) и с временным разрешением 1 мс. 18 процессоров ARM968 интегрированы в однокристальный мультипроцессор (CMP), изготовленный на основе 130-нанометрового CMOS. 16 процессоров используются для моделирования, один процессор применяется для администрирования и один процессор является резервным на случай неисправности. Полная система, имеющая двумерную тороидальную структуру связей, состоит из 216 CMP.

Первая версия SpiNNaker содержит количество нейронов и связей между ними, составляющее около 1 % от

таковых в человеческом мозге. Второе поколение, названное SpiNNaker2, направлено на моделирование сети, количество нейронов в которой сопоставимо с их количеством, содержащимся в целом мозге [132]. Для достижения этой цели планируется увеличить масштаб системы предыдущего поколения, так что SpiNNaker2 будет иметь 144 ядра ARM MF4 на каждый CMP, изготовленный на основе современной технологии 22FDX (22-нанометровая FD SOI). Кроме того, SpiNNaker2 будет включать в себя новые функции, такие как динамическое управление питанием, поддержка вычислений с плавающей запятой, совместное синхронное использование памяти с соседними ядрами, ускорители с множественным накоплением и другие числовые ускорители.

Проекты SpiNNaker и BrainScaleS развиваются более 12 лет, и примеров их применения достаточно много, отметим лишь некоторые из них. Нейронная спайковая сеть, реализованная на нейроморфном чипе SpiNNaker (4 чипа, 64 ядра), выступает в качестве неинвазивного интерфейса мозг – компьютер, производя декодирование вообразаемых движений по сигналам электроэнцефало-

граммы [133]. Система SpiNNaker может управлять взаимодействием мобильного робота с окружающей средой [134], а также мобильным роботом, интерпретируя визуальные данные [135]. В системе BrainScaleS реализована спайковая сеть, генерирующая случайные выборки с байесовским распределением, которые используют для генеративных и дискриминационных вычислений на визуальных данных [136]. Новое поколение нейроморфной системы BrainScaleS-2 демонстрирует экспериментальную возможность создания спайковой сети с вознаграждением и STDP-синапсами, которая обучается видеоигре Pong [137].

5.3. Система TrueNorth

Нейроморфная платформа TrueNorth (рис. 8) разработана IBM в рамках программы SyNAPSE Управления перспективных исследовательских проектов Министерства обороны США (Defence Advanced Research Projects Agency — DARPA) [138]. Один чип системы TrueNorth состоит из 4096 нейросинаптических ядер, каждое из которых объединяет память ("синапсы"), процессоры




Рис. 8. (В цвете онлайн.) (а) Архитектура системы TrueNorth. Нейросинаптическое ядро 1 является основным строительным блоком, содержащим 256 входных аксонов, 256 нейронов и 64 тыс. синаптических контактов (пересечений). Ядро 2, состоящее из связанных нейронов, синапсов и связей (аксонов и дендритов), занимает на кремнии площадь 240×390 мкм². Объединение 4096 нейросинаптических ядер в двумерный массив формирует чип TrueNorth 3, который занимает площадь 4,3 см² при использовании 28-нанометрового CMOS-техпроцесса 4. Конечным результатом является эффективная аппроксимация кортикальной структуры на кремниевой подложке 5. PRNG (Pseudo Random Number Generator) — генератор псевдослучайных чисел. (Адаптированный рисунок из [138].) (б) Блок-диаграмма нейрона накопление – сброс с утечкой. (Адаптированный рисунок из [138].) (в) Система на основе TrueNorth, состоящая из 64 млн нейронов [139].

("нейроны") и связи ("аксоны"), изготовленные по 45-нанометровой технологии SOI (Silicon-On-Insulator) IBM [140]. На каждом ядре реализовано 256 нейронов накопление – сброс с утечкой, имеющих 1024 аксональные цепи входной связи, организованной по схеме Static Random Access Memory (SRAM) [141]. Один чип TrueNorth, содержащий 5,4 млрд транзисторов, способен имитировать 1 млн нейронов и 256 млн синапсов, интегрированных в единую структуру. Несколько микросхем объединено в более крупную платформу NS16e с 16 микросхемами, что позволило моделировать 16 млн нейронов и 4 млрд синапсов.

Система TrueNorth развита более семи лет, и на ней протестированы многие задачи. Например, она выполняет задачи классификации, демонстрируя очень высокую точность на восьми наборах различных данных (в числе которых изображения различных объектов инфраструктуры, дорожных знаков, номеров домов, различных звуков и произносимых англоязычных фонем), причём имеет внушительную скорость обработки изображений — от 1200 до 2600 кадров в 1 с, потребление энергии составляет от 25 до 275 мВт [142]. Система TrueNorth реализует фильтрацию шума для датчика изображения с асинхронным обнаружением изменений для движущихся объектов (так называемая кремниевая сетчатка, новый класс датчиков зрения, функционирующий на основе биологических принципов зрения), при этом фильтрация превосходит традиционный шумовой фильтр ближайшего соседа [143].

5.4. Система Loihi

Компания Intel разработала цифровой нейроморфный исследовательский чип Loihi [144], который имеет уникальный программируемый движок обучения спайковых нейронных сетей на кристалле. Loihi изготавливается по 14-нанометровому техпроцессу Intel. Помимо 128-нейроморфных ядер на чипе есть три ядра Lakemont, ко-

торые реализуют более сложные правила обучения с управлением нейроморфными ядрами. 128-нейроморфные ядра реализуют 130 тыс. искусственных нейронов (CUBA IF [86, 145]) и 130 млн синапсов. Подробная блок-схема такого нейрона представлена на рис. 9. Конструкция Loihi поддерживает масштабирование до 4096 ядер на кристалле и 16384 микросхемы. Все ядра функционируют асинхронно, поэтому при получении сигналов каждое ядро может тратить различное время на их обработку; однако только после того, как все ядра завершат обработку, начнётся следующая итерация по передаче спайков и их обработке. Данное свойство означает, что чем больше спайков генерируется во всей системе, тем дольше будет обрабатываться каждая итерация.

Как заявляет компания Intel, данный чип по сравнению с другими является полностью детерминированным, т.е. передача всех спайков между всеми нейронами гарантируется, и при одинаковых начальных условиях вычислительный процесс будет полностью повторяться даже при размерах системы, сравнимых по количеству нейронов и синапсов с человеческим мозгом. Для рассматриваемого устройства реализован язык программирования, позволяющий определять различные параметры как самих нейронов, так и синаптических связей, а также структуру связей между нейронами.

Нейроморфная система Loihi демонстрирует различные возможности её использования в области обучения спайковых сетей. Например, с помощью системы Loihi реализована спайковая сеть, классифицирующая видеоданные дорожной обстановки, необходимые для решения задач автономного управления автомобилем. Реализация с помощью нейроморфного оборудования имеет максимальную задержку 0,72 мс для каждой выборки и потребляет всего 310 мВт [146]. В работе [147] система Loihi используется для распознавания изображений, рукописных цифр и других данных, а также проводится




Рис. 9. (В цвете онлайн.) Строение нейрона CUBA IF в системе Loihi. Цветные прямоугольники соответствуют блокам памяти, в которых хранятся связи, конфигурация и динамическое состояние всех нейронов. Цвет линий, соединяющих блоки памяти, и цвет самих блоков обозначают четыре основных режима работы: обработка входных импульсов (зелёный), обновление отдельных блоков нейрона (фиолетовый), генерация выходных импульсов (синий) и обновления синапсов (красный). Чёрная структура UCODE (Update CODE) — код обновления — реализует настраиваемый механизм обучения. SYNAPSE_MAP PRE-TRACE — ячейка памяти для описания синапсов, SYNAPSE MEM — состояние пресинаптической обработки, DENDRITE ACCUM — ячейка памяти для описания дендритов, CX META_STATE — начальное состояние компонентов нейрона, CX_CFG — конфигурация компонентов нейрона, CX STATE — состояние компонентов нейрона, SOMA STATE — состояние сомы, AXON MAP — ячейка памяти для описания аксонов, AXON MEM — состояние аксонов, UCODE → ΣPT_{ij} — правила обновления переменных T_{ij} обучения. N_{axin} — число входных аксонов, N_{axout} — число выходных аксонов, N_{syn} — объём синаптической памяти, N_{cx} — число компонентов нейрона, N_{sdelay} — наименьшая синаптическая задержка.

сравнение её эффективности с эффективностью других нейроморфных систем. На системе Loihi реализована нейронная сеть онлайн-обучения и идентификации образцов запахов в условиях шума, основанная на архитектуре обонятельной луковицы млекопитающих, при этом используются синапсы с STDP-пластичностью [148].

5.5. Система "Алтай"

В Российской Федерации также есть примеры разработки нейроморфных систем. Компания ООО "Мотив" (г. Новосибирск) представила нейроморфный чип "Алтай", разрабатываемый для применения в робототехнических комплексах, специализированных системах в задачах классификации и распознавания [149]. Сама микросхема представляет собой масштабируемую сеть нейроядер. Ядро представляет собой небольшую обособленную группу спайковых нейронов, коммуникация между которыми осуществляется посредством матрицы связей, обеспечивающей высокую пропускную способность сигналов и исключающей их взаимную блокировку. Ядра связаны в двумерную сеть, и для коммуникации между ними используются разделяемые шины и относительная маршрутизация AER (Address Event Representation). В нейроморфном чипе "Алтай", так же как и в Loihi, используется асинхронная работа ядер, однако внутри ядра вычисления происходят синхронно. В качестве модели нейрона применяется модифицированная модель нейрона накопление–сброс с постоянной величиной утечки. Каждый нейрон имеет дискретный набор разрешённых состояний (целочисленные вычисления). Чип содержит решётку нейроядер 32×32 , т.е. 1024 ядра, в которых расположены 262144 нейрона и 67108864 синапса [149], микросхема выполнена по 28-нанометровой технологии.

5.6. Система Tianjic

Группа исследователей из Китая, Сингапура и США представила нейроморфный чип Tianjic [150], на котором возможно программирование двух типов сетей. Первый тип — сети частотных нейронов, представленных функциями активации от взвешенной суммы входов. Второй тип — спайковые нейронные сети, в которых в качестве модели используется нейрон накопление–сброс. Оба типа сетей также содержат модели дендритов и аксонов и синаптических связей между ними. На чипе можно реализовать модели не только одного типа, но и совместно двух типов. Чип, выполненный по 28-нанометровой технологии, имеет тактовую частоту 300 МГц, площадь кристалла 14,44 мм², его энергопотребление 0,95 Вт. Один чип содержит 156 ядер, на которых размещаются 40000 нейронов и 10^6 синапсов. Чипы могут объединяться между собой и обеспечивать взаимодействие между нейросетями, расположенными на разных чипах. На рисунке 10 представлены фотографии одного чипа и массива из 25 связанных чипов.

В [150] приводятся результаты использования такого чипа для управления двухколёсным велосипедом, следующим за человеком и обрабатывающим голосовые команды, т.е. чип производит обработку и распознавание изображений, распознавание нескольких голосовых команд, а также управляет несколькими параметрами движения (угловой скоростью вращения колеса, двумя углами, поступательной скоростью движения), при этом сети, отвечающие за соответствующее управление той




Рис. 10. (В цвете онлайн.) (а) Нейроморфный чип Tianjic в корпусе и увеличенная схема одного ядра, в которой цветом выделены составляющие нейронной сети и управляющие элементы. (б) Массив из 25 объединённых чипов [150].

или иной функцией, имеют разную топологию связей и различный тип.

В целом, развитие аппаратных нейроморфных систем, имитирующих основные принципы работы мозга, нацелено на разработку и реализацию алгоритмов, которые потребляют гораздо меньше энергии и легче масштабируются до массового распараллеливания вычислительных архитектур по сравнению со стандартными нейросетями глубокого обучения и работают в режиме реального времени (см. таблицу).

6. Заключение

Несмотря на успехи в экспериментальном изучении сетей мозга на различных масштабах пространства и времени и на развитие математического моделирования активности в нервной системе, мы ещё далеки от всестороннего понимания того, как элементарные процессы передачи коротких импульсов между нейронами в итоге складываются в реализацию организмом сложных сенсорных, двигательных и когнитивных функций. Один из подходов — восходящий — связан с нахождением коннектома, т.е. детального устройства связей между нервными клетками, и установлением режимов индивидуальной активности составляющих сеть нейронов. Казалось бы, имея в явном виде матрицу связей между нейронами и уравнения, описывающие динамику каждого из них, можно сделать выводы о том, какие функциональные свойства такая сеть будет демонстрировать. Однако подобная математическая модель с огромным массивом переменных и параметров оказывается почти такой же сложной для анализа, как и биологический прототип. Её можно интегрировать с использованием суперкомпьютерных технологий, получая временные ряды, но ответить на вопрос о механизмах выполнения той или иной функции на основе этих данных не всегда представляется возможным.

Альтернативный подход — нисходящий — отталкивается от анализа конкретных преобразований входных

Таблица. Сравнение характеристик нейроморфных систем

Нейроморфное устройство	Граф связей	Пластичность	Количество нейронов\количество синапсов на один нейрон	Модель	Пропуск обмена спайками
Neurogrid	Иерархический (древовидный), программируемый	Нет	65536 (на одном чипе)\256	Аналоговая LIF	Нет
SpiNNaker	Иерархический (древовидный), программируемый, двумерная сеть (2D Mesh)	Программируемые модели	10^9 \Программируемое до 1000	Программируемые модели	Возможен
BrainScaleS	Иерархический (древовидный)	LTP, STP, STDP	4×10^6 \224-14336	ALIF и/или перцептрон	Возможен
TrueNorth	Программируемый	Нет	10^6 (на одном чипе)\256	LIF	Возможен
Loihi	Иерархическая (древовидная), двумерная сеть (2D Mesh), адресная (задаваемая)	LTP, STP, STDP	130000 (на одном чипе)\1000	CUBA IF	Нет
Алтай	Программируемый	—	262144 (на одном чипе)\256	LIF	—
Tianjic	Программируемый	Офлайн-STDP-обучение весов	40000 (на одном чипе)\250	LIF и/или перцептрон	—

стимулов в выходные отклики, выполняемые нейронной сетью. На основе методов машинного обучения происходит настройка нейронной сети, в первую очередь её весовых коэффициентов, для выполнения аналогичных преобразований, сформулированных в виде целевых функций. Полученная искусственная нейронная сеть представляет собой динамическую систему, которая, с одной стороны, учитывает определённые аспекты структуры и активности прототипной нейронной сети, а с другой — является способной выполнять заданные целевые функции. Исследование данной многомерной динамической системы методами нелинейной динамики и теории сложных сетей позволяет выявить механизмы реализации сетью анализируемых сенсорных, моторных или когнитивных функций. Приведённые в настоящем обзоре примеры применения рекуррентных нейронных сетей демонстрируют эффективность описанного подхода. Однако изначальные допущения, очевидно, ограничивают возможности полного понимания принципов кодирования и обработки когнитивной информации головным мозгом.

Во-первых, случайная рекуррентная топология связей контрастирует с высокоорганизованными и структурированными отделами мозга, и добавление в модель выявленных структурных свойств с большой вероятностью улучшит характеристики искусственной сети. Например, в ряде работ в структуру модели заложен принцип Дейла, который состоит в том, что порядка 80 % кортикальных нейронов имеют возбуждающие связи, а 20 % — подавляющие. В то же время полностью коннектом межнейронных связей прочитан лишь для самых простых существ, таких как почвенная нематода *C. elegans*, а для высших организмов существующий инструментарий пока не позволяет с аналогичной детализацией определить точную топологию. С другой стороны, в нервной системе двух особей одного вида коннектомы не идентичны друг другу, а значит, актуальной остаётся задача выявить общие закономерности структуры связей, которые превосходят индивидуальные различия и позволяют выполнять сложные нервные функции. Моделирование с

помощью искусственных нейронных сетей, возможно, поможет выявить искомые характеристики, поскольку в ходе оптимизации параметров сеть настраивается на выполнение определённых целевых задач и с помощью найденных свойств коннектома обученной сети можно выдвигать гипотезы о важности той или иной структуры в решении конкретных задач.

Во-вторых, методы обучения в приведённых примерах, основанные на контролируемой минимизации ошибки с помощью стохастического градиентного спуска, не являются биологически релевантными. Этот факт не означает, что обученная сеть не может нести в себе черты работы вплоть до уровня индивидуальной активности отдельных нейронов, свойственные биологическому прототипу, поскольку модельная система после обучения всё же решает целевую задачу; однако путь, по которому она приходит в стадию выполнения целевой функции, не отражает сути процессов, происходящих в биологических системах. В данном направлении актуальными являются задачи применения уже установленных в эксперименте на сегодня законов пластичности различных типов, которые характеризуются тем, что, в отличие от градиентного спуска, обучение происходит онлайн, т.е. в текущем времени, и локально, т.е. интенсивность синаптических связей определяется активностью смежных нейронов и концентрацией доступных нейромедиаторов. Кроме того, обучение в естественных условиях происходит в окружающей среде, и целевой сигнал, так же как и сигнал ошибки, часто недоступен когнитивному агенту в явном виде. В такой ситуации нахождение решения происходит за счёт штрафов и поощрений, получаемых извне, и адекватным методом, описывающим этот процесс в искусственных нейронных сетях, является концепция обучения с подкреплением.

Таким образом, двигаясь в направлении всё большей детализации индивидуальной активности нейронов и структуры межнейронных связей, базируясь в то же время на моделях, эффективных для машинного обучения, исследования в рамках данного подхода способны выяв-

лять динамические механизмы выполнения сетями мозга всё более сложных задач. Реализация в модельных системах биоинспирированных свойств пластичности позволяет, на наш взгляд, установить причины высокой адаптивности и многозадачности, свойственных сетям мозга.

За время подготовки обзора к печати вышел целый ряд работ, актуальных по обсуждаемой в обзоре тематике. Среди них отметим следующие публикации, важные для соответствующих разделов обзора: [151–157] (раздел 3), [158–160] (раздел 4), [161, 162] (раздел 5).

Работа профинансирована Министерством науки и высшего образования РФ в рамках государственного задания ИПФ РАН, проект № 0030-2021-0011.

Список литературы

- Gerstner W et al. *Neuronal Dynamics: From Single Neurons to Networks and Models of Cognition* (Cambridge: Cambridge Univ. Press, 2014)
- Bassett D S, Zurn P, Gold J I *Nat. Rev. Neurosci.* **19** 566 (2018)
- Breakspear M *Nat. Neurosci.* **20** 340 (2017)
- Ashwin P, Coombes S, Nicks R J *J. Math. Neurosci.* **6** 2 (2016)
- Izhikevich E M *Dynamical Systems in Neuroscience: the Geometry of Excitability and Bursting* (Cambridge, MA: MIT Press, 2007)
- Rabinovich M I et al. *Rev. Mod. Phys.* **78** 1213 (2006)
- Храмов А Е и др. *УФН* **191** 614 (2021); Hramov A E et al. *Phys. Usp.* **64** 584 (2021)
- Иваницкий Г Р, Морозов А А *УФН* **190** 1165 (2020); Ivanitskii G R, Morozov A A *Phys. Usp.* **63** 1092 (2020)
- Иваницкий Г Р *УФН* **188** 965 (2018); Ivanitskii G R *Phys. Usp.* **61** 871 (2018)
- Доронина-Амитонова Л В и др. *УФН* **185** 371 (2015); Doronina-Amitonova L M et al. *Phys. Usp.* **58** 345 (2015)
- Клиньшов В В, Некоркин В И *УФН* **183** 1323 (2013); Klinshov V V, Nekorkin V I *Phys. Usp.* **56** 1217 (2013)
- Павлов А Н и др. *УФН* **182** 905 (2012); Pavlov A N et al. *Phys. Usp.* **55** 845 (2012)
- Рабинович М И, Мюезинолу М К *УФН* **180** 371 (2010); Rabinovich M I, Muezzinoglu M K *Phys. Usp.* **53** 357 (2010)
- Некоркин В И *УФН* **178** 313 (2008); Nekorkin V I *Phys. Usp.* **51** 295 (2008)
- Безручко Б П и др. *УФН* **178** 323 (2008); Bezruchko B P et al. *Phys. Usp.* **51** 304 (2008)
- Борисюк Г Н и др. *УФН* **172** 1189 (2002); Borisjuk G N et al. *Phys. Usp.* **45** 1073 (2002)
- Абарбанель Г Д и др. *УФН* **166** 363 (1996); Abarbanel H D et al. *Phys. Usp.* **39** 337 (1996)
- Иваницкий Г Р, Медвинский А Б, Цыганов М А *УФН* **164** 1041 (1994); Ivanitskii G R, Medvinskii A B, Tsyganov M A *Phys. Usp.* **37** 961 (1994)
- Rabinovich M I, Zaks M A, Varona P *Phys. Rep.* **883** 1 (2020)
- Rabinovich M I, Friston K J, Varona P *Principles of Brain Dynamics: Global State Interactions* (Cambridge, MA: MIT Press, 2012)
- Rabinovich M I et al. *Phys. Life Rev.* **9** (1) 51 (2012)
- Шумский С А *Машинный интеллект. Очерки по теории машинного обучения и искусственного интеллекта* (М.: РИОР, 2019)
- Lake B M et al. *Behavioral Brain Sci.* **40** e253 (2017)
- Vyas S et al. *Annu. Rev. Neurosci.* **43** 249 (2020)
- Sussillo D *Current Opin. Neurobiol.* **25** 156 (2014)
- Barak O *Current Opin. Neurobiol.* **46** 1 (2017)
- Yang G R, Wang X-J *Neuron* **107** 1048 (2020)
- Glaser J I et al. *Prog. Neurobiol.* **175** 126 (2019)
- Marblestone A H, Wayne G, Kording K P *Front. Comput. Neurosci.* **10** 94 (2016)
- Hassabis D et al. *Neuron* **95** 245 (2017)
- Cichy R M, Kaiser D *Trends Cognitive Sci.* **23** 305 (2019)
- Киселев М *Импульсные нейронные сети: Представление информации, обучение, память* (Chisinau: Palmarium Acad. Publ., 2020)
- Zenke F, Ganguli S *Neural Computat.* **30** 1514 (2018)
- Nicola W, Clopath C *Nat. Commun.* **8** 2208 (2017)
- Mozafari M et al., arXiv:1804.00227
- Bellec G et al. *Adv. Neural Inform. Proc. Syst.* **31** 787 (2018)
- Schuman C D et al., arXiv:1705.06963
- James C D et al. *Biol. Inspired Cognitive Arch.* **19** 49 (2017)
- Chen Y et al. *Integration* **61** 49 (2018)
- Schmidhuber J *Neural Networks* **61** 85 (2015)
- Samarasinghe S *Neural Networks for Applied Sciences and Engineering: from Fundamentals to Complex Pattern Recognition* (Boca Raton, FL: CRC Press, 2016)
- Botvinick M et al. *Neuron* **107** 603 (2020)
- Botvinick M et al. *Trends Cognitive Sci.* **23** 408 (2019)
- Sompolinsky H, Crisanti A, Sommers H J *Phys. Rev. Lett.* **61** 259 (1988)
- Jaeger H, Haas H D *Science* **304** 78 (2004)
- Sussillo D, Abbott L F *Neuron* **63** 544 (2009)
- Дмитричев А С и др. *Изв. вузов. Прикладная нелинейная динамика* **26** (4) 5 (2018)
- Abbott L F *Brain Res. Bull.* **50** 303 (1999)
- Ermentrout B *Neural Comput.* **8** 979 (1996)
- Latham P E et al. *J. Neurophysiol.* **83** 808 (2000)
- Fourcaud-Trocmé N et al. *J. Neurosci.* **23** 11628 (2003)
- Ermentrout G B, Kopell N *SIAM J. Appl. Math.* **46** 233 (1986)
- Brette R, Gerstner W *J. Neurophysiol.* **94** 3637 (2005)
- Douglas R J, Martin K A J *J. Physiol.* **440** 735 (1991)
- Van Vreeswijk C, Sompolinsky H *Science* **274** 1724 (1996)
- LeCun Y, Bengio Y, Hinton G *Nature* **521** 436 (2015)
- Sussillo D, Barak O *Neural Comput.* **25** 626 (2013)
- Maslennikov O V, Nekorkin V I *Nonlin. Dyn.* **101** 1093 (2020)
- Pugavko M M, Maslennikov O V, Nekorkin V I *Commun. Nonlin. Sci. Numer. Simulat.* **90** 105399 (2020)
- Пугавко М М, Маслеников О В, Некоркин В И *Изв. вузов. Прикладная нелинейная динамика* **28** (1) 77 (2020)
- Maslennikov O V, Nekorkin V I *Chaos* **29** 103126 (2019)
- Маслеников О В, Некоркин В И *УФН* **187** 745 (2017); Maslennikov O V, Nekorkin V I *Phys. Usp.* **60** 694 (2017)
- Mante V et al. *Nature* **503** 78 (2013)
- Chaisangmongkon W et al. *Neuron* **93** 1504 (2017)
- Freedman D J, Assad J A *Nature* **443** 85 (2006)
- Swaminathan S K, Freedman D J *Nat. Neurosci.* **15** 315 (2012)
- Wang J et al. *Nat. Neurosci.* **21** 102 (2018)
- Yang G R et al. *Nat. Neurosci.* **22** 297 (2019)
- Zhang X et al. *eLife* **8** e43191 (2019)
- Romo R et al. *Nature* **399** 470 (1999)
- Genovesio A, Tsujimoto S, Wise S P *Neuron* **63** 254 (2009)
- Inagaki H K et al. *Nature* **566** 212 (2019)
- Barracough D J, Conroy M L, Lee D *Nat. Neurosci.* **7** 404 (2004)
- Purcell B A, Kiani R *Proc. Natl. Acad. Sci. USA* **113** E4531 (2016)
- Remington E D et al. *Neuron* **98** 1005 (2018)
- Padoa-Schioppa C, Assad J A *Nature* **441** 223 (2006)
- Munoz D P, Everling S *Nat. Rev. Neurosci.* **5** 218 (2004)
- Wilson H R, Cowan J D *Biophys. J.* **12** (1) 1 (1972)
- Dayan P, Abbott L F *Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems* (Cambridge, MA: Massachusetts Institute of Technology Press, 2001)
- Maass W *Neural Networks* **10** 1659 (1997)
- Roy K, Jaiswal A, Panda P *Nature* **575** 607 (2019)
- Tavanaei A et al. *Neural Networks* **111** 47 (2019)
- Pfeiffer M, Pfeil T *Front. Neurosci.* **12** 774 (2018)
- Perrinet L, Samuelides M, Thorpe S *IEEE Trans. Neural Networks* **15** 1164 (2004)
- Escobar M-J *Int. J. Comput. Vision* **82** 284 (2009)
- Brette R et al. *J. Comput. Neurosci.* **23** 349 (2007)
- Gerstner W, van Hemmen J L *Network Comput. Neural Syst.* **3** (2) 139 (1992)
- Sommer F T, Wennekers T *Neural Networks* **14** 825 (2001)
- Amit D J, Mongillo G *Neural Comput.* **15** 565 (2003)
- Mongillo G, Barak O, Tsodyks M *Science* **319** 1543 (2008)
- Szatmáry B, Izhikevich E M *PLoS Comput. Biol.* **6** e1000879 (2010)
- Buzsáki G *Rhythms of the Brain* (Oxford: Oxford Univ. Press, 2006)
- Izhikevich E M, Edelman G M *Proc. Natl. Acad. Sci. USA* **105** 3593 (2008)
- Ma J, Wu J *Neural Comput.* **19** 2124 (2007)
- Oster M, Douglas R, Liu S-C *Neural Comput.* **21** 2437 (2009)
- Jin D Z, Seung H S *Phys. Rev. E* **65** 051922 (2002)
- Lumer E D *Neural Comput.* **12** 181 (2000)
- Wang X-J *Neuron* **60** 215 (2008)
- Atiya A F, Parlos A G *IEEE Trans. Neural Networks* **11** 697 (2000)
- Dominey P F, Ramus F *Language Cognitive Proces.* **15** (1) 87 (2000)
- Jaeger H, Technical GMD Report 148 (Boon: German National Research Center for Information Technology GMD, 2001) p. 13
- Maass W, Natschläger T, Markram H *Neural Comput.* **14** 2531 (2002)

103. Schrauwen B, Verstraeten D, Van Campenhout J M, in *Proc. of the 15th European Symp. on Artificial Neural Networks, ESANN 2007, Bruges, Belgium, April 25–27, 2007*, p. 471
104. Lukoševičius M, Jaeger H *Comput. Sci. Rev.* **3** (3) 127 (2009)
105. Häusler S, Markram H, Maass W *Complexity* **8** (4) 39 (2003)
106. Joshi P, Maass W *Neural Comput.* **17** 1715 (2005)
107. Burgsteiner H, in *Novel Applications of Neural Networks in Engineering. Proc. of the 9th Intern. Conf. on Engineering Applications of Neural Networks, 24–26 August 2005, Lille, France* (Douai: École des Mines de Douai, 2005) p. 129
108. Kasiński A, Ponulak F *Int. J. Appl. Math. Comput. Sci.* **16** 101 (2006)
109. Verstraeten D et al. *Inform. Proces. Lett.* **95** 521 (2005)
110. Ponulak F, Kasiński A *Neural Comput.* **22** 467 (2010)
111. Raven J C, Court J H, Raven J *Manual for Raven's Progressive Matrices and Vocabulary Scales* (Oxford: Oxford Psychologists Press, 1998)
112. Eliasmith C et al. *Science* **338** 1202 (2012)
113. Voelker A R, Eliasmith C *Neural Comput.* **30** 569 (2018)
114. Bekolay T et al. *Front. Neuroinform.* **7** 48 (2014)
115. Boahen K *Comput. Sci. Eng.* **19** (2) 14 (2017)
116. Liu S-C et al. *Analog VLSI: Circuits and Principles* (Cambridge, MA: MIT Press, 2002)
117. Indiveri G et al. *Front. Neurosci.* **5** 73 (2011)
118. Tang J et al. *Adv. Mater.* **31** 1902761 (2019)
119. Kelly J E (III), Hamm S *Smart Machines: IBM's Watson and the Era of Cognitive Computing* (New York: Columbia Business School Publ., 2013)
120. Zheng N, Mazumder P *Learning in Energy-Efficient Neuromorphic Computing: Algorithm and Architecture Co-Design* (Hoboken, NJ: Wiley–IEEE Press, 2019)
121. Minvielle R, Bayoumi M, in *2013 4th Annual Intern. Conf. on Energy Aware Computing Systems and Applications, ICEAC* (Piscataway, NJ: IEEE, 2013) p. 125
122. Bhardwaj K, Nowick S M *IEEE Trans. Very Large Scale Integrat. VLSI Syst.* **27** (2) 350 (2019)
123. Kim M-K et al. *iScience* **23** 101846 (2020)
124. Benjamin B V et al. *Proc. IEEE* **102** 699 (2014)
125. Menon S et al., in *Proc. of the 5th IEEE/RAS–EMBS Intern. Conf. on Biomedical Robotics and Biomechanics* (Piscataway, NJ: IEEE, 2014) p. 181
126. Neckar A et al. *Proc. IEEE* **107** 144 (2019)
127. Markram H et al. *Procedia Comput. Sci.* **7** 39 (2011); in *Proc. of the 2nd European Future Technologies Conf. and Exhibition, FET 11, 4–6 May 2011, Budapest, Hungary* (Amsterdam: Elsevier, 2011) p. 11
128. Schemmel J et al., in *ISCAS 2010, 2010 IEEE Intern. Symp. on Circuits and Systems Nano-Bio Circuit Fabrics and Systems, May 30th–June 2nd, 2010, Paris, France* (Piscataway, NJ: IEEE, 2010) p. 1947
129. Scholze S et al. *Front. Neurosci.* **5** 117 (2011)
130. Schemmel J, in *Proc. of the 6th Annual Neuro Inspired Computational Elements, NICE, Conf., Hillsboro, Oregon, 2018*
131. Furber S, Brown A, in *Proc. of the Ninth Intern. Conf. on Application of Concurrency to System Design, 1–3 July 2009, Augsburg, Germany* (Eds S Edwards, R Lorenz, W Vogler) (Los Alamitos, CA: IEEE Computer Soc., 2009) p. 3
132. Höppner S, Mayr C, in *Proc. of the 6th Annual Neuro Inspired Computational Elements, NICE, Conf., Hillsboro, Oregon, 2018*
133. Tayeb Z, Ergelik E, Conradt J, in *Proc. of the 8th Intern. IEEE EMBS Conf. on Neural Engineering NER, May 25–28, 2017, Shanghai, China* (Piscataway, NJ: IEEE, 2017) p. 263
134. Galluppi F et al. in *2014 IEEE Intern. Conf. on Robotics and Automation, ICRA, 31 May–5 June, 2014, Hong Kong, China* (Piscataway, NJ: IEEE, 2014) p. 2862
135. Denk C et al., in *Artificial Neural Networks and Machine Learning — ICANN 2013, 23rd Intern. Conf. on Artificial Neural Networks, Sofia, Bulgaria, September 10–13, 2013, Proc. (Lecture Notes in Computer Science, Vol. 8131, Eds V Mladenov et al.)* (Berlin: Springer, 2013) p. 467
136. Kungl A F et al. *Front. Neurosci.* **13** 1201 (2019)
137. Wunderlich T et al. *Front. Neurosci.* **13** 260 (2019)
138. Akopyan F et al. *IEEE Trans. Computer-Aided Design Integrated Circuits Syst.* **34** 1537 (2015)
139. DeBole M V et al. *Computer* **52** (5) 20 (2019)
140. Amir A et al., in *The 2013 Intern. Joint Conf. on Neural Networks IJCNN, 4–9 Aug. 2013* (Piscataway, NJ: IEEE, 2013) p. 1
141. Merolla P et al., in *2011 IEEE Custom Integrated Circuits Conf., CICC* (Piscataway, NJ: IEEE, 2011) p. 1
142. Esser S K et al. *Proc. Natl. Acad. Sci. USA* **113** 11441 (2016)
143. Padala V, Basu A, Orchard G *Front. Neurosci.* **12** 118 (2018)
144. Davies M et al. *IEEE Micro* **38** (1) 82 (2018)
145. Vogels T P, Abbott L F *J. Neurosci.* **25** 10786 (2005)
146. Viale A et al., arXiv:2107.00401
147. Rueckauer B et al., arXiv:2101.04261
148. Imam N, Cleland T A *Nat. Mach. Intell.* **2** 181 (2020)
149. Канглер В М, Панченко К Е, в сб. *Беспилотные транспортные средства с элементами искусственного интеллекта. Третий Всероссийский научно-практический семинар, 22–23 сентября 2015, Иннополис, Республика Татарстан, Россия. Труды семинара. Российская ассоциация искусственного интеллекта* (М.: Перо, 2016) с. 169
150. Pei J et al. *Nature* **572** 106 (2019)
151. Yang G R, Molano-Mazón M *Current Opin. Neurobiol.* **70** 182 (2021)
152. Pulvermüller F et al. *Nat. Rev. Neurosci.* **22** 488 (2021)
153. Zhang X, Liu S, Chen Z S *iScience* **24** 102919 (2021)
154. Goulas A, Damicelli F, Hilgetag C C *Neural Networks* **142** 608 (2021)
155. Масленников О В *Изв. вузов. Прикладная нелинейная динамика* **29** 799 (2021)
156. Ehrlich D B et al. *eNeuro* **8** (1) 0427-20 (2021)
157. Chung S, Abbott L F *Current Opin. Neurobiol.* **70** 137 (2021)
158. Xue X et al. "Spiking recurrent neural networks represent task-relevant neural sequences in rule-dependent computation" *Cogn. Comput.* (2022) <https://doi.org/10.1007/s12559-022-09994-2>
159. Calaim N et al. *eLife* **11** e73276 (2022)
160. Пугавко М М, Масленников О В, Некоркин В И *Изв. вузов. Радиофизика* **64** 817 (2021); Pugavko M M, Maslennikov O V, Nekorkin V I *Radiophys. Quantum Electron.* **64** 736 (2022)
161. Schuman C D et al. *Nat. Comput. Sci.* **2** 10 (2022)
162. Ivanov D et al. *Front. Neurosci.* (2022) <https://doi.org/10.3389/fnins.2022.959626>

Nonlinear dynamics and machine learning of recurrent spiking neural networks

O.V. Maslennikov^(*), M.M. Pugavko, D.S. Shchapin, V.I. Nekorkin

Federal Research Center Institute of Applied Physics, Russian Academy of Sciences,
ul. Ul'yanova 46, 603950 Nizhny Novgorod, Russian Federation
E-mail: ^(*)olmaov@ipfran.ru

Major achievements in designing and analyzing recurrent spiking neural networks intended for modeling functional brain networks are reviewed. Key terms and definitions employed in machine learning are introduced. The main approaches to the development and exploration of spiking and rate neural networks trained to perform specific cognitive functions are presented. State-of-the-art neuromorphic hardware systems simulating information processing by the brain are described. Concepts of nonlinear dynamics are discussed, which enable identification of the mechanisms used by neural networks to perform target tasks.

Keywords: artificial neural networks, nonlinear dynamics, machine learning, spiking neurons, modeling of cognitive functions

PACS numbers: 07.05.Mh, **84.35.+i**, 87.19.L–

Bibliography — 162 references

Uspekhi Fizicheskikh Nauk **192** (10) 1089–1109 (2022)

DOI: <https://doi.org/10.3367/UFNr.2021.08.039042>

Received 1 June 2021, revised 13 August 2021

Physics – Uspekhi **65** (10) (2022)

DOI: <https://doi.org/10.3367/UFNe.2021.08.039042>