

И.В. СТЕПАНЯН, А.В. ХОМИЧ  
**СТРУКТУРА И ФУНКЦИИ РЕПЛИКАТИВНОГО  
НЕЙРОПОДОБНОГО МОДУЛЯ**

*Степанян И.В., Хомич А.В. Структура и функции репликативного нейроподобного модуля.*

**Аннотация.** Описывается технология построения нейросетевой системы искусственного интеллекта на стыке декларативного программирования и машинного обучения на основе моделирования кортикальных колонок. Используя доступный материал и сравнительно простые явления, эволюционные механизмы создали сложноорганизованные разумные системы. Из этого следует вывод, что искусственный интеллект также должен основываться на простых, но масштабируемых и биоправдоподобных алгоритмах, в которых стохастическая динамика корковых нейронных модулей позволяет быстро и эффективно находить решения сложных проблем. Цель исследования – алгоритмическая формализация на уровне репликативных нейросетевых комплексов. Базовый модуль искусственного интеллекта представлен как специализация и формализация понятия «китайская комната», введенного Джоном Сёрлом. Приведены результаты экспериментов по прогнозированию бинарных последовательностей. Компьютерная симуляция показала высокую эффективность реализации предложенных алгоритмов, при этом вместо использования для каждой задачи тщательно подобранного и адаптированного отдельного метода с частично эквивалентной переформулировкой задач были применены стандартный единый подход и единые параметры алгоритма. Делается вывод, что результаты экспериментов показывают возможность эффективных прикладных решений на базе предложенной технологии. Представленная технология позволяет создать самообучающиеся и планирующие деятельности системы.

**Ключевые слова:** эволюционное моделирование, декларативное программирование нейронных сетей, китайская комната, репликативный нейроподобный модуль, модель колонки неокортекса.

**1. Введение.** Рассматривается опыт реализации машинного обучения на основе так называемых формальных искусственных нейронных сетей, – по сути, на основе нелинейной аппроксимации с использованием численных методов оптимизации. Не рассматриваются специализированные методы машинного обучения, такие как конкурентное обучение, свёрточные нейронные сети и другие, так как все эти методы направлены на определенные классы задач. По этой же причине они не в достаточной степени биоправдоподобны. Они могут быть полезны для решения определенных практических задач, но они не масштабируемы на необозримое разнообразие задач, которые решают в реальном мире живые организмы. Также не ставится цель превзойти известные специализированные методы в решении частных задач.

Цель работы – показать альтернативное направление исследований в области машинного обучения, ориентированное на решение задач адаптивного управления в естественной постановке и делающее

технологии машинного обучения более универсальной, простой и доступной широкому кругу специалистов. В частности, предпринимается попытка отойти от концепции обучения с учителем в пользу более гибкой концепции обучения с подкреплением. Дополнительно предлагается замена градиентных методов оптимизации, которые связаны с трудностями в области глубокого машинного обучения. Данная концепция позволяет сделать из нейронных сетей интеллектуальных агентов, активно управляющих потоком входных сигналов и собственным обучением. Практическая польза предложенного подхода – возможность создать технологию разработки интеллектуальных приложений. Предлагается шаблонное применение стандартной технологии с хорошо прогнозируемым полезным результатом (концепция мотивированного самообучения вместо прямого программирования).

Обратимся к эволюционно-физиологическим основам моделирования искусственного интеллекта. С одной стороны, предпринимается попытка придерживаться биоподобия по критерию реализуемости биовычислений, а с другой стороны – учитываются математические основы проблемы вычислимости. В итоге появилась концепция, которую можно представить как сеть «китайских комнат» с известным алфавитом языка общения и с системой обратной связи, но неизвестными инструкциями. Утерянные инструкции методом проб и ошибок должен восстановить ученик, запертый внутри комнаты и испытывающий потребность в поставках определенного вида информации. Исследование имеет концептуальный характер и условно использует терминологию из нейробиологии. Например, термин «нейромедиатор» упрощен до символа в некотором алфавите (данный термин понадобился, чтобы показать, что нейроны могут обмениваться разнотипными сигналами, числовое представление которых является частным техническим решением). Однако в данной статье не используется устоявшаяся терминология искусственных нейронных сетей, такая как адаптивный сумматор, функция активации, слой формальных нейронов и другое, так как представленная концепция далека от подобных типовых решений.

Не углубляясь в вопросы эффективной алгоритмической технической реализации, показывается суть концепции, которая заключается в объединении нейронов в сеть репликативных модулей, обладающих относительно простой структурой и собственной памятью и локально обучающихся методом подкрепления. Обучение проходит без явной глобальной координации с другими репликативными модулями. Координация взаимодействия для появления эффекта от объединения репликативных модулей в сеть должна выстраиваться в процессе самоорганизации.

Предлагаемый репликативный модуль функционально эквивалентен машине Тьюринга, и поэтому формально обладает вычислительной полнотой. В дополнение к формализму машины Тьюринга предлагается метод машинного обучения, позволяющий итеративно настроить репликативный модуль для решения различных задач.

**2. Обзор работ по самоорганизующимся нейросетевым алгоритмам и алгоритмическому моделированию комплексов колонок неокортекса.** Неокортекс – область коры, расположенная в верхнем слое головного мозга и отвечающая за высшие когнитивные функции – осознанное мышление, сенсорное восприятие и речь. Каждая колонка кортекса представляет собой группу нейронных клеток, расположенных перпендикулярно поверхности коры. Из литературы известны различные модели неокортекса для исследования динамики и когнитивных свойств соответствующих нейросетевых моделей. Соответствие между структурной и функциональной связностью в кортикальных системах формирует проблему понимания общего функционирования мозга и построения моделей сознания. При этом собственная стохастическая динамика общих корковых нейронных комплексов позволяет им экстренно мобилизовать приближенные решения сложных проблем, где хранимые знания и текущие данные совместно ограничивают поиск возможных решений. Принципы модульной самоорганизации в структурно-функциональном отношении с учетом медиаторики и интервзаимодействий исследованы в [1], где предложена концепция глобальности связей в коре мозжечка и приведено математическое описание (вопросы фазовой синхронизации нейронных сетей с изменяющимися во времени задержками рассмотрены в [2]). В [3] описаны результаты изучения хаотических свойств функционирования нейрона с учетом его автофрактального субсетевого строения.

Мозг обрабатывает информацию через коллективную динамику больших нейронных сетей, при этом интеллект как эволюционно полезное приспособление повышает вероятность выживания. В связи с этим в нейроинформатике используются эволюционно-генетические алгоритмы и коллективы нейронных сетей. В [4] предложен метод организации искусственных нейронных сетей (ИНС) с учителем в виде набора раздельно обучаемых подсетей (блоков), взаимодействующих только при вычислении выходных сигналов ИНС. В [5] предложен алгоритм самообучения дифференциальной эволюции и оператор мутации для оптимизации архитектуры и параметров прямой нейросети; делается вывод, что предложенный подход может быть статистически сильным в решении универсальных задач. В [6] обучали глубокие нейронные сети имитации поведения пирамидальных нейро-

нов (в кортикальных структурах млекопитающих они представляют наиболее многочисленную популяцию возбудительных нейронов), получая пространственно-временные модели активации. В [7] исходили из модели коллективного хаоса в основе сложной динамики, наблюдаемой в сетях коры головного мозга, и вычислили спектр Ляпунова при всевозможных начальных условиях функционирования нейронных сетей для исследования динамики и геометрии соответствующих хаотических аттракторов.

В [8] проведено имитационное моделирование корковой обработки визуальных образов во время решения задач рабочей памяти и предложена архитектура, которая лежит в основе нейронных механизмов, опосредующих конкретные задачи памяти. В [9] представлено усовершенствованное измерение сложности на основе аттрактора для булевых рекуррентных нейронных сетей, которое представляет оценку их вычислительной мощности с точки зрения значимости динамики аттрактора. Следует отметить, что нейронная сеть с обратным распространением может решать сложные задачи нелинейного отображения, однако с увеличением размера выборки время, необходимое для обучения нейронных сетей, увеличивается, а точность классификации уменьшается. Чтобы повысить точность классификации и эффективность времени выполнения алгоритма нейронной сети, в [10] предложили метод параллельного проектирования и реализации для нейронной сети обратного распространения.

Экспериментальные данные нейробиологии предполагают, что значительный объем знаний хранится в мозге в виде распределений вероятностей по сетевым состояниям и траекториям сетевых состояний. В [11] приведена теоретическая основа для этой гипотезы, показывая, что даже очень подробные модели корковых нейронных комплексов с разнообразными нелинейными нейронами и синапсами имеют стационарное распределение состояний сети и траекторий состояний сети, к которым они экспоненциально сходятся при любых начальных условиях. В [12] исследовали процессы изучения языка в модели коры мозга. Сеть состояла из нейроноподобных элементов и имитировала нейроанатомические области в коре. В [13] исследовали использование искусственных нейронных сетей для моделирования взаимосвязи между скоростями запуска одиночных нейронов проприоцептивной области соматосенсорной коры и несколькими типами кинематических переменных, связанных с движением руки. В [14, 15] сравнивали вычислительную эффективность моделей спайковых нейронов Ижикевича и их применимость к крупномасштабным симуляциям кортикальных нейронных сетей для использования в нейроинженерных исследованиях.

В [16] исследовали механизмы модификации рецептивных полей отдельных нейронов в результате синаптической передачи внутри кортикальной сети. Для этого использовали акустический сигнал, который был подан на вход в модель улитки и слуховой периферии. В [17] приведена интересная попытка объяснить функцию коры головного мозга как массива маленьких компьютеров, каждый из которых применяет определенный алгоритм обучения для прогнозирования входов от органов чувств или других частей мозга. При этом на первый план выдвигается роль мозга для обучения законам изменения закономерностей входящих последовательностей. В [18] дана формальная математическая модель разреженных представлений активных дендритов неокортекса. Эти исследования позволяют предположить, что основная единица памяти паттерна в неокортексе инстанцирована небольшими кластерами синапсов, оперируемыми локализованными нелинейными дендритными процессами. Экспериментальное исследование в соматосенсорной коре крыс с фотостимуляцией, приведенное в [19], показывает, что большее количество горизонтальных связей неокортекса способствует развитию устойчивых асинхронных состояний текущей активности и уменьшает шумовые корреляции в стимулированной активности.

Идея поиска паттернов во входящих данных не нова, различные подходы описаны в [20-25]. В то же время большой научный интерес представляют идеи Дж. Хокинса по иерархической темпоральной памяти и кортикальным алгоритмам обучения (иерархическая временная память (hierarchical temporal memory, НТМ)). НТМ – коммерческая разработка, в открытом доступе подробное описание алгоритмов отсутствует. Из доступных материалов понятно, что есть некоторая родственная связь с предлагаемым подходом в плане формирования паттернов в режиме обучения без учителя. Но эти идеи не новы и встречаются уже в ART-модели (адаптивно резонансная теория) [26] и в сетях встречного распространения [27]. Предлагаемый вариант принципиально расходится с НТМ, поскольку в данном подходе отсутствует требование иерархичности структур (в этом же состоит радикальное отличие от свёрточных сетей).

Считается, что при моделировании нейронных систем на уровне бионейрона за деталями функционирования элементарных клеток могут теряться базовые принципы обучения, поэтому моделирование на уровне более крупных модулей может дать больше результатов. И здесь возникает аналогия с колонками неокортекса. Что если «забыть», что колонки неокортекса сделаны из клеток, и попробовать смодели-

ровать их функциональное назначение (как сеть формальных нейронов, как машину Тьюринга, как нормальный алгоритм Маркова и др.)

### **3. Методология эволюционного моделирования интеллекта.**

Рассмотрим модель эволюции интеллекта на различных этапах.

*Этап 1.* Нейронная сеть отсутствует в организме. Клетки эффекторы действуют самостоятельно и прямо в ответ на воздействие. Появляются специализированные клетки-детекторы/индикаторы внутреннего состояния, которые:

- могут по синапсам напрямую передавать сигналы на клетки эффекторы;
- активируются при наступлении определенного состояния (выход за безопасный диапазон параметров).

Сигналы при этом генерируются хаотически. При возникновении опасного состояния организм начинает хаотическое движение, пока его состояние не придет в норму (алгоритм случайного поиска).

*Этап 2.* С развитием возникает проблема затухания сигнала, идущего от клетки-детектора к клеткам-эффекторам. Проблема решается появлением вставочных нейронов – усилителей сигнала. На данном этапе они лишены адаптации. Единственная «интеллектуальность» поведения в том, что они могут только усиливать сигнал выше некоторого порогового уровня, фильтруя таким образом шум.

*Этап 3.* Поведение вставочных нейронов усложняются. Они могут жестко программироваться в процессе развертывания организма по заданной генетической программе и с помощью инициируемых процессов. Возникают нейросетевые комплексы, реализующие безусловные рефлексы (неизменная последовательность действий, стартовая при наступлении некоторых условий). Появляются нейроны-сенсоры, чей сигнал нейтрален и не указывает прямо на опасность или эволюционную полезность. Сенсоры необходимы для активации программ инстинктов при определенных условиях.

*Этап 4.* Некоторые типовые нейросетевые комплексы, аналоги колонок неокортекса, начинают реализовывать функцию специализированного микрокомпьютера со своей перезаписываемой памятью и хранящимся в ней изменяемым алгоритмом функционирования. В отличие от неизменных программ инстинктов функция такого модуля меняется в зависимости от истории прошлого функционирования и изменений состояния организма во времени.

На всех этапах нет глобального архитектора системы, строящей ее по рациональным правилам. Поэтому будем придерживаться эмпирического правила: должна просматриваться возможность естественно-эволюционного получения результата, аналогичного требуемому.

**4. Материалы и методы: репликативный нейронный модуль, ассоциативная память, синапс, эффектор, обучение.** Для взаимодействия с внешним миром нейронная сеть связана с нейронами-сенсорами, эффекторами и индикаторами. Связи осуществляются синапсами. Но есть ограничения на направление связей: разрешена передача сигнала только от индикатора к нейрону. Эффектор принимает сигналы от нейромодулей, но обратного направления сигналов нет. Сенсор также не принимает сигналов от нейронов, но только передает их нейромодулям.

Гипотезы:

1. Нейросеть эффективней анализировать на уровне нейронных комплексов (нейромодулей), а не отдельных нейронов. В этом случае появляется возможность наделять нейромодули функциональностью специализированных миникомпьютеров, не нарушая при этом биологической правдоподобности.

2. Каждый нейромодуль по отдельности обладает слабыми возможностями к адаптации, но способность к адаптации группы нейромодулей экспоненциально зависит от ее размера.

3. Нерегулярность синаптических связей есть необходимое свойство для возможности специализации нейромодулей и всей сети. Это позволяет нейромодулю оставаться относительно простым, не реализуя глобальную оптимизацию, а специализируясь под свою частную функцию, которая определяется структурой своих связей (локальная оптимизация).

Репликативный нейромодуль – это типовой вычислительный узел (рис. 1), одинаковый по своим возможностям (функциональному полю, множеству потенциально реализуемых функций) для всей нейронной сети. На рисунке 1 на входе отображены нейромедиаторы, внутри идет классификация (левый и правый столбцы). Null – признак отсутствия медиатора. Базовый модуль сети хранит и модифицирует два списка правил. Каждое правило с точки зрения целей всей сети интерпретируется как прогноз положительного (Good) или отрицательного (Evil) исхода в ответ на определенное действие модуля при определенном состоянии входов модуля (наблюдаемых переменных). Правило на рисунке 1 записано в формате вход модуля → выход модуля. Прогноз результата применения правила определяется списком, в котором сохранено правило. Все вычислительные узлы соединены синапсами и образуют нейронную сеть (рис. 2). Базовые обучаемые модули моделируют функционал, реализуемый колонками в неокортексе. На рисунке 2 демонстрируется вариант взаимного расположения модулей относительно друг друга и сенсоров (черные точки – базовые обучаемые модули, S – сенсоры, e – эффекторы). Нейромодули управляют производством нейромедиаторов и сами управляются нейромедиаторами.

Задача модуля – адаптивная корректировка правил, позволяющих управлять работой нейронной сети в условиях неполных данных. Хотя модуль осуществляет локальное управление без знания всей системы и всей истории сигналов, взаимодействие сети модулей должно решать глобальные задачи сети. С точки зрения вычислительной полноты представленная сеть эквивалентна клеточному автомату.

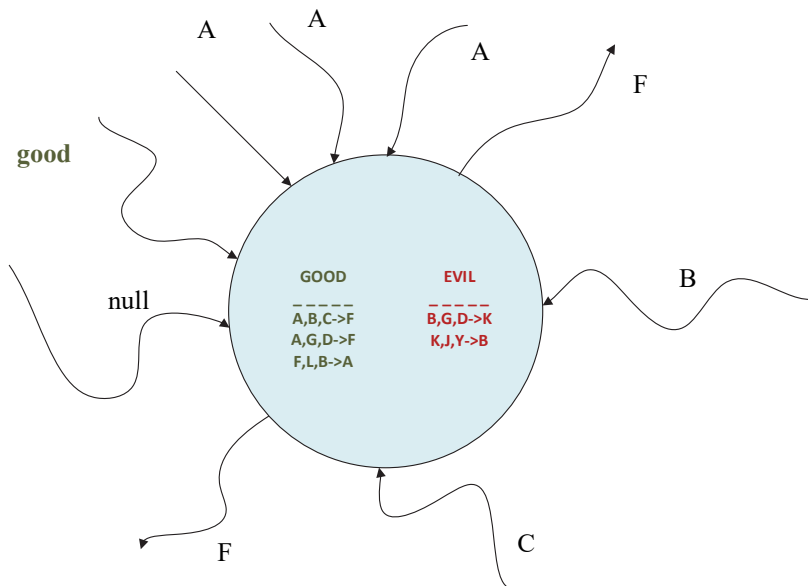


Рис. 1. Иллюстрация работы репликативного модуля

В формальной нейросети нейроны обмениваются числами. В предлагаемом подходе идет обмен нейромедиаторами. Качественный состав нейромедиаторов зависит от заданного алфавита. Само по себе это отличие от формальной нейросети не принципиально, ведь тип нейромедиатора можно кодировать числовым вектором, и наоборот. Формально оба варианта имеют равную вычислительную мощность, однако предлагаемый вариант позволяет явно задать определенный алгоритм обучения нейромодулей, основанный на списке шаблонов функционирования (наподобие программ для машины Тьюринга или инструкций для «китайской комнаты»).

Предлагаются следующие функции и свойства репликативного нейромодуля:

– Соседние нейромодули могут быть соединены синапсами. Нейромодуль вырабатывает нейромедиатор, который может быть пе-



редан далее по синапсам. В каждый момент времени нейромодуль может вырабатывать нейромедиатор только определенного типа. Также нейромодуль может быть неактивным и ничего не производить.

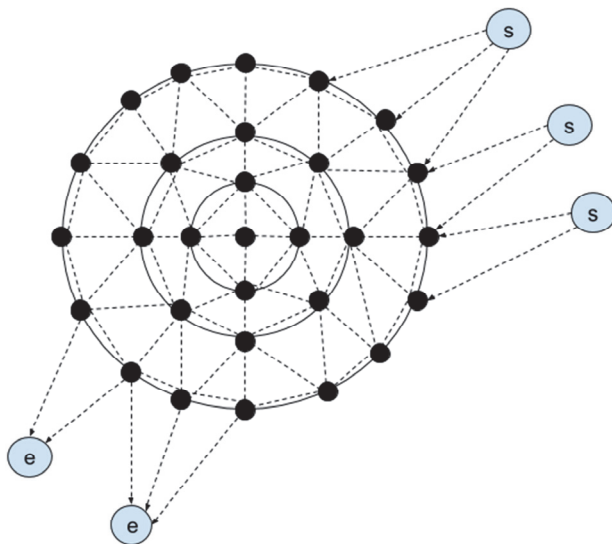


Рис. 2. Схематическое отображение сети, построенной на репликах модуля

Возможные типы нейромедиаторов ограничены списком (алфавитом), формируемым в ходе эволюции организма. Отсутствие нейромедиатора кодируют словом «Null». Предлагается три специальных типа нейромедиатора: Good – нейромедиатор позитивного сигнала (удовольствие); Evil – нейромедиатор негативного сигнала (ущерб); Inhibitor – нейромедиатор, подавляющий производство всех нейромедиаторов. Нейромедиаторы Evil и Good производят только клетки-индикаторы состояния организма (иначе есть риск, что нейроны начнут стимулировать синапсы безусловно производить только один нейромедиатор Good, что не является эволюционно полезным свойством). Клетки-индикаторы распределены равномерно среди клеток нейронов. При компьютерной симуляции не требуется реализовывать индикатор состояния организма как множество отдельных клеток. Достаточно одной клетки, соединенной со всеми нейромодулями. Другие нейромедиаторы могут производиться нейромодулями и клетками-сенсорами.

– Первичным входом репликативного нейромодуля является качественный и количественный состав поступивших по входным синапсам

нейромедиаторов. На первом этапе работы репликативного нейромодуля оригинальный паттерн, точно отражающий тип и количество медиатора в каждом входном синапсе, значительно сокращается до жестко фиксированного паттерна небольшого размера, который отражает только качественную карту медиаторов. Это необходимо, чтобы была возможность обучить репликативный нейромодуль за приемлемое время.

– Репликативный нейромодуль обладает программой производства нейромедиаторов в виде списка шаблонов: качественный состав нейромедиаторов на входе → производимый нейромедиатор. Шаблоны поведения оцениваются по количеству поступающего на вход нейромедиатора Good и Evil. В процессе обучения нейромодуля решается задача подбора шаблонов, максимизирующую показатель Rating:

Rating = количество Good на входе – количество Evil на входе.

– Количество хранимых шаблонов ограничено размером памяти нейромодуля. В случае необходимости запомнить новый шаблон и нехватке на это памяти нейромодуль забывает наименее используемый шаблон. При небольшом алфавите медиаторов и размере входного паттерна появляется возможность хранить в памяти нейромодуля все возможные правила поведения.

**5. Группа методов обучения, построенных на принципе обобщения «китайской комнаты».** В оригинальной модели «китайской комнаты» [28] инструкции уже даны в готовом виде. В данной модификации изначально у обитателя комнаты нет инструкций. Он должен начать со случайной версии инструкции и затем скорректировать ее, анализируя свои действия и обратную связь, причем может делать это разными способами. Второе отличие от оригинала – обитатель комнаты за свои действия получает обратную связь. Иногда он получает поощрение, иногда наказание, иногда ничего не получает.

У комнаты есть конечное множество входов, из которых можно брать медиаторы, и один выход, в который также помещается некоторый медиатор из ограниченного списка допустимых медиаторов. Обратную связь обитатель комнаты получает с неизвестной и непостоянной задержкой. На обратную связь также воздействуют неконтролируемые факторы, меняющиеся со временем. Из-за этого на одни и те же действия в разное время можно получить как положительную, так и отрицательную обратную связь. На конкретную обратную связь в момент времени T может накладываться результат нескольких предыдущих действий и случайные факторы.

У нейромодуля есть два типа памяти: предпамять (Pre-Memory) и основная память (Memory). В основной памяти хранятся рабочие шаб-

лоны поведения, в предпамяти хранится история поведения и его результаты. Будем называть информационным медиатором все медиаторы, кроме Inhibitor, Good и Evil. Медиаторы Good и Evil необходимы для оценки эффективности поведения. Inhibitor – это командный медиатор.

Предпамять хранит информацию об истории функционирования нейромодуля. В ней хранится не более  $N$  последних действий нейромодуля (приказ вырабатывать определенный медиатор) в ответ на определенный качественный состав входных медиаторов. Здесь  $N$  – емкость предпамяти. Запись в предпамять выполняется только в присутствии медиаторов Good или Evil. При нейтральной ситуации запись в предпамять не ведется. История действий нейромодуля в предпамяти сопровождается историей состояния индикаторов. Структура записи предпамяти:

$$\langle \text{Input, Output, Rating} \rangle,$$

где Input отражает структурный и качественный состав информационных медиаторов на входе нейромодуля, каждый элемент Input отражает тип медиатора на определенном входе; Output – произведенный медиатор в ответ на вход; Rating вычисляется в момент начала производства Output. При вычислении Rating никакие задержки влияния и кросс-влияния не учитываются.

Записи в предпамять добавляются только при ненулевом количестве медиатора Good или Evil на входе нейромодуля. В отсутствии сигналов от индикаторов предпамять не заполняется. Когда количество записей в предпамяти достигает максимального возможного значения (предпамять полностью заполнена) выполняется очередной цикл обучения нейромодуля. После чего предпамять полностью очищается.

**6. Память шаблонов поведения.** В памяти нейромодуля хранятся шаблоны поведения – варианты производства медиаторов в выходных синапсах – в ответ на конкретный качественный состав информационных медиаторов на входе нейромодуля. Каждый вариант продукции сопровождается оценкой Rating. Вариант с максимальным значением Rating выбирается в качестве текущего рабочего варианта продукции. Структура записи памяти (шаблон поведения):

$$\langle \text{Input, Output} \rangle; \text{Output} = \{ \langle M_1, R_1 \rangle, \langle M_2, R_2 \rangle, \dots, \langle M_n, R_n \rangle \},$$

где Input – необходимый состав информационных медиаторов на входе нейромодуля для активации правила; Output – список пар <медиатор кандидат для продукции, рейтинг (приоритет) производства медиато-

$ra >$ ;  $M_i$  –  $i$ -й вариант медиатора продукции;  $R_i$  – рейтинг  $i$ -го варианта медиатора продукции.

Обучающие примеры накапливаются либо в ходе пассивного наблюдения, либо в ходе активного планирования экспериментов. Классическое машинное обучение предполагает, что набор обучающих примеров подготовлен заранее. Сама обучаемая машина не влияет на план экспериментов. В отличие от классического машинного обучения, пассивно принимающие обучающие примеры, репликативный нейромодуль одновременно обучается и проводит активный эксперимент.

Input является уникальным ключом шаблона поведения в памяти. В памяти может быть не более одной записи с заданным Input. Для активации шаблона поведения текущий состав входных информационных медиаторов должен точно совпадать с Input. Новый шаблон поведения в памяти возникает, когда для текущего состава медиаторов на входе нейромодуля не находится подходящий шаблон поведения. В этом случае такой шаблон создается со случайными значениями рейтингов в Output. Если доступной памяти недостаточно для сохранения нового шаблона, то из памяти удаляется наиболее редко используемый шаблон поведения.

**7. Алгоритм обучения.** Репликативный нейромодуль обучается когда предпамять полностью заполнена. После обучения предпамять полностью очищается и начинает наполняться снова. Итак, предпамять полностью заполнилась и настало время корректировать рейтинги в шаблонах поведения:

1. По всем записям в предпамяти рассчитываем средний рейтинг. Обозначим его как AvgRating.

2.  $I := 0$ .

3. Для  $I$ -й записи предпамяти Pre-Memory[ $I$ ] находим в памяти шаблон поведения Pattern, для которого Pre-Memory[ $I$ ].Input = Pattern.Input. Если такого нет, то переход на шаг 6.

4. В шаблоне Pattern находим позицию  $K$ , такую что Pattern.Output[ $K$ ].M = Pre-Memory[ $I$ ].Output.

5. Pattern.Output[ $K$ ].R := Pattern.Output[ $K$ ].R \* (1 - F) + AvgRating \* F. Где  $0 < F < 1$  задает скорость обучения.

6.  $I := I + 1$ .

7. Если  $I$  равно количеству записей в предпамяти, то очищаем предпамять и СТОП.

8. Переход на шаг 3.

**8. Эффектор.** Логика обработки эффектором входящих медиаторов может быть различной. Один из простых вариантов следующий. Эффектор имеет только два состояния – активное или пассивное. Эффекто-

ру назначается его активирующий медиатор. Если среди входных медиаторов активирующий медиатор представлен наибольшим количеством, то эффе́ктор активизируется, иначе эффе́ктор остается пассивным.

**9. Нейросетевая структура.** Нейросеть не имеет регулярной структуры. Изначально синапсы и клетки-детекторы/индикаторы состояния организма приблизительно равномерно заполняют некоторый объем, отведенный под нейронную сеть. Например, сенсоры (s) и эффе́кторы (e) располагаются согласно анатомии моделируемого организма или архитектуре робототехнического комплекса.

Репликативные нейромодули и отдельные нейроны связываются с соседними нейронами. Оптимизации структуры связей не выполняется. Требования, чтобы два соседних нейромодуля были обязательно связаны, не предъявляется (регулярность связей не обязательна). Определение «соседнего» нейромодуля жестко не задается. Важно, чтобы не было структуры связи, близкой к типу «каждый-с-каждым». Это необходимо для поддержания разнообразия функций нейромодулей.

**10. Выявленные проблемы и пути их решения.** Выявленная в ходе тестирования проблема – затухание влияния изменения сигнала. Проблема остается в силе и для многослойного персептрона (MLP), обучаемого градиентными алгоритмами [10]. Нейрон может одинаково реагировать на различные входные сигналы. Таким образом, чем больше промежуточных нейронов, тем ниже вероятность того, что изменение выходного сигнала сенсора или первых нейронов повлияет на итоговый входной сигнал эффе́ктора (рис. 3).

Возможны следующие решения:

1. Увеличение количества альтернативных путей прохождения с преобразованием сигнала от сенсора к эффе́ктору.
2. Сокращение длины путей, то есть сокращение количества промежуточных преобразователей сигнала.
3. Дублирование сигналов от сенсоров через простые ретранслирующие узлы и повышение доли прямых связей нейронов с эффе́кторами.

Таким образом, количество промежуточных нейронов должно быть сбалансировано с количеством сенсоров и эффе́кторов. В данной модели видно, что интеллектуальные возможности зависят не только от количества промежуточных нейронов, но и от количества сенсоров и эффе́кторов. На рисунке 3 иллюстрируется проблема, что если нейроны выстроены в длинную цепочку, то вероятность того, что изменения на входе цепочки приведут к изменениям на ее выходе, снижается по мере удлинения цепочки.

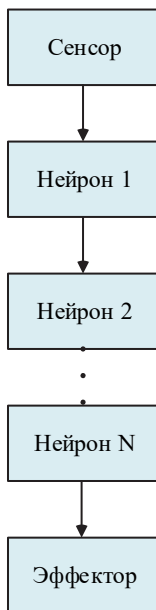


Рис. 3. Цепочка обработки сигнала от сенсора до эффектора

Базовые обучаемые модули моделируют функционал, реализуемый колонками в неокортексе. Обучаются именно «колонки», отдельные же нейроны, из которых состоят «колонки», реализуют неизменяемый алгоритм работы «колонки» и ее память.

Рациональная пространственная структура нейросети – это относительно тонкая плоскость или поверхность сферы, в которой распределены сенсоры, эффекторы и нейроны. Их равномерное распределение предлагается использовать как базовый вариант, когда нет оснований для выбора иного распределения.

**11. Введение эффекта рефрактерности.** Идея заключается в том, чтобы подавлять сигналы нейромодулей с константным (не меняющимся) выходом. Даже если обеспечить достаточное множество альтернативных путей обработки сигнала, все равно большое количество неизменных фоновых сигналов из нейромодулей заглушит полезный сигнал. Но неизменность выхода вне зависимости от входа противоречит назначению нейросистемы, которая должна обеспечивать на каждый вариант входов индивидуальную и полезную реакцию. Проблема не в том, что поведение становится далеким от оптимального, самая большая проблема заключается в остановке обучения нейросистемы.

Введем дендриты. Дендрит – часть репликативного нейромодуля, выполняющая предварительную и жестко запрограммированную обработку входных сигналов. Количество дендритов фиксировано в количестве от 1 до 3, а вот количество синапсов, входящих в дендрит, может достигать на порядок больших значений. Области входов дендритов одного нейромодуля не должны полностью совпадать. В идеале они не должны даже пересекаться. Дендрит из всех входящих медиаторов выбирает представленный наибольшим количеством (принцип, известный в машинном обучении как «победитель забирает все» [29-30]) и передает его в центральную часть нейромодуля, который содержит предпамять и адаптивные правила функционирования. Нейромодуль сверяет паттерн, сформированный дендритами, со списком правил функционирования и формирует на выходе соответствующий нейромедиатор в количестве  $Out[1]$  (рис. 4).

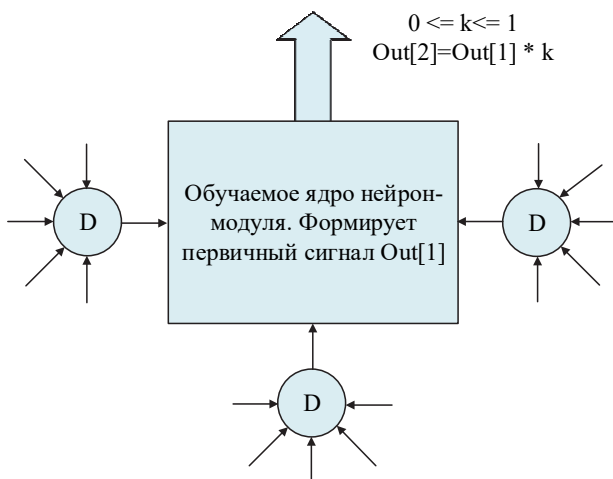


Рис. 4. Репликативный нейромодуль с обучаемым ядром, содержащим предпамять и память шаблонов поведения. На периферии необучаемые дендриты, выполняющие предобработку входных сигналов по фиксированному алгоритму. Количество медиатора на выходе ядра изменяется в зависимости от значения коэффициента усиления

## 12. Введение коэффициента усиления выходного сигнала.

Его значение меняется от 0 до 1. При 0 выходной сигнал полностью подавляется, а при 1 количество выходного медиатора остается стандартным ( $Out[2]=Out[1]*k$ ). Коэффициент уменьшается при каждом случае повторения выходного медиатора, и наоборот, увеличивается при каждом случае изменения типа выходного медиатора.

Таким образом, нейросистема дополнительно разряжается, усиливая только нейроцепочки с функциональным разнообразием. Остальные части нейросистемы временно подавляются, пока они в ходе обучения не придут к функционально разнообразному и полезному состоянию. Нейросистема по количеству нейромоделей становится с чисто вычислительной точки зрения избыточной, но зато обучаемой (аналогично в «естественных» нейросетях в полезном функционировании задействован лишь небольшой процент нейронов).

**13. Эксперименты.** Прогнозирование двоичной последовательности. В данной задаче возможно несколько способов подачи известной части ряда в нейронную сеть: последовательно (динамическая последовательность) или в виде графика (образ). Для тестов был выбран второй вариант. Двоичная последовательность формируется по конечному шаблону. Фиксируется четкий размер шаблона. Каждому биту шаблона случайно назначается 0 и 1, но так, чтобы количество нулей и единиц в шаблоне было одинаково. Это необходимо для максимизации количества информации (по Шеннону) в шаблоне. Двоичная последовательность составляется из повторяющихся блоков шаблона. Например, если шаблон = 01110010, то двоичная последовательность будет следующей 01110010-01110010-□.

Нейронная сеть должна была прогнозировать следующий бит бинарной последовательности по известным значениям ограниченного числа предыдущих бит. Минимальный используемый алфавит медиаторов: Null, Good, Evil, Inhibitor, A, B, C, D. Для построения бинарной последовательности в выполненном тесте использовались шаблоны из 10, 20, 50 и 100 бит. Нейронной сети было, соответственно, доступно 20, 40, 100, 200 значений последних бит последовательности. Каждый бит известной предыстории последовательности был представлен отдельным сенсором. Каждый сенсор кодировал 0 медиатором A, а 1 медиатором B. Изучалось влияние на точность прогнозов после обучения следующих параметров:

- размер шаблона бинарной последовательности;
- размер известной истории бинарной последовательности;
- количество итераций обмена медиаторами между нейронами;
- размер алфавита медиаторов;
- уровень связности нейронов;
- ограничение на количество типов входных медиаторов, определяющих продукцию нейрона.

Ограничение локальности связей нейросети реализовывалось через ограничение числа соседних нейронов. Сами «соседи» подбирались случайно, без использования метрик расстояния. После установки



состояния сенсоров нейроны несколько раз обменивались медиаторами, от 3 до 10 итераций.

Единственный эффектор считывал производимый медиатор всех нейронов нейросети. Медиатор C интерпретировался как -1, медиатор D как +1, остальные как 0. Положительная сумма интерпретировалась как прогноз 1, отрицательная как прогноз 0, нулевая как неопределенный прогноз. В случае совпадения прогноза и факта, индикаторы выделяли медиатор Good. В ином случае, в том числе при неопределенном прогнозе, индикатор выделял медиатор Evil.

Сеть инициировалась один раз перед началом работы. Далее прямо менялись только состояния сенсоров. Нейросеть функционировала и одновременно обучалась на фиксированном количестве примеров. При любых вариантах настройки количество примеров оставалось неизменным.

Второй эксперимент – распознавание 2D-образов из базы MNIST. База данных MNIST (сокращение от «Modified National Institute of Standards and Technology») – объемная база данных образов рукописного написания цифр. База данных является стандартом, предложенным Национальным институтом стандартов и технологий США с целью калибровки и сопоставления методов распознавания изображений с помощью машинного обучения. Данные состоят из заранее подготовленных примеров полутоновых изображений размером 28x28 пикселей. База данных MNIST содержит 60000 изображений для обучения и 10000 изображений для тестирования [31].

**14. Результаты и обсуждение.** Первоначально тестировался вариант нейросети без использования адаптивного коэффициента усиления выхода нейромодуля (без дендритов). Из-за этого и благодаря этому на практике был обнаружен эффект затухания влияния изменения сигнала.

При указанных ограничениях в случае простейших шаблонов в 2 или 4 бита нейросеть училась прогнозировать с точностью 100%. При более сложных шаблонах в 10 и 20 бит нейросеть обучалась прогнозировать бинарную последовательность с точностью от 60% до 90%. При шаблоне в 50 бит точность прогнозирования достигала 60%-70%. При шаблоне в 100 бит точность прогнозирования достигала 60%-68%. При недостаточном количестве нейромодулей или истории бинарной последовательности (сенсоров) нейросеть не показывала значительного прогресса в обучении. Таким образом, увеличение размера шаблона снижало достижимую в ходе обучения точность прогнозирования. Напомним, количество итераций обучения было фиксировано и не зависело от сложности задачи.

Для фиксированного размера шаблона существует оптимальное количество сенсоров и нейромоделей в сети, при котором точность прогнозирования после обучения максимальна. Отклонение от этих значений в любую сторону ведет к снижению точности прогнозирования (растет размер шаблона – растет и оптимальный размер нейросети). При этом важно соблюдение баланса между количеством сенсоров, эффекторов, отзывчивостью среды и количеством анализирующих нейронов.

Снятие ограничений на локальность связей и количество типов медиаторов на входе нейрона приводило к отсутствию прогресса обучения. Таким образом, поддержание разнообразия функциональности критично для обучаемости нейросети.

Увеличение алфавита медиаторов приводило к снижению достигаемой точности прогнозирования. Максимальный эффект был достигнут при кодировании состояния сенсоров двумя медиаторами и кодировании продукции нейромоделей двумя медиаторами. Медиаторы были разделены на производимые сенсорами и производимые нейромоделями.

Вариант нейросети с дендритами при приблизительно тех же затратах вычислительных ресурсов показывал лучшие результаты (результаты модельных экспериментов приведены в таблице 1).

Для второго эксперимента по распознаванию 2D-образов из базы MNIST изображения подвергались предварительному кодированию. Вариации полутонов сводились к 10 уровням, делящим совокупность пикселей изображения на равные части (децили).

Задача связана с распознаванием 2D-образов, поэтому мы ввели привязку нейронов к 3D-координатам и ввели ограничения на локальность связей с расчетом расстояния между нейронами по Евклидовой метрике (L2-норма). Нейроны условно размещались в 3D-кубе  $28 \times 28 \times N$ , где  $N$  варьировалось от 5 до 30. Нейроны располагались послойно, но медиаторы могли распространяться в любом направлении. Слой в данном случае определял набор правил функционирования нейронов. В каждом слое правила функционирования нейронов после цикла обучения приводились к единому набору. Данное ограничение сближало нашу архитектуру с архитектурой свёрточных сетей, в которых одно ядро свертки применяется к различным участкам изображений. В нашем случае вместо ядра свертки к различным участкам соседних слоев сети применялся общий набор правил функционирования.

Таблица 1. Результаты обучения нейросетей прогнозированию бинарной последовательности с фиксированным количеством итераций обучения

Длина бинарной последовательности	Средняя точность прогнозирования после обучения на 1000 случайно сгенерированных примерах (%)	
	Без дендритов	С дендритами
$2 * 10^3$	100	100
$4 * 10^3$	100	100
$10 * 10^3$	87,3	98,3
$20 * 10^3$	75,7	95,2
$50 * 10^3$	65,1	92,7
$100 * 10^3$	64,6	88,3
$150 * 10^3$	61,5	84,1
$200 * 10^3$	57,1	82,6

В отличие от Conv-сетей или MLP-сетей, ограничений по направлению распространения сигналов нет. Сигналы/медиаторы от одного слоя могут передаваться в любой из двух соседних слоев: входные данные сначала поступают в первый слой, затем во второй, из второго слоя сигналы идут в третий и обратно в первый. Из третьего слоя в четвертый и второй и так далее. Это можно изобразить в виде кубической решетки, в узлах которой находятся нейроны.

На каждом уровне решетки все нейроны работают по одному правилу. Нейроны из разных слоев работают по разным правилам.

Слои использовались нами для обработки изображений. Различные участки изображения обрабатываются единообразно. Два соседних пикселя изображения – это не просто две переменные, они имеют связь и пространственную привязку.

Примеры изображений предъявлялись сети однократно. Таким образом моделировалось адаптивное онлайн-обучение.

Достигнутая точность распознавания сопоставима с результатами применения линейного классификатора [32]. Но следует учесть, что результат достигнут за один проход по базе и без дорогостоящего вычисления градиента функции потерь. Результаты эксперимента по распознаванию рукописных цифр из базы MNIST приведены в таблице 2.

Таблица 2. Результаты обучения нейросети распознаванию рукописных цифр из базы MNIST

Количество слоев	Точность прогнозирования после однократного предъявления сети каждого изображения из набора для обучения
5	57%
10	59%
15	73%
20	86%
25	88%
30	93%

Отметим, что демонстрация решения задач служит не для того, чтобы показать, что метод превосходит по результатам другие методы. Цель – продемонстрировать принципиальную жизнеспособность метода на простой задаче. Несомненно, требуются дополнительные исследования и проверка на других задачах, что будет показано в следующих работах.

**15. Заключение.** В последние годы машинное обучение бурно развивается и активно внедряется в практику. Однако преимущественно развивается совершенствование решения задач, относящихся к классу «обучение с учителем» – построение классификаторов по примерам, регрессия, распознавание образов по 2D-изображениям. Решение этих задач в большей степени достигло технологического совершенства.

Однако при решении задач адаптивного управления, в частности встающих перед интеллектуальными агентами в мультиагентных системах, использование классических методов машинного обучения все еще нестандартизировано в выборе архитектуры решений. Задачи адаптивного управления приходится переформулировать в терминах задач обучения с учителем, иногда с потерей качества решения исходной задачи.

Известно, что современные методы машинного обучения, по видимому, имеют мало общего с процессами обучения и управления в биологических организмах. Если понятия «формальный нейрон» и «синапс» еще могут ассоциироваться с естественными нейронными

системами, то метод обратного распространения ошибки не встречает аналогов в естественных системах.

Предпринята попытка обрисовать контуры новой нейросетевой технологии, которая сохраняет относительную простоту типовых вычислительных узлов нейронов, но не требует для обучения расчета и накопления градиента некоторой функции ошибки. Отказавшись от обучения с учителем, выбрали более биоправдоподобное обучение с подкреплением. При разработке технологии за отправную точку был взят мысленный эксперимент «китайская комната».

Эксперименты по компьютерной симуляции показали возможность реализации предложенных алгоритмов и верность направления исследований. С помощью стандартных построений удалось успешно решить ряд тестовых задач. При этом вместо использования для каждой задачи тщательно подобранного и адаптированного отдельного метода с частично эквивалентной переформулировкой задач были применены единый стандартный метод, единые параметры алгоритма и естественная постановка задачи.

Представленные эксперименты служат для целей самой первичной проверки работоспособности высказанных идей. Результаты экспериментов представляются достаточно интересными, чтобы продолжать исследования в выбранном направлении.

Целесообразным шагом видится создание универсального декларативного языка для ввода запросов в репликативную систему. Необходимо начинать решать более сложные и практически важные задачи, которые плохо решаются известными методами машинного обучения. В идеале для апробации технологии нужен роботизированный комплекс, включающий различные сенсоры, манипуляторы и вычислительные блоки. Необходимо в рамках единой технологии научить такого робота примитивному общению и выполнению на первых этапах несложных практических задач.

В перспективе результаты исследований могут привести к созданию методов, эффективно работающих в областях, в которых другие известные методы (нейросетевая регрессия, деревья решений, сверточные сети) могут применяться только ограниченно. Также предполагается, что возможны эффективные приложения новой технологии в области анализа изображений.

### Литература

1. *Савельев А.В.* Критический анализ функциональной роли модульной самоорганизации мозга // *Нейрокомпьютеры: разработка и применение.* 2008. № 5-6. С. 4-17.
2. *Shi Y., Cao J.* Finite-time synchronization of memristive Cohen–Grossberg neural networks with time delays // *Neurocomputing.* 2020. vol. 377. pp. 159–167.

3. *Степанян И.В., Савельев А.В.* Управление хаотическими свойствами нейрона // Нейрокомпьютеры: разработка, применение. 2016. № 6. С. 27–29.
4. *Степанян И.В., Хомич А.В., Карпишук А.В.* Принцип блочности в эволюционной оптимизации структур нейронных сетей // Нейрокомпьютеры: разработка и применение. 2006. № 3. С. 17–25.
5. *Ruizheng J. et al.* A Collective Intelligence Based Differential Evolution Algorithm for Optimizing the Structure and Parameters of a Neural Network // IEEE Access. 2020. vol. 8. pp. 69601–69614.
6. *Beniaquev D., Idan S., London M.* Single Cortical Neurons as Deep Artificial Neural Networks // bioRxiv. 2020. pp. 613141.
7. *Engelken R., Fred W., Abbott L.F.* Lyapunov spectra of chaotic recurrent neural networks //2020. arXiv preprint arXiv:2006.02427.
8. *Liu Q., Ulloa A., Horwitz B.* Using a Large-scale Neural Model of Cortical Object Processing to Investigate the Neural Substrate for Managing Multiple Items in Short-term Memory // J Cogn Neurosci. 2017. vol. 29. no. 11. pp. 1860–1876.
9. *Cabessa J., Villa A.E.P.* An Attractor-Based Complexity Measurement for Boolean Recurrent Neural Networks // PLoS ONE. 2014. vol. 9. no. 4. pp. e94204.
10. *Cao J., Cui H., Shi H., Jiao L.* Big Data: A Parallel Particle Swarm Optimization-Back-Propagation Neural Network Algorithm Based on MapReduce // PLoS ONE. 2016. vol. 11(6). pp. e0157551.
11. *Habenschuss S., Jonke Z., Maass W.* Stochastic Computations in Cortical Microcircuit Models // PLoS Comput Biol. 2013. vol. 9(11). pp. e1003311.
12. *Fry D.B.* The development of the phonological system in the normal and deaf child // The genesis of language. 1966. pp. 187–206.
13. *Lucas A. et al.* Neural Networks for Modeling Neural Spiking in S1 Cortex // Front. Syst. Neurosci. 2019. vol. 13. pp. 13.
14. *Teka W.W., Upadhyay R.K., Mondal A.* Spiking and bursting patterns of fractional-order Izhikevich model // Communications in Nonlinear Science and Numerical Simulation. 2018. vol. 56. pp. 161–176.
15. *Karam E. et al.* Izhikevich Neuron Spike Model in LabVIEW // 2017 ASEE Northeast Section Conference. 2017.
16. *Chambers J.D. et al.* Computational Neural Modeling of Auditory Cortical Receptive Fields // Front Comput Neurosci. 2019. vol. 13. pp. 28.
17. *Mycielski J., Swierczkowski S.* A model of the neocortex // Advances in Applied Mathematics. 1988. vol. 9. no. 4. pp. 465–480.
18. *Ahmad S., Hawkins J.* How do neurons operate on sparse distributed representations? A mathematical theory of sparsity, neurons and active dendrites // 2016. arXiv preprint arXiv:1601.00720.
19. *Schnepel P. et al.* Physiology and Impact of Horizontal Connections in Rat Neocortex // Cerebral Cortex. 2015. vol. 25. no. 10. pp. 3818–3835.
20. *Vaz A.I.F., Vicente L.N.* A particle swarm pattern search method for bound constrained global optimization // Journal of Global Optimization. 2007. vol. 39. no. 2. pp. 197–219.
21. *Momma M., Bennett K.P.* A pattern search method for model selection of support vector regression // Proceedings of the 2002 SIAM International Conference on Data Mining. Society for Industrial and Applied Mathematics. 2002. pp. 261–274.
22. *Audet C., Dennis Jr.J.E.* A pattern search filter method for nonlinear programming without derivatives // SIAM Journal on Optimization. 2004. vol. 14. no. 4. pp. 980–1010.
23. *Zhao Y., Zhou C.C.* System and method for knowledge pattern search from networked agents // US Patent 8903756. 2014.

24. *Torczon V.* On the convergence of pattern search algorithms // *SIAM Journal on optimization*. 1997. vol. 7. no. 1. pp. 1–25.
25. *Kamotsky D., Vargas M.* System and method for performing a pattern matching search // *US Patent 10565188*. 2020.
26. *da Silva L. E.B., Elnabarawy I., Wunsch D.C.* A Survey of Adaptive Resonance Theory Neural Network Models for Engineering Applications // *Neural Networks*. 2019. vol. 120. pp. 167–203.
27. *Hecht-Nielsen R.* Counterpropagation networks // *Applied Optics*. 1987. vol. 26. no. 23. pp. 4979–4984.
28. *Pisano N.A.* Searle’s Chinese Room Reconsidered // *Rerum Causae*. 2019. vol. 10(1).
29. *Chen Y.* Mechanisms of Winner-Take-All and Group Selection in Neuronal Spiking Networks // *Fronts Comput Neurosci*. 2017. vol. 11. pp. 20.
30. *Çağatay H. et al.* A Fair Version of the Chinese Room // *Problemos*. 2019. vol. 96. pp. 121–133.
31. *Kussul E.; Baidyk T.* Improved method of handwritten digit recognition tested on MNIST database // *Image and Vision Computing*. 2004. vol. 22. no. 12. pp. 971–981.
32. *LeCun Y., Bottou L., Bengio Y., Haffner P.* Gradient-Based Learning Applied to Document Recognition // *Proceedings of the IEEE*. 1998. vol. 86. no. 11. pp. 22782324.

**Степанян Иван Викторович** – д-р биол. наук, ведущий научный сотрудник, лаборатория исследования биомеханических систем отдела вибрационной биомеханики, ФГБУН Институт машиноведения им. А.А. Благонравова Российской академии наук (ИМАШ РАН). Область научных интересов: биомеханика, биоматематика, психоакустика, медицина и психофизиология умственного труда, нейросетевые технологии. Число научных публикаций – 150. [neurocomp.pro@gmail.com](mailto:neurocomp.pro@gmail.com); Малый Харитоньевский пер., 4, 101000, Москва, Россия; р.т.: +7(495)628-87-30.

**Хомич Андрей Владимирович** – инженер-программист, АО «Райффайзенбанк». Область научных интересов: нейроинформатика, математическая статистика, теория вероятности, применение методов математического моделирования в экономике. Число научных публикаций – 12. [supremum76@gmail.com](mailto:supremum76@gmail.com); ул. Троицкая, 17/1, 129090, Москва, Россия; р.т.: 111.

I. STEPANYAN, A. HOMICH  
**STRUCTURE AND FUNCTIONS OF A REPLICATIVE NEURO-  
LIKE MODULE**

*Stepanyan I., Homich A. Structure and Functions of a Replicative Neuro-like Module.*

**Abstract.** The given work describes a technology of construction of neural network system of artificial intellect (AI) at a junction of declarative programming and machine training on the basis of modelling of cortical columns. Evolutionary mechanisms, using available material and relatively simple phenomena, have created complex intelligent systems. From this, the authors conclude that AI should also be based on simple but scalable and biofeasible algorithms, in which the stochastic dynamics of cortical neural modules allow to find solutions to of complex problems quickly and efficiently.. Purpose: Algorithmic formalization at the level of replicative neural network complexes - neocortex columns of the brain. Methods: The basic AI module is presented as a specialization and formalization of the concept "Chinese room" introduced by John Earle. The results of experiments on forecasting binary sequences are presented. The computer simulation experiments have shown high efficiency in implementing the proposed algorithms. At the same time, instead of using for each task a carefully selected and adapted separate method with partially equivalent restatement of tasks, the standard unified approach and unified algorithm parameters were used. It is concluded that the results of the experiments show the possibility of effective applied solutions based on the proposed technology. Practical value: the presented technology allows creating self-learning and planning systems.

**Keywords:** Evolutionary Modeling, Declarative Programming of Neural Networks, Chinese Room, Replicative Neural-like Module, Model of Neocortex Columns.

**Stepanyan Ivan** – Ph.D., Dr.Sci., Leading Researcher, Biomechanical Systems Research Laboratory of Department of Vibrational Biomechanics, Mechanical Engineering Research Institute of the Russian Academy of Sciences. Research interests: biomechanics, biomathematics, psychoacoustics, medicine and the psychophysiology of mental labor, neural network technologies. The number of publications – 150. neurocomp.pro@gmail.com; 4, Maly Khari-tonyevskiy per., 101000, Moscow, Russia; office phone: +7(495)628-87-30.

**Khomich Andrey** – Software Engineer, Raiffeisenbank JSC. Research interests: neuroinformatics, mathematical statistics, probability theory, application of mathematical modeling methods in economics. The number of publications – 12. supremum76@gmail.com; 17/1, Troitskaya str., 129090, Moscow, Russia; office phone: 111.

## References

1. Savel'ev A.V. [Critical analysis of the functional role of modular brain self-organization] *Nejrokompyutery: razrabotka i primeneniye – Neurocomputers: development and application*, 2008. vol. 5–6. pp. 4–17. (In Russ.).
2. Shi Y., Cao J. Finite-time synchronization of memristive Cohen–Grossberg neural networks with time delays. *Neurocomputing*. 2020. vol. 377. pp. 159–167.
3. Stepanyan I.V., Savel'ev A.V. [Managing the chaotic properties of a neuron] *Nejrokompyutery: razrabotka, primeneniye – Neurocomputers: development and application*. 2016. vol. 6. pp. 27–29. (In Russ.).
4. Stepanyan I.V., Homich A.V., Karpishuk A.V. [The principle of modularity in evolutionary optimization of neural network structures] *Nejrokompyutery: razrabotka i primeneniye – Neurocomputers: development and application*. 2006. vol. 3. pp. 17–25. (In Russ.).



5. Ruizheng J. et al. A Collective Intelligence Based Differential Evolution Algorithm for Optimizing the Structure and Parameters of a Neural Network. *IEEE Access*. 2020. vol. 8. pp. 69601–69614.
6. Beniaguev D., Idan S., London M. Single Cortical Neurons as Deep Artificial Neural Networks. *bioRxiv*. 2020. pp. 613141.
7. Engelken R., Fred W., Abbott L.F. Lyapunov spectra of chaotic recurrent neural networks. 2020. arXiv preprint arXiv:2006.02427.
8. Liu Q, Ulloa A, Horwitz B. Using a Large-scale Neural Model of Cortical Object Processing to Investigate the Neural Substrate for Managing Multiple Items in Short-term Memory. *J Cogn Neurosci*. 2017. vol. 29. no. 11. pp. 1860–1876.
9. Cabessa J, Villa A.E.P. An Attractor-Based Complexity Measurement for Boolean Recurrent Neural Networks. *PLoS ONE*. 2014. vol. 9. no. 4. pp. e94204.
10. Cao J, Cui H, Shi H, Jiao L. Big Data: A Parallel Particle Swarm Optimization-Back-Propagation Neural Network Algorithm Based on MapReduce. *PLoS ONE*. 2016. vol. 11(6). pp. e0157551.
11. Habenschuss S., Jonke Z., Maass W. Stochastic Computations in Cortical Microcircuit Models. *PLoS Comput Biol*. 2013. vol. 9(11). pp. e1003311.
12. Fry D.B. The development of the phonological system in the normal and deaf child. The genesis of language. 1966. pp. 187–206.
13. Lucas A. et al. Neural Networks for Modeling Neural Spiking in S1 Cortex. *Front. Syst. Neurosci*. 2019. vol. 13. pp. 13.
14. Teka W.W., Upadhyay R.K., Mondal A. Spiking and bursting patterns of fractional-order Izhikevich model. *Communications in Nonlinear Science and Numerical Simulation*. 2018. vol. 56. pp. 161–176.
15. Karam E. et al. Izhikevich Neuron Spike Model in LabVIEW. 2017 ASEE Northeast Section Conference. 2017.
16. Chambers J.D. et al. Computational Neural Modeling of Auditory Cortical Receptive Fields. *Front Comput Neurosci*. 2019. vol. 13. pp. 28.
17. Mycielski J., Swierczkowski S. A model of the neocortex. *Advances in Applied Mathematics*. 1988. vol. 9. no. 4. pp. 465–480.
18. Ahmad S., Hawkins J. How do neurons operate on sparse distributed representations? A mathematical theory of sparsity, neurons and active dendrites. 2016. arXiv preprint arXiv:1601.00720.
19. Schnepel P. et al. Physiology and Impact of Horizontal Connections in Rat Neocortex. *Cerebral Cortex*. 2015. vol. 25. no. 10. pp. 3818–3835.
20. Vaz A.I.F., Vicente L.N. A particle swarm pattern search method for bound constrained global optimization. *Journal of Global Optimization*. 2007. vol. 39. no. 2. pp. 197–219.
21. Momma M., Bennett K.P. A pattern search method for model selection of support vector regression. Proceedings of the 2002 SIAM International Conference on Data Mining. Society for Industrial and Applied Mathematics. 2002. pp. 261–274.
22. Audet C., Dennis Jr.J.E. A pattern search filter method for nonlinear programming without derivatives. *SIAM Journal on Optimization*. 2004. vol. 14. no. 4. pp. 980–1010.
23. Zhao Y., Zhou C.C. System and method for knowledge pattern search from networked agents. US Patent 8903756. 2014.
24. Torczon V. On the convergence of pattern search algorithms. *SIAM Journal on optimization*. 1997. vol. 7. no. 1. pp. 1–25.
25. Kamotsky D., Vargas M. System and method for performing a pattern matching search. US Patent 10565188. 2020.

26. da Silva L. E.B., Elnabarawy I., Wunsch D.C. A Survey of Adaptive Resonance Theory Neural Network Models for Engineering Applications. *Neural Networks*. 2019. vol. 120. pp. 167–203.
27. Hecht-Nielsen R. Counterpropagation networks. *Applied Optics*. 1987. vol. 26. no. 23. pp. 4979–4984.
28. Pisano N.A. Searle’s Chinese Room Reconsidered. *Rerum Causae*. 2019. vol. 10(1).
29. Chen Y. Mechanisms of Winner-Take-All and Group Selection in Neuronal Spiking Networks. *Front Comput Neurosci*. 2017. vol. 11. pp. 20.
30. Çagatay H. et al. A Fair Version of the Chinese Room. *Problemos*. 2019. vol. 96. pp. 121–133.
31. Kussul E.; Baidyk T. Improved method of handwritten digit recognition tested on MNIST database. *Image and Vision Computing*. 2004. vol. 22. no. 12. pp. 971–981.
32. LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*. 1998. vol. 86. no. 11. pp. 22782324.