

DOI: 10.5862/JCSTCS.234.6

УДК 004.023, 004.383.8.032.26

Е.Н. Бендерская, А.О. Перешейн

ХАОТИЧЕСКИЕ МОДЕЛИ ГИППОКАМПА В ЗАДАЧАХ РАСПОЗНАВАНИЯ ДИНАМИЧЕСКИХ ОБРАЗОВ

E.N. Benderskaya, A.O. Pereshein

CHAOTIC MODELS OF THE HIPPOCAMPUS FOR DYNAMIC PATTERN RECOGNITION

Проведен анализ использования систем с хаотической динамикой для решения задачи распознавания динамических образов. Выполнен анализ существующих хаотических моделей гиппокампа для решения задачи хранения, кодирования и воспроизведения динамических образов. Для детального анализа отобраны: модель хаотической эпизодической памяти Осаны, модель неокортекса-гиппокампа Куремото, модель гиппокампа Тсуды. Первые две модели построены с включением в свой состав хаотической нейронной сети Айхары. Для отобранных моделей выполнено подробное сравнение на основании результатов проведенного моделирования. Показана роль хаотической динамики при учете контекста в задаче распознавания динамических образов. Также определены направления развития рассмотренных моделей.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ; НЕЛИНЕЙНАЯ ДИНАМИКА; ХАОТИЧЕСКИЕ НЕЙРОННЫЕ СЕТИ; ЭПИЗОДИЧЕСКАЯ ПАМЯТЬ; МОДЕЛИ ГИППОКАМПА; РАСПОЗНАВАНИЕ ДИНАМИЧЕСКИХ ОБРАЗОВ.

The paper carried out an analysis of using systems with chaotic dynamics to solve the problem of dynamic pattern recognition. We reviewed the existing chaotic models of the hippocampus for storage, coding and retrieval of dynamic information. An episodic chaotic associative memory models proposed by Y. Osana, a hippocampus-neocortex model proposed by T. Kuremoto, and Tsuda's hippocampus model are considered in detail. The first two of these models incorporate Aihara's chaotic neural networks. We compared the selected models based on the simulation results. It is shown that chaotic dynamics is necessary in order to take into account the context of dynamic pattern recognition problems. Trends of further modification of the models are also proposed.

ARTIFICIAL INTELLIGENCE; NONLINEAR DYNAMICS; CHAOTIC NEURAL NETWORKS; EPISODIC MEMORY; MODELS OF THE HIPPOCAMPUS; DYNAMIC PATTERN RECOGNITION.

Различные методы и алгоритмы, относящиеся к научному направлению под названием *искусственный интеллект*, уже давно успешно применяются для решения различных задач в отдельных проблемных областях. Но при этом системы, реализующие такие алгоритмы, не обладают достаточной гибкостью и универсальностью. Возможно и по этой причине (создание множества специфических подходов к решению каждой прикладной задачи), на данный момент еще не решена одна из главных задач

искусственного интеллекта: понимание и моделирование мышления, схожего с человеческим.

На фоне различных отдельных подходов, направленных на решение конкретных прикладных задач, выделяется направление, связанное с универсальным подходом и получившее название *сильный* или *универсальный искусственный интеллект*. Предполагается, что истинно интеллектуальное решение поставленных задач должно обладать универсальностью и основываться на



процессах самоорганизации, т. е. обладать свойствами, помогающими в решении поставленных задач, но не закладываемыми в систему разработчиком непосредственно. Универсальные системы требуют другого, качественного подхода, а не просто интеграции нескольких модулей, решающих разные задачи, в одну систему.

Одним из подходов к построению интеллектуальных систем является использование нелинейных систем с хаотической динамикой [1, 2]. Существование хаоса в системе и ее сложное поведение может обеспечиваться за счет простого нелинейного взаимодействия компонент, что невозможно выявить с помощью принципа декомпозиции. При этом на фоне нерегулярной активности отдельных элементов проявляется синхронизация всей системы, т. е. самоорганизация.

Большое значение при разработке общих интеллектуальных методов обработки информации придается тому, как те же задачи решает человек. Примечательно, что биологические системы в здоровом состоянии обладают предельно неустойчивой динамикой. В связи с этим актуально исследование методов и моделей, построенных по аналогии с биологическими структурами (например, гиппокампом) в рамках рассмотрения нелинейных систем обработки информации.

Цель данной работы – выявление наиболее перспективных моделей обработки информации в нелинейных динамических системах, построенных по принципам работы гиппокампа, для их развития и применения в решении задач распознавания динамических образов. Для выбора моделей, подлежащих детальному анализу и моделированию, необходимо рассмотреть основные свойства хаотических нейронных сетей и соответствующих моделей гиппокампа.

Хаотические нейронные сети и модели гиппокампа

Как известно, живые организмы реагируют не только на внешнюю среду, но и на паттерны, возникающие в результате внутренней активности системы. При предъ-

явлении стимула, в свою очередь, динамика хаотической сети становится более устойчивой, но все равно сохраняется. При этом отклик сети на знакомый ей стимул и на новый отличается. Таким образом, хаос здесь предстает как интерфейс между внешним миром и внутренней динамикой системы. Обобщая особенности данного подхода, можно выделить следующие преимущества нелинейной динамической интерпретации нейронной активности [3]:

- увеличенная емкость памяти системы;
- способность к выделению нового образа от уже запомненного при наличии внешнего стимула и обучение в реальном времени;
- эффективный поиск в пространстве состояний системы (избегание локальных минимумов энергии системы, отвечающих ложным образам);
- объединение процессов запоминания и воспроизведения информации;
- представление памяти в виде динамического процесса, позволяющего связывать несколько образов в единую цепь.

Интерпретируя данные преимущества в рамках построения технических систем обработки информации, использование хаотических нейронных сетей позволяет наделить систему следующими свойствами:

- автономность (ослабление зависимости от априорной информации);
- адаптация (подстройка под решаемую задачу за счет динамики элементов системы, отличие новой информации от уже известной и обучение в реальном времени);
- комплексное восприятие образов (учет временного и пространственного контекста);
- адекватность сложности системы по сравнению со сложностью решаемой задачи (динамически изменяющиеся внешние стимулы требуют динамического отклика системы, раскрывающего их контекст).

Сложность в использовании хаотических систем связана с необходимостью управления собственной динамикой, а также с определением значений различных параметров моделей.

Примерами наиболее известных хаотических нейронных сетей могут служить

модели обонятельной луковицы Фримана (W.J. Freeman) [4] и хаотической нейронной сети Айхары (K. Aihara) [5].

Отметим, что упомянутые модели хаотических систем позволяют добиться улучшения результата и в задачах распознавания и классификации статических образов. Модель Фримана, например, нашла применение в работах [6, 7]. Сеть Айхары, в свою очередь, продемонстрировала большое количество различных динамических режимов [8] и позволила решить задачу распознавания в условиях неопределенности [9]. Данные модели также используются в задачах навигации роботом в условиях неопределенной внешней среды [10, 11].

Гиппокамп – отдел головного мозга, являющийся частью лимбической системы, который задействован в механизмах памяти и пространственной навигации. На сегодняшний день существуют четыре основные теории о роли гиппокампа в формировании памяти, и окончательное примирение между ними еще не достигнуто [12]. Тем не менее очевидным является то, что гиппокамп играет ключевую роль в кодировании, хранении и воспроизведении воспоминаний. Поиск и анализ моделей гиппокампа был выполнен в соответствии со следующими критериями:

- описание модели на уровне ансамблей (слоев) нейронов без учета физико-химических особенностей отдельных элементов;

- наличие в составе системы нейронов с хаотической динамикой и проявление синхронизации при их взаимодействии;

- применимость модели к задаче кодирования и распознавания динамической информации.

В результате анализа существующих моделей для более детального исследования были выделены три модели:

- хаотической эпизодической памяти Осаны (Y. Osana) [13];

- неокортекса-гиппокампа Куремото (T. Kuremoto) [14];

- гиппокампа Тсуды (I. Tsuda) [15].

В следующих разделах рассматривается каждая из моделей, анализируется и сравнивается на основе результатов проведенного моделирования.

Хаотическая модель эпизодической памяти Осаны

Хаотическая модель эпизодической памяти (CEAM – Chaotic Episodic Associative Memory), предложенная японским ученым Осаной (Y. Osana) и коллегами [13], по структуре напоминает двунаправленную ассоциативную память, но с добавлением хаотических нейронов Айхары [5], которые отвечают за хранение и воспроизведение контекстной информации.

Структура модели Осаны приведена на рис. 1.

Выходы нейронов слоя Y выражаются формулой:




Рис. 1. Структура модели эпизодической памяти Осаны
 ● – хаотический нейрон; ○ – обычный нейрон

$$y_i(t) = f \left(\sum_{j=1}^{N+n} W_{ij} x_j(t) \right). \quad (1)$$

Нейроны входного слоя X описываются уравнениями:

$$z_i(t+1) = \sum_{j=1}^{N+n} W_{ij}^{auto} x_j(t) + k_f z_i(t); \quad (2)$$

$$v_i(t+1) = \sum_{j=1}^N W_{ij}^T y_j(t) + k_e v_i(t); \quad (3)$$

$$\eta_i(t+1) = -\alpha x_i(t) + k_r \eta_i(t) - a_i(t); \quad (4)$$

$$x_i(t+1) = f(\eta_i(t+1) + z_i(t+1) + \gamma v_i(t+1)), \quad (5)$$

где $x_i(t)$ – выход i -го нейрона слоя X в момент времени t ; $y_i(t)$ – выход i -го нейрона слоя Y в момент времени t ; N – число обычных нейронов в каждом слое; n – число хаотических нейронов в слое X ; W_{ij} – сила связи от j -го нейрона слоя X к i -му нейрону слоя Y ; W_{ij}^{auto} – сила связи от j -го к i -му нейрону внутри слоя X ; $a_i(t)$ – параметр для задания внешней стимуляции; α – параметр силы рефрактерности нейронов; k_p , k_e , k_r – параметры затухания связей; γ – коэффициент усиления сигнала между слоями; $f(c) = \frac{2}{1 + e^{-c/\varepsilon}} - 1$ – передаточная функция нейронов с параметром ε .

Хаотические и нехаотические нейроны отличаются значениями параметров k_p , k_r , k_e , α .

В моделировании используются M последовательностей S из m образов каждая: $S_i = \{s^1, \dots, s^k, \dots, s^m\}$, $i = \overline{1, M}$, где $s^k = \{s_1^k, \dots, s_j^k, \dots, s_N^k\}$ – k -й хранимый образ, а $s_j^k \in \{-1, 1\}$, $\forall j, k$ – j -й элемент k -го образа.

Веса W_{ij}^{auto} будут обеспечивать воспроизведение каждого образа (слой X), а веса W_{ij} – восстановление самих последовательностей, т. е. воспроизведение следующего образа в последовательности (слой Y) в соответствии с предыдущим (слой X).

Каждому образу из одной последовательности также соответствует контекстная информация: $c_i = \{c_{N+1}, \dots, c_j, \dots, c_{N+n}\}$, $i = \overline{1, M}$, где $c_j \in \{-1, 1\}$, $\forall j$ – j -й элемент контекста. Эта величина позволяет сети отличать разные последовательности с общими образа-

ми. Ее генерация производится случайным образом независимо для каждой последовательности, а за ее хранение и воспроизведение отвечают веса W_{ij}^{auto} и хаотические нейроны слоя X . В итоге результирующий образ p^k состоит из исходного образа и контекста $p^k = s^k \cdot c^k$, где “ \cdot ” – операция конкатенации.

Обучение (настройка весовых коэффициентов W_{ij}^{auto} и W_{ij}) сети выполняется перед непосредственным моделированием в соответствии с алгоритмом быстрого обучения (quick learning) [16]. Обучение выполняется в два этапа. Сначала производится настройка по правилу Хебба:

$$W_{ij} = \begin{cases} \sum_{k=1}^m p_i^k p_j^k, & i \neq j \\ 0, & i = j \end{cases}. \quad (6)$$

Затем производится корректировка полученных значений в соответствии с правилом

$$\Delta W_{ij} = -\frac{\lambda}{N+1} \left(\sum_{j=1}^N W_{ij} X_j - \xi Y_i \right) X_j,$$

если $\left(\sum_{j=1}^N W_{ij} X_j \right) Y_i \leq 0$ и $\Delta W_{ij} = 0, \forall i, j$ в ином случае, где λ – параметр релаксации, ξ – константа нормализации. Здесь мы обозначили текущий образ p^k за X , а следующий за ним в последовательности p^{k+1} за Y . Аналогично производится настройка весов W_{ij}^{auto} .

Моделирование начинается с инициализации слоя X одним из хранимых сетью образов. Как только сеть воспроизвела следующий в последовательности образ, необходимо произвести инициализацию слоя X в соответствии с получившимся результатом для продолжения распознавания. Момент, когда необходимо это сделать, определяется в соответствии с равенством нулю критерия $J = \sum_{d=1}^D \sum_{i=1}^N (y_i(t) - y_i(t-d))^2$, где D – некая константа.

В результате проведенного моделирования (параметры модели: $N = 100$; $n = 7$; $M = 3$; $m = 4$; $D = 3$; $\lambda = 1,9$; $\xi = 0,1$; $\varepsilon = 0,0015$; $a_i(t) = 0, \forall i, t$; $k_p = 0,1$; $k_e = 0,1$; $k_r = 0,95$; $\alpha = 10$, для нехаотических нейро-

Таблица 1

Статистика воспроизведения последовательностей образов сетью Осаны

Последовательность	1	2	3	Ошибки
Воспроизведение, %	33	50	17	0

нов $k_f = k_e = k_r = \alpha = 0$) были получены результаты по распознаванию динамических образов (последовательностей) для $t = 2500$ итераций, приведенные в табл. 1. Используемые образы представлялись в виде изображений размером 10×10 . Частично динамика сети представлена на рис. 2. Из результатов моделирования видно, что сеть успешно справляется с задачей распознавания динамических образов с разным временным контекстом (сеть по одному общему для всех последовательностей образу восстано-

вила каждую из последовательностей).

Модель неокортекса-гиппокампа Куремото

Модель, предложенная группой японских ученых под руководством Куремото (Т. Kuremoto) [14], учитывает в своем составе не только гиппокамп, но и энториальную кору. Гиппокамп в данном случае выступает в роли временного хранилища информации. Модель основана на работе Ито (М. Ito) [17], по сравнению с которой нейроны области СА3 являются хаотиче-

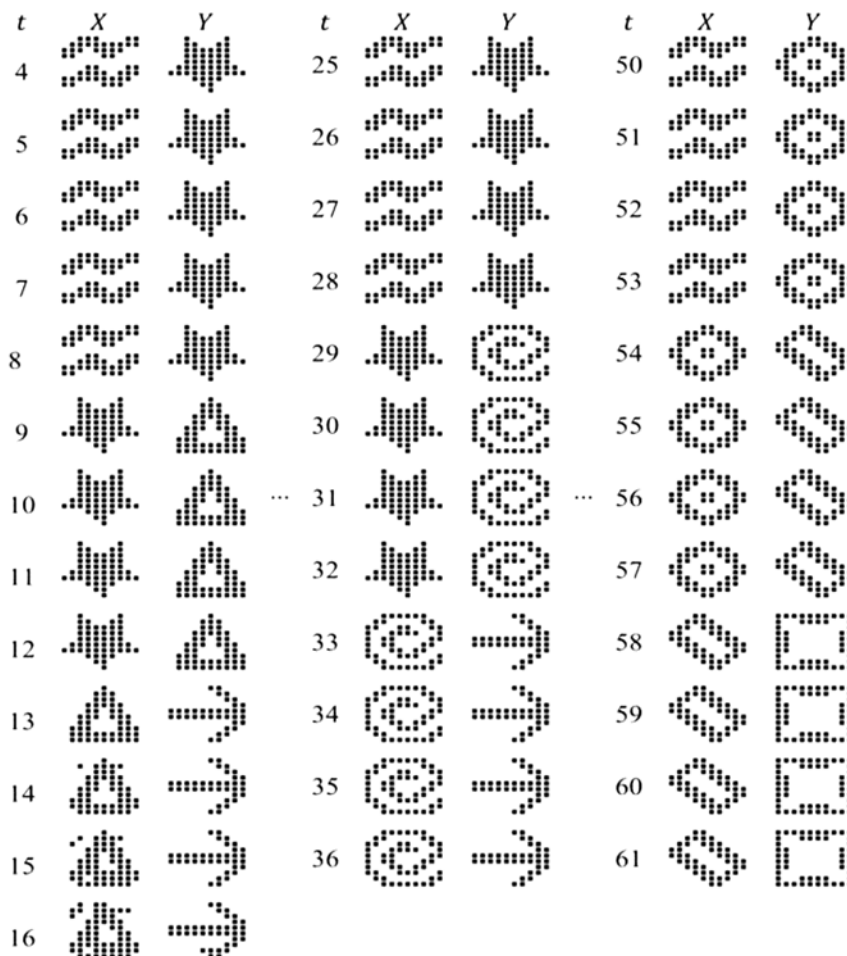


Рис. 2. Воспроизведение сетью Осаны каждой из хранимых последовательностей




Рис. 3. Структура области CA3 модели Куремото

скими нейронами Айхары (в модели Ито область CA3 представлена однослойной сетью Хопфилда).

Подробная структура области CA3 изображена на рис. 3, а структура всей модели

Куремото приведена на рис. 4.

Первый слой энториальной коры необходим для фиксации внешнего стимула, нейроны ЗИ (зубчатая извилина) выполняют кодирование полученной информации, нейроны CA3 – хранение (кратковременная память), CA1 – декодирование. Второй слой энториальной коры является местом хранения долговременной памяти.

Математическое описание модели приведено ниже. Для обозначения выхода i -го нейрона любого из слоев используется обозначение x_i^* (например, $x_i^{cx1}(t)$ – выход i -го нейрона первого слоя энториальной коры в момент времени t). Весовые коэффициенты настраиваются в соответствии с правилом Хебба и обозначаются как ω_{ij}^* (например, $\omega_{ij}^{cx2-cx1}$ – сила связи от j -го нейрона первого слоя к i -му нейрону второго слоя энториальной коры).

Рецепторы входного слоя (Input, сокращенно – I):

$$I_i(t) = \{0, 1\}. \quad (7)$$




Рис. 4. Структура модели неокортекса-гиппокампа Куремото

Нейроны первого слоя энториальной коры (Cortex 1, сокращенно – cx1):

$$x_i^{cx1}(t) = I_i(t). \quad (8)$$

Нейроны второго слоя энториальной коры (Cortex 2, сокращенно – cx2):

$$x_i^{cx2}(t) = g \left(\sum_{j=1}^N \omega_{ij}^{cx2-cx2} x_j^{cx2}(t-1) + \omega^{cx2-cx1} x_i^{cx1}(t) + \omega^{cx2-ca1} x_i^{ca1}(t) - \theta^{cx2} \right), \quad (9)$$

$$\Delta \omega_{ij}^{cx2-cx2} = \alpha_{hc} x_i^{cx2}(t) x_j^{cx2}(t-1), \quad (10)$$

где N – число нейронов в слое; $g(c) = \begin{cases} 1, c \geq 0 \\ 0, c < 0 \end{cases}$ – передаточная функция нейронов; θ^{cx2} – порог срабатывания нейронов; α_{hc} – скорость обучения.

Нейроны зубчатой извилины (Dentate Gurus, сокращенно – dg):

$$x_i^{dg}(0) = random \in \{-1, 1\}, \forall i, \quad (11)$$

$$x_i^{dg}(t) = g \left(\sum_{j=1}^n \omega_{ij}^{dg-cx1} x_j^{cx1}(t) - \theta^{dg} \right), \quad (12)$$

$$\Delta \omega_{ij}^{dg-cx1} = \beta_{hc} x_i^{dg}(t) x_j^{cx1}(t), \quad (13)$$

где n – число нейронов в слое; $g(c) = \begin{cases} 1, c \geq 0 \\ 0, c < 0 \end{cases}$ – передаточная функция нейронов; θ^{dg} – порог срабатывания нейронов; β_{hc} – скорость обучения.

Нейроны области CA3 (каждый из двух входных слоев – CNN1, CNN2):

$$z_i(t+1) = \sum_{j=1}^N \omega_{ij} x_j(t) + k_f z_i(t), \quad (14)$$

$$v_i(t+1) = \sum_{j=1}^N W_{ij} x_j^*(t) + k_e v_i(t), \quad (15)$$

$$y_i(t+1) = -\alpha x_i(t) + k_r y_i(t) - a_i(t), \quad (16)$$

$$x_i(t+1) = f(y_i(t+1) + z_i(t+1) + \gamma v_i(t+1)), \quad (17)$$

$$\Delta \omega_{ij} = \begin{cases} \frac{1}{m} (2x_i - 1)(2x_j - 1), & i \neq j \\ 0, & i = j \end{cases}, \quad (18)$$

$$\Delta W_{ij} = \beta (2x_i - 1)(2x_j^* - 1), \quad (19)$$

где $x_i(t)$ – выход i -го нейрона текущего слоя в момент времени t ; $x_i^*(t)$ – выход i -го нейрона второго слоя в момент времени t ; N – число нейронов в каждом слое; ω_{ij} – сила связи от j -го к i -му нейрону внутри одного слоя; W_{ij} – сила связи от j -го нейрона второго слоя к i -му нейрону текущего слоя; $a_i(t) = a + k \cdot A_i(t)$ – параметр для задания внешней стимуляции $A_i(t)$ с коэффициентами a и k ; $f(c) = \frac{1}{1 + e^{-c/\epsilon}}$ – передаточная функция нейронов с коэффициентом ϵ ; α – параметр силы рефрактерности нейронов; k_f, k_e, k_r – параметры затухания связей; γ – коэффициент усиления сигнала между слоями; β – скорость обучения.

Нейроны области CA3 (выходной слой):

$$x_i^{ca3}(t) = \begin{cases} 1, & i = k \\ 0, & i \neq k \end{cases}, \quad (20)$$

$$k = \arg \max_i \sum_{j=1}^n \omega_{ij}^{ca3-cnn} (2x_j^{cnn}(t) - 1), \quad (21)$$

$$\Delta \omega_{ij}^{ca3-cnn} = \frac{1}{n} x_i^{ca3}(t) x_j^{cnn}(t), \quad (22)$$

где x_i^{cnn} – i -й нейрон одного из входных слоев области CA3 (CNN1 или CNN2); n – число нейронов в слоях области CA3.

Нейроны области CA1:

$$x_i^{ca1}(t) = g \left(\sum_{j=1}^N \omega_{ij}^{ca1-ca3} x_j^{ca3}(t) + \omega^{ca1-cx1} x_i^{cx1}(t) - \theta^{ca1} \right), \quad (23)$$

$$\Delta \omega_{ij}^{ca1-ca3} = \beta_{hc} x_i^{ca1}(t) x_j^{ca3}(t), \quad (24)$$

где N – число нейронов в слое; $g(c) = \begin{cases} 1, c \geq 0 \\ 0, c < 0 \end{cases}$ – передаточная функция нейронов; θ^{ca1} – порог срабатывания нейронов; β_{hc} – скорость обучения.

Область CA3 состоит из двухслойной хаотической нейронной сети (MCNN – Multi-Layered Chaotic Neural Network) и выходного соревновательного слоя. Нейроны каждого из слоев попеременно получают внешний стимул, обучаются и настраивают связи друг с другом. Когда один из слоев получает информацию от ЗИ, его

Таблица 2

**Статистика воспроизведения последовательностей
образов сетью Куремото**

Последовательность	1	2	Ошибки
Воспроизведение, %	26	28	46

динамика является хаотической, в то время как другой слой находится в устойчивом состоянии. Каждый из слоев хранит отдельные образы (в виде ω_{ij}), а воспроизведение целых последовательностей осуществляется через настройку W_{ij} .

Управление хаотической динамикой определяется вычислением критерия $\Delta x = \sum_{i=1}^N |x_i(t+1) - x_i(t)|$ и сравнением его с параметром θ . Если $\Delta x > \theta$, то динамика слоя должна быть хаотической, иначе слой переключается в статический режим. Каждому режиму соответствуют свои значения параметров k_p, k_s, α . При моделировании работы неокортекса-гиппокампа Куремото используются M последовательностей S из m обра-

зов каждая: $S_i = \{s^1, \dots, s^k, \dots, s^m\}, i = \overline{1, M}$, где $s^k = \{s_1^k, \dots, s_j^k, \dots, s_N^k\}$ – k -й хранимый образ, а $s_j^k \in \{-1, 1\}, \forall j, k$ – j -й элемент k -го образа. Обучение сети (настройка всех весовых коэффициентов) производится во время непосредственного моделирования.

Моделирование проводилось в пять этапов (на рис. 4 они обозначены римскими цифрами).

I. Подача двух последовательностей на слой нейронов Cortex 1 и формирование кратковременной памяти в гиппокампе (настройка $\omega_{ij}^{dg:cx1}, \omega_{ij}^{ca3:cm}, \omega_{ij}, W_{ij}, \omega_{ij}^{ca1:ca3}$).

II. Подача первого образа каждой из последовательностей, проверка сформированной кратковременной памяти.

III. Проверка формирования долговре-

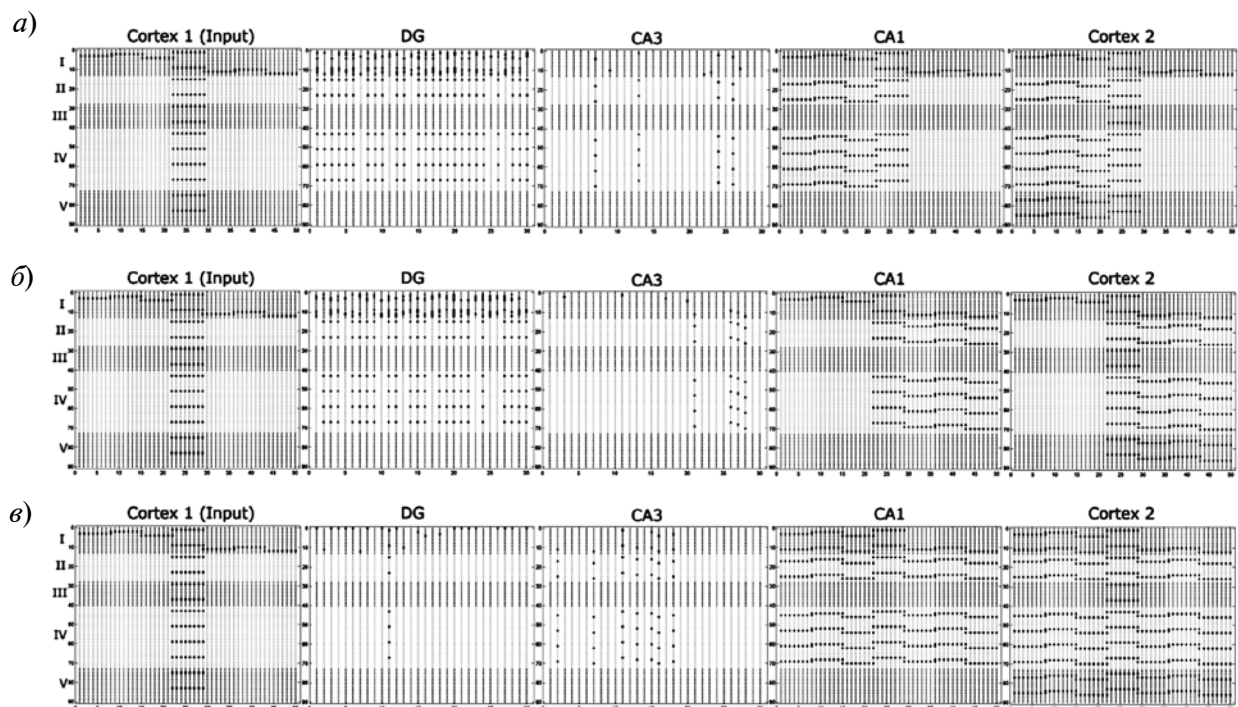


Рис. 5. Динамика сети Куремото в случае воспроизведения каждой из входных последовательностей (а, б); моделирование сети Ито (в).

По оси ординат отложено дискретное время t (сверху вниз), по оси абсцисс – активность каждого нейрона соответствующего слоя

менной памяти во втором слое энториальной коры путем «отключения» гиппокампа от системы.

IV. Многократная подача первого образа последовательностей для формирования в долговременной памяти одной из них (настройка $\omega_{ij}^{cx2 \cdot cx2}$).

V. Повторная проверка формирования долговременной памяти во втором слое энториальной коры.

В результате проведенного моделирования (параметры модели: $N = 50$; $n = 30$; $m = 4$; $M = 2$; $\theta^{dg} = 5,5$; $\theta^{cx2} = \theta^{ca1} = 0,5$; $\beta_{hc} = \beta = 1$; $\alpha_{hc} = 0,012$; $\varepsilon = 0,015$; $\gamma = 30$; $\theta = 5$; $k = 30$; $a = 0$; $\omega^{cx2 \cdot cx1} = \omega^{cx2 \cdot ca1} = \omega^{ca1 \cdot cx1} = 1$; $k_e = 0,2$; $k_f = 0,02$; $k_r = 0,1$; $\alpha = 1$, для нехаотических нейронов $k_f = k_r = \alpha = 0$) были получены результаты по распознаванию динамических образов (последовательностей) для 50 разных начальных инициализаций x^{dg} , приведенные в табл. 2.

Динамика сети Куремото в случае воспроизведения первой и второй из последовательностей представлена на рис. 5 а и б соответственно, а результат моделирования сети Ито для аналогичной задачи представлен на рис. 5 в.

Анализируя результаты, видим, что данная модель позволяет решать поставленную задачу: после подачи входных последовательностей (этап I) формируется промежуточная память (этап II); на данном этапе видим, что в долговременной памяти эти изображения еще не закреплены (этап III); производится повтор образов

для закрепления в долговременной памяти (этап IV); в результате нужная временная последовательность закрепляется в Cortex 2 как долговременная память (этап V).

Из результатов моделирования также видно, что модель Куремото за счет наличия хаотической динамики позволяет решить задачу распознавания последовательностей образов с общими элементами.

Хаотическая модель гиппокампа Тсуды

Модель, предложенная японскими учеными Тсудой (I. Tsuda) и Куродой (S. Kuroda) [15], демонстрирует участие хаотической динамики в кодировании временных последовательностей образов. Ее структура приведена на рис. 6.

Область CA3 в данной модели отвечает за хранение динамических образов (ассоциативная память), ее динамика является хаотической. Область CA1 отвечает за кластеризацию последовательностей образов за счет иерархической самоподобной структуры на основе множества Кантора. Каждый образ в отдельности хранится в CA3, как ассоциативная память, а его «контекст» (в данном случае временной) учитывается в виде особой структуры в пространстве состояний нейронов CA1.

Математическое описание нейронов области CA3:

$$x_i(t+1) = H_x \left(\frac{1}{N} \sum_{j=1}^N \omega_{ij} x_j(t) - d_i y_i(t) \right) \quad (25)$$

с вероятностью p_x ;

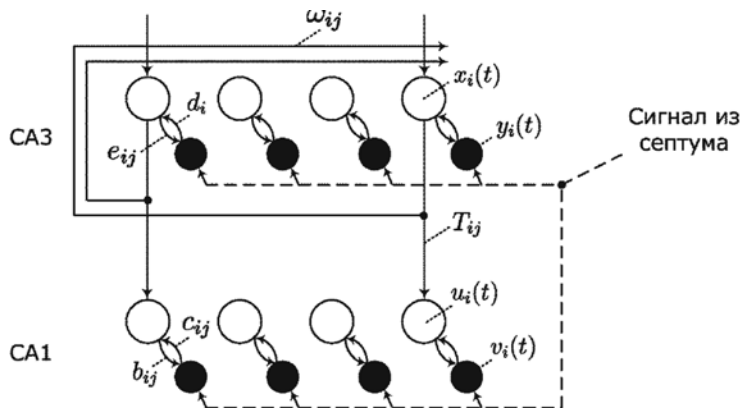


Рис. 6. Структура модели гиппокампа Тсуды
 ○ — возбуждающий нейрон; ● — тормозящий нейрон

$$x_i(t+1) = x_i(t) \quad (26)$$

с вероятностью $1 - p_x$;

$$y_i(t+1) = H_y \left(\frac{1}{N} \sum_{j=1}^N e_{ij} x_j(t) \right) \quad (27)$$

с вероятностью p_y ;

$$y_i(t+1) = 0 \quad (28)$$

с вероятностью $1 - p_y$,

где $x_i(t)$ – выход i -го возбуждающего нейрона САЗ в момент времени t ; $y_i(t)$ – выход i -го тормозящего нейрона САЗ в момент времени t ; N – число нейронов каждого типа в области САЗ; ω_{ij} – сила связи от j -го возбуждающего к i -му возбуждающему нейрону САЗ; e_{ij} – сила связи от j -го возбуждающего к i -му тормозящему нейрону САЗ; d_i – сила связи от i -го тормозящего к i -му возбуждающему нейрону САЗ; $H_x(c) = H_y(c) = \frac{2}{1 + e^{-\lambda_{ca3}c}} - 1$ – передаточная функция нейронов САЗ с коэффициентом λ_{ca3} .

Обучение (настройка весовых коэффициентов ω_{ij}) сети выполняется перед непосредственным моделированием по правилу Хебба:

$$\omega_{ij} = \begin{cases} \frac{1}{m} \sum_{k=1}^m s_i^k s_j^k, & i \neq j \\ 0, & i = j \end{cases}, \quad (29)$$

где $s_j^k \in \{-1, 1\}, \forall j, k$ – j -й элемент k -го образа; m – количество образов, хранимых сетью.

Математическое описание нейронов области СА1:

$$u_i(t+1) = H_u \left(\varepsilon \frac{1}{N} \sum_{j=1}^N T_{ij} \frac{x_j^*(t) + 1}{2} - \delta \sum_{j=1}^n c_{ij} v_j(t) + \theta \right), \quad (30)$$

$$v_i(t) = \sum_{j=1}^n b_{ij} u_j(t), \quad (31)$$

$$x_j^*(t) = \begin{cases} x_j(t), & x_1(t) > 0 \\ -x_j(t), & x_1(t) < 0 \end{cases}, \quad (32)$$

где $u_i(t)$ – выход i -го возбуждающего нейрона СА1 в момент времени t ; $v_i(t)$ – выход

i -го тормозящего нейрона СА1 в момент времени t ; $x_i(t)$ – выход i -го возбуждающего нейрона САЗ в момент времени t ; N – число нейронов каждого типа в области САЗ; n – количество нейронов каждого типа в области СА1; T_{ij} – сила связи от j -го возбуждающего нейрона САЗ к i -му возбуждающему нейрону СА1; c_{ij} – сила связи от j -го тормозящего к i -му возбуждающему нейрону СА1; b_{ij} – сила связи от j -го возбуждающего к i -му тормозящему нейрону СА1; $H_x(c) = H_y(c) = \frac{2}{1 + e^{-\lambda_{ca1}c}} - 1$ – передаточная функция нейронов СА1 с коэффициентом λ_{ca1} .

Динамика нейронов САЗ меняется с хаотической на статическую периодически (через время T). Каждому режиму соответствуют свои значения для параметров d_i, δ, θ . Биологическое обоснование этого эффекта – сигнал от септума (septum effect), воздействующий на тормозящие нейроны СА1 и САЗ.

Было проведено моделирование данной сети (параметры моделирования: $N = 33$; $n = 32$; $\varepsilon = 0,032$; $\delta = 0,8$, для нехаотического режима $\delta = 0,05$; $\lambda_{ca1} = \lambda_{ca3} = 50$; $m = 3$; $\theta = 0,5$, для нехаотического режима $\theta = 0$; $p_x = 0,6$; $p_y = 1$; $T = 2$; $T_{ij} = random \in [0, 1], \forall i, j$; $d_i = random \in [0, 1], \forall i$, для нехаотического режима $d_i = 0, \forall i$; $e_{ij} = random \in [0, 1], \forall i, j$; $b_{ij} = c_{ij} = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases}$) с использованием ортогональных образов.

При отсутствии влияния тормозящих нейронов ($d_i = 0, \forall i$) динамика САЗ является устойчивой, т. е. начальное состояние сети, представленное в виде образа (возможно зашумленного), со временем сходится к одному из устойчивых аттракторов и не выходит из области его притяжения, т. е. реализуется ассоциативная динамика. При $d_i \neq 0, \forall i$ динамика сети является хаотической, но при этом сеть воспроизводит каждый из запомненных образов.

Нейроны области СА1 обеспечивают кодирование временных последовательностей, полученных от нейронов САЗ. В результате такого кодирования в пространстве состояний нейронов СА1 образуется фрактальная структура, что показано на рис. 7.




Рис. 7. Пространство состояний нейронов при моделировании области CA1 модели Теуды

Таким образом, каждой области фазового пространства состояний нейронов CA1 соответствует номер текущего (наблюдаемого на выходе сети в данный момент времени) образа. Количество таких областей соответствует количеству хранимых сетью паттернов. Каждая область, в свою очередь, делится еще на такое же количество кластеров, в соответствии с тем, какой образ был на выходе сети в предшествующий момент времени и т. д.

Результаты анализа и сравнения моделей гиппокампа

Все рассмотренные модели используют динамику хаотических элементов для решения задачи обработки динамической информации, без применения которой эту задачу решить не удастся.

Модель Осаны за счет наличия хаотической динамики позволяет различать пересекающиеся последовательности образов (те, которые имеют общие образы в своем составе), т. е. учитывать временной контекст. По

сравнению с другими моделями эта сеть не является именно моделью гиппокампа, но задача, решаемая с ее помощью, непосредственно относится к его функциям. Также в структурном плане можно прийти к выводу о том, что модель SEAM может являться прототипом области CA3 гиппокампа. Для этой модели обучение сети не ограничивается правилом Хебба, а требуется использовать дополнительные алгоритмы, как видно из результатов анализа модели.

Модель Куремото также позволяет решить задачу распознавания динамических образов с учетом временного контекста. При этом она является наиболее полной в функциональном плане (обеспечивает не только распознавание динамических образов, но и своеобразную «разгрузку» памяти, т. е. перевод необходимой части воспоминаний из кратковременной в долговременную), но при этом обладает относительно сложным описанием и большим количеством параметров. Отметим, что связку из структур DG+CA3+CA1 можно рассматри-



вать и отдельно, ограничиваясь только распознаванием динамических образов.

Сравнение модели Куремото с моделью Осаны показало, что по информационной емкости сеть Осаны более предпочтительна. Также было выполнено моделирование модели SEAM и сети MCNN (из модели Куремото) с целью выявления влияния шума на качество распознавания. Модель MCNN позволяет восстановить последовательность при шуме в 25 %, в то время как сеть SEAM успешно решает задачу при 45 %-ом шуме. Для повышения качества распознавания возможен учет работы других отделов мозга без нарушения целостности системы в целом.

Модель Тсуды демонстрирует свойство самоорганизации, проявляющееся при кодировании образов в пространстве состояний нейронов области CA1. Отметим, что подобное свойство в представлении динамической информации было замечено в реальных нейронах [18]. Динамика слоя CA3 представляет собой не только хранимые образы, но и хаотическую составляющую, поэтому в результате образуются кластеры могут несколько размываться. Этого можно избежать, используя более точную хаотическую нейронную сеть, а также снижая размерность фазового пространства нейронов в области CA1 в процессе визуализации образованных кластеров.

Необходимость использования биологически ориентированных моделей обра-

ботки информации обусловлена стремлением к более универсальной и комплексной обработке, которая свойственна живым организмам. Многие научные группы рассматривают интеллектуальную деятельность мозга с точки зрения одной большой динамической системы, подчеркивая важность общего, комплексного рассмотрения ее активности. Модели, рассмотренные в данной статье, построены по принципам обработки информации в нелинейных динамических системах и могут быть использованы в дальнейшем в технических системах для повышения их универсальности.

В результате подробного анализа моделей сделаны выводы об их особенностях и выполнено их сравнение на основе проведенного всестороннего моделирования. Кроме того, определены направления их модификации и развития: во-первых, путем объединения и расширения принципов, заложенных в их основу; во-вторых, путем интегрирования в рассмотренные структуры других биоинспирированных моделей; в-третьих, путем «искусственной» модификации алгоритмов обучения с целью уменьшения количества необходимой априорной информации и повышения качества распознавания.

Учитывая выявленные особенности, на основе рассмотренных моделей представляется возможным перейти к разработке методов комплексной обработки информации и адаптивных систем, реализующих подобные алгоритмы.

СПИСОК ЛИТЕРАТУРЫ

1. **Benderskaya E.** Nonlinear Trends in Modern Artificial Intelligence: A New Perspective // *Topics in Intelligent Engineering and Informatics*. 2013. Vol. 4. Pp. 113–124.
2. **Tsuda I.** Chaotic itinerancy and its roles in cognitive neurodynamics // *Current Opinion in Neurobiology*. 2015. Vol. 31. Pp. 67–71.
3. **Tsuda I.** Toward an interpretation of dynamic neural activity in terms of chaotic dynamical systems // *Behavioral and Brain Sciences*. 2001. Vol. 24. Pp. 793–810.
4. **Freeman W.** Simulation of chaotic EEG patterns with a dynamic model of the olfactory system // *Biological Cybernetics*. 1987. Vol. 56. Pp. 139–150.
5. **Aihara K., Takabe T., Toyoda M.** Chaotic neural networks // *Physics Letters A*. 1990. Vol. 144. No. 6, 7. Pp. 333–340.
6. **Obayashi M., Koga S., Feng L., Kuremoto T., Kobayashi K.** Handwriting character classification using Freeman's olfactory KIII model // *Artificial Life and Robotics*. 2012. Vol. 17. Pp. 227–232.
7. **Li G., Zhang J., Wang Y., Freeman W.** Face Recognition Using a Neural Network Simulating Olfactory Systems // *LNCS*. 2006. 3972. Pp. 93–97.
8. **Qin K., Oommen B.** Chaotic pattern recognition: The spectrum of properties of the Adachi Neural Network // *Lecture Notes in Computer Science*. 2008. Vol. 5342. Pp. 540–550.

9. **Matykiewicz P.** Chaotic Itinerary for Patterns Separation // *Lecture Notes in Computer Science*. 2004. Vol. 3070. Pp. 235–240.

10. **Voicu H., Kozma R., Wong D., Freeman W.** Spatial navigation model based on chaotic attractor networks // *Connection Science*. 2004. Vol. 16. No. 1. Pp. 1–19.

11. **Obayashi M., Narita K., Okamoto Y., Kuremoto T., Kobayashi K., Feng L.** A Reinforcement Learning System Embedded Agent with Neural Network – Based Adaptive Hierarchical Memory Structure // *Advances in Reinforcement Learning*. 2011. Pp. 189–208.

12. **Игумен Феофан (Крюков).** Роль гиппокампа в долговременной памяти: системно-динамический подход // *Журнал высшей нервной деятельности им. И.П. Павлова*. 2007. Т. 57. № 3. С. 261–278.

13. **Kitada J., Osana Y., Hagiwara M.** Episodic chaotic associative memory // *IEEE Internat. Conf. on Systems, Man and Cybernetics*. 1998. Pp. 3629–3634.

14. **Kuremoto T., Eto T., Kobayashi K., Obayashi M.** A hippocampus-neocortex model for chaotic association // *Trends in Neural Computation (Studies in Computational Intelligence)*. 2007. Vol. 35. Pp. 111–133.

15. **Tsuda I., Kuroda S.** Cantor coding in the hippocampus // *Japan Journal of Industrial and Applied Mathematics*. 2001. Vol. 18. Pp. 249–258.

16. **Hattori M., Hagiwara M., Nakagawa M.** Quick learning for bidirectional associative memory // *IEICE Japan*. 1994. Vol. E77-D. No. 4. Pp. 385–392.

17. **Ito M., Miyake S., Inawashiro S., Kuroiwa J., Sawada Y.** Long-term memory of temporal patterns in a hippocampus-cortex model // *Technical Report of IEICE*. 2000. Vol. 18. Pp. 25–32. (jap)

18. **Fukushima Y., Tsukada M., Tsuda I., Yamaguti Y., Kuroda S.** Coding mechanisms in hippocampal networks for learning and memory // *Advances in Neuro-Information Processing: Lecture Notes in Computer Science*. 2009. Vol. 5506. Pp. 72–79.

REFERENCES

1. **Benderskaya E.** Nonlinear Trends in Modern Artificial Intelligence: A New Perspective, *Topics in Intelligent Engineering and Informatics*, 2013, Vol. 4, Pp. 113–124.

2. **Tsuda I.** Chaotic itinerancy and its roles in cognitive neurodynamics, *Current Opinion in Neurobiology*, 2015, Vol. 31, Pp. 67–71.

3. **Tsuda I.** Toward an interpretation of dynamic neural activity in terms of chaotic dynamical systems, *Behavioral and Brain Sciences*, 2001, Vol. 24, Pp. 793–810.

4. **Freeman W.** Simulation of chaotic EEG patterns with a dynamic model of the olfactory system, *Biological Cybernetics*, 1987, Vol. 56, Pp. 139–150.

5. **Aihara K., Takabe T., Toyoda M.** Chaotic neural networks, *Physics Letters A*, 1990, Vol. 144, No. 6, 7, Pp. 333–340.

6. **Obayashi M., Koga S., Feng L., Kuremoto T., Kobayashi K.** Handwriting character classification using Freeman's olfactory KIII model, *Artificial Life and Robotics*, 2012, Vol. 17, Pp. 227–232.

7. **Li G., Zhang J., Wang Y., Freeman W.** Face Recognition Using a Neural Network Simulating Olfactory Systems, *LNCS*, 2006, 3972, Pp. 93–97.

8. **Qin K., Oommen B.** Chaotic pattern recognition: The spectrum of properties of the Adachi Neural Network, *Lecture Notes in Computer Science*, 2008, Vol. 5342, Pp. 540–550.

9. **Matykiewicz P.** Chaotic Itinerary for Patterns Separation, *Lecture Notes in Computer Science*, 2004, Vol. 3070, Pp. 235–240.

10. **Voicu H., Kozma R., Wong D., Freeman W.** Spatial navigation model based on chaotic attractor networks, *Connection Science*, 2004, Vol. 16, No. 1, Pp. 1–19.

11. **Obayashi M., Narita K., Okamoto Y., Kuremoto T., Kobayashi K., Feng L.** A Reinforcement Learning System Embedded Agent with Neural Network – Based Adaptive Hierarchical Memory Structure, *Advances in Reinforcement Learning*, 2011, Pp. 189–208.

12. **Игумен Феофан (Крюков).** Роль гиппокампа в долговременной памяти: системно-динамический подход [The role of the hippocampus in long-term memory: system dynamic approach], *Zhurnal vysshey nervnoy deyatel'nosti im. I.P. Pavlova [I.P. Pavlov Journal of Higher Nervous Activity]*, 2007, Vol. 57, No. 3, Pp. 261–278. (rus)

13. **Kitada J., Osana Y., Hagiwara M.** Episodic chaotic associative memory, *IEEE International Conference on Systems, Man and Cybernetics*, 1998, Pp. 3629–3634.

14. **Kuremoto T., Eto T., Kobayashi K., Obayashi M.** A hippocampus-neocortex model for chaotic association, *Trends in Neural Computation (Studies in Computational Intelligence)*, 2007, Vol. 35, Pp. 111–133.

15. **Tsuda I., Kuroda S.** Cantor coding in the hippocampus, *Japan Journal of Industrial and Applied Mathematics*, 2001, Vol. 18, Pp. 249–258.

16. **Hattori M., Hagiwara M., Nakagawa M.** Quick learning for bidirectional associative memory, *IEICE Japan*, 1994, Vol. E77-D, No. 4, Pp. 385–392.

17. Ito M., Miyake S., Inawashiro S., Kuroiwa J., Sawada Y. Long-term memory of temporal patterns in a hippocampus-cortex model, *Technical Report of IEICE*, 2000, Vol. 18, Pp. 25–32. (jap)
18. Fukushima Y., Tsukada M., Tsuda I., Yamaguti Y., Kuroda S. Coding mechanisms in hippocampal networks for learning and memory. *Advances in Neuro-Information Processing, Lecture Notes in Computer Science*, 2009, Vol. 5506, Pp. 72–79.
-

БЕНДЕРСКАЯ Елена Николаевна — доцент кафедры компьютерных систем и программных технологий Санкт-Петербургского политехнического университета Петра Великого, кандидат технических наук.

195251, Россия, Санкт-Петербург, ул. Политехническая, д. 29.
E-mail: helen.bend@gmail.com

BENDERSKAYA Elena N. *Peter the Great St. Petersburg Polytechnic University.*

195251, Politekhnikeskaya Str. 29, St. Petersburg, Russia.
E-mail: helen.bend@gmail.com

ПЕРЕШЕИН Артем Олегович — студент кафедры компьютерных систем и программных технологий Санкт-Петербургского политехнического университета Петра Великого.

195251, Россия, Санкт-Петербург, ул. Политехническая, д. 29.
E-mail: pereshein.artem@gmail.com

PERESHEIN Artem O. *Peter the Great St. Petersburg Polytechnic University.*

195251, Politekhnikeskaya Str. 29, St. Petersburg, Russia.
E-mail: pereshein.artem@gmail.com