

УДК 004.8

## НЕЙРОСЕТЕВАЯ АРХИТЕКТУРА ВОПЛОЩЕННОГО ИНТЕЛЛЕКТА

А. Р. Нурутдинов<sup>[0009-0007-0918-0879]</sup>

ПАО "Таттелеком", ул. Ершова, 57, г. Казань, 420061

ayrat.nurutdinov@gmail.com

### **Аннотация**

В последние годы достижения в области искусственного интеллекта (ИИ) и машинного обучения обусловлены успехами в разработке больших языковых моделей (LLM) на основе глубоких нейронных сетей. В то же время, несмотря на существенные возможности, LLM имеет такие принципиальные ограничения, как спонтанная недостоверность в фактах и суждениях; допущение простых ошибок, диссонирующих с высокой компетентностью в целом; легковерие, проявляющееся в готовности принимать за истину заведомо ложные утверждения пользователя; отсутствие сведений о событиях, произошедших после завершения обучения.

Вероятно, ключевой причиной является то, что обучение биологического интеллекта происходит через усвоение неявных знаний воплощенной формой интеллекта, позволяющей решать интерактивные физические задачи реального мира. Биоинспирированные исследования нервных систем организмов позволяют рассматривать мозжечок, координирующий движения и поддерживающий равновесие, в качестве главного кандидата для раскрытия методов реализации воплощенного физического интеллекта. Его простая повторяющаяся структура и способность управлять сложными движениями дают надежду на возможность создания аналога адаптивным нейронным сетям.

В настоящей работе изучается биоинспирированная архитектура мозжечка как форма аналоговых вычислительных сетей, способная моделировать сложные физические системы реального мира. В качестве простого примера представлена реализация воплощенного ИИ в виде многокомпонентной модели щупальца осьминога, демонстрирующей потенциал в создании адаптивных физических систем, обучающихся и взаимодействующих с окружающей средой.

**Ключевые слова:** Искусственные нейронные сети, большие языковые модели, неявное обучение, мозжечок, аналоговые компьютеры, воплощенный интеллект, мягкие роботы, осьминоги.

## 1. ВВЕДЕНИЕ

В последние годы в области искусственного интеллекта (AI) и машинного обучения значительные достижения были получены благодаря развитию больших языковых моделей (LLM), построенных на глубоких нейронных сетях. Исследователи из Microsoft Research пришли к выводам, что ChatGPT-4o можно рассматривать как раннюю версию системы общего искусственного интеллекта (AGI) [1]. В то же время, несмотря на существенные возможности, LLM имеет значимые ограничения [2], такие как: спонтанная недостоверность в фактах и суждениях; допущение простых ошибок, диссонирующих с высокой компетентностью в целом; легковерие, проявляющееся в готовности принимать за истину заведомо ложные утверждения пользователя; отсутствие сведений о событиях, произошедших после завершения обучения. Однако названные часто упоминаемые недостатки не так фундаментальны, как следующие четыре фактора:

**1. Обучение наиболее продвинутых LLM требует чрезвычайно объема вычислительной мощности.** По данным, предоставленным OpenAI, для обучения GPT-3 с параметрами 175B потребовалось 3640 petaFLOP/s-days [3]. Согласно сведениям проекта TOP500 [4], ранжирующего 500 самых мощных нераспределенных компьютерных систем в мире, суперкомпьютер Eagle компании Microsoft, предоставляющей облачную платформу Azure для обучения моделей OpenAI, имеет вычислительную мощность  $R_{max}$ , равную 561,2 petaFlop/s. Таким образом, для разового GPT-3 обучения необходимо шесть дней непрерывной работы Eagle только над этой задачей. Если говорить о модели GPT-4, количество параметров которой не разглашается, но явно на порядок больше, можно предположить, что необходимы месяцы работы третьего по производительности суперкомпьютера в мире. Очевидно, что увеличение параметров еще на порядок потребует годы на создание следующего поколения LLM.

**2. Дальнейшее развитие языковых моделей требует все большего размера очищенных текстовых данных, качественный объем которых ограничен.** Согласно опубликованным данным, для обучения GPT-3 уже использовался

чрезвычайно большой набор данных, основная часть которого была получена из Common Crawl – базы, собравшей за последние 17 лет более 250 млрд страниц. В обучающую выборку также были добавлены известные корпуса высокого качества, включая расширенную версию набора данных WebText, коллекции книг в интернете (Books1 и Books2) и англоязычную «Википедию» (см. Таблица 1).

Таблица 1.

<i>Набор данных</i>	<i>Количество (токены)</i>	<i>Вес в обучении</i>
Common Crawl (фильтрованный)	410 миллиардов	60 %
WebText2	19 миллиардов	22 %
Books1	12 миллиардов	8 %
Books2	55 миллиардов	8 %
Wikipedia	3 миллиарда	3 %
ВСЕГО	499 миллиардов	

С увеличением размеров моделей искусственного интеллекта, таких как GPT-4, возрастает и потребность в большем объеме обучающих данных. При этом остро встает вопрос очистки данных, так как имеющиеся масштабные наборы часто содержат существенную часть избыточной или нерелевантной информации. Кроме того, все больше возникает претензий о нарушении авторских прав. Например, The New York Times предъявила иск, в котором утверждает, что компания OpenAI использовала миллионы статей этой газеты для обучения, что привело к уменьшению числа подписчиков издания [5].

Также следует отметить, что многочисленные исследования подтверждают значительное влияние социальных сетей на процесс обмена информацией [6]. Эти сети играют важнейшую роль в накоплении и хранении знаний, а также в предоставлении возможности находить и получать к ним доступ. Хотя точные цифры не раскрываются, можно предположить, что данные из социальных сетей составляют значимую, но не главную часть обучающей информации для моделей GPT, а основная масса данных по-прежнему вынуждено берется из более традиционных источников, таких как веб-страницы и научные статьи. При этом стоит отметить, что большая часть информации на таких платформах, как

Facebook, Instagram и Telegram, вероятно, носит приватный характер и не может быть получена и использована сторонними лицами для обучения.

Все это приводит к тому, что расширение обучающих данных осуществляется за счет мультимедиа контента, который имеет гораздо более низкую плотность информации, и это явно требует существенного роста как размера моделей, значит, так и затрат на их обучение.

**3. Неспособность к непрерывному обучению на своем опыте.** LLM не адаптирует и не изменяет свое поведение на основе взаимодействия с конкретными пользователями или их данными, то есть генерирует ответы, основываясь исключительно на обучающем наборе данных и внутренних алгоритмах, но не обновляет свои знания или не учитывает новую информацию от пользователей после завершения обучения. Способность к дообучению определяется только размером *контекстного окна (Input Context Window)*, соответствующего количеству токенов, которые модель может рассматривать одновременно при выполнении задачи. Окно является ограничением области входных данных, на которой модель может сосредоточить внимание, чтобы вывести нужные закономерности или сгенерировать ответ. В таблице 2 представлено максимальное количество токенов в запросе, заявленное разработчиками.

Таблица 2.

<b>Модель</b>	<b>Дата выпуска</b>	<b>Контекстное окно</b>
GPT-3.5 Turbo	28.11.2022	4k токенов
GPT-4	14.03.2023	8k токенов
GPT-4o	13.05.2024	128k токенов
Gemini 1.5 Pro	15.02.2024	8k токенов
Claude 3 Haiku	13.03.2024	200k токенов
Llama 3 70B Instruct	18.04.2024	8k токенов

Мы видим стремление разработчиков максимально увеличить размер контекстного окна, однако даже текущие размеры крайне ограничены; для примера, оценочно роман «Война и мир» Л. Толстого содержит около 750k токенов. Кроме того, обучение модели изменяет фундаментальные параметры модели –

вес, а контекстное окно – только входные параметры, на основе которых генерируется ответ, то есть увеличение контекстного окна нельзя рассматривать как полноценную, пусть даже локальную, замену дообучения.

Эти ограничения значительно сужают спектр возможного использования LLM, ограничивая их в основном энциклопедическими знаниями общего характера. В отличие от LLM, традиционные поисковые системы, несмотря на их меньшую структурированность, предоставляют более актуальную информацию о текущих событиях. В результате LLM не могут в большинстве сфер интеллектуальной деятельности конкурировать с человеком, который способен непрерывно обновлять свои знания в реальном времени.

**4. Исходный состав данных для обучения не содержит огромный пласт неявных знаний.** Модели GPT используют архитектуры трансформеров, которые позволяют им эффективно анализировать и обрабатывать тексты, экстрагируют знания. Процесс обучения включает в себя обработку огромного количества текстов, что позволяет этим моделям накапливать знания, по сути схожие с базами знаний в традиционных экспертных системах, ранее основанных на алгоритмах. Одной из ключевых характеристик LLM является их SelfIE (Self-Interpretation of Embeddings) – способность строить внутренние представления и логические связи между различными концепциями [7]. В процессе обучения модели не только запоминают информацию, но и создают внутренние сложные иерархии данных, что позволяет им делать выводы на основе контекста и генерировать осмысленные тексты [8]. Этот процесс аналогичен тому, как экспертные системы используют правила логического вывода для принятия решений. Таким образом, LLM представляют собой своего рода мощные экспертные системы, самонастраивающиеся в процессе обучения, которые не только накапливают знания на основе огромных объемов предоставленных текстовых данных, но и формируют внутренние алгоритмы логических связей между различными концепциями.

Однако использование для обучения предварительно уже сконцентрированных и структурированных знаний, сформированных исходя из представления определенных групп человечества об их значимости, порождает труднопреодолимые проблемы. В частности, неравномерное представление демографических и культурных групп, доминирование определенных языков и идеологий, а

также существующие стереотипы и эмоциональные ассоциации в обучающих данных порождают алгоритмическую предвзятость, приводящую к наследованию и усилению предвзятостей, присутствующих в данных, на которых эти модели обучаются [9].

Гораздо большим ограничением является проблема неявных знаний, то есть знаний, которые люди используют интуитивно и не могут объяснить или формализовать [10]. Такие знания включают интуитивные навыки и опыт, которые сложно передать ИИ. В первую очередь это физические и интерактивные способности к взаимодействию с окружающим миром, то есть те навыки, которые формируются у человека в силу биологических особенностей или в первые годы жизни и плохо или совсем не осознаются им. Это приводит к тому, что LLM не обладают истинным пониманием мира. В результате, несмотря на способность генерировать правдоподобные тексты, модели LLM спонтанно дают нелогичные или бессмысленные ответы, выходящие за пределы их контекстного шаблона.

Безусловно, LLM сейчас активно осваивают существенную нишу в ландшафте интеллектуальных систем – интеллектуальных агентов, способных проявлять высшие когнитивные функции в области языковых способностей, абстрактного мышления и аккумуляции знаний и фактов, накопленных в текстовом виде. Однако они не могут полноценно заменить или воспроизвести эмоциональные, социальные, моторные и метакогнитивные системы, требующие глубокого уровня самосознания, адаптивности, межличностного взаимодействия и базирующиеся на глубоко персонализированной информации. Еще большей сложностью сталкиваются попытки использования LLM для создания кибернетических интеллектуальных систем реального физического мира, изначально максимально соответствующих нервным системам организмов, решающих базовые задачи адаптации и выживания и способных к непрерывному естественному обучению. Нахождению возможных путей решения этой задачи посвящена настоящая статья.

## 2. НЕЯВНЫЕ ЗНАНИЯ И ФОРМЫ ПРОЯВЛЕНИЯ ИНТЕЛЛЕКТА

Современные исследования утверждают, что неявное обучение является фундаментальным и непрерывным процессом в ходе познания человеком окружающего мира [11]. Понятие «*обучение без осознания*» имеет решающее значение для автономных интеллектуальных систем широкого назначения, поскольку неотъемлемым их качеством является непрерывное пожизненное обучение, через которое происходит постоянная адаптация по изучению и изменению окружающей среды.

Примерами неявного обучения являются способность ездить на велосипеде, управлять автомобилем, плавать, ходить, кататься на коньках и лыжах. Каждое из этих умений хранится как неявная процедурная память, которая может быть вызвана без сознательного усилия.

Одно из главных различий между явной и неявной памятью заключается в том, что в *неявной памяти хранятся неосознаваемые воспоминания о навыках и умениях. В явной памяти хранятся факты и события, которые можно вспомнить с помощью сознательного усилия.* То есть память – это не единая система с сознанием, а несколько систем, имеющих разные принципы работы [12]:

*Эксплицитная память* – декларативная память, содержащая воспоминания о фактах, событиях и информационных материалах.

*Имплицитная память* – обучение навыкам и формирование привычек. В имплицитной памяти опыт изменяет поведение без какого-либо осознанного содержания или переживания того, что память используется. Имплицитная память измеряется через результаты деятельности. Она не является воспоминанием, но оказывает существенное влияние на черты личности или даже создает их.

Эти две системы работают параллельно друг с другом. Ниже приведена таблица, характеризующая оба вида памяти.

Таблица 3.

<b>Фактор</b>	<b>Явная (эксплицитная) память</b>	<b>Неявная (имплицитная) память</b>
<b>Процесс в памяти</b>	Сознательная, целенаправленная	Неосознанная, автоматическая
<b>Структура памяти</b>	Гиппокамп и височная доля	Неокортекс, мозжечок и др.
<b>Вид информации</b>	Факты, вербальные, семантические, операционные и процедурные описания	Эмоциональные, условные, сенсорные, автоматические и процедурные навыки

Наиболее тесно неявные знания связаны с важнейшей когнитивной функцией – *праксисом*, способностью выполнять целенаправленные движения и действия, которые требуют координации и последовательности. Этот термин охватывает широкий спектр моторных навыков, начиная от базовых действий, таких как одевание и чистка зубов, до сложных профессиональных и бытовых умений, таких как вождение автомобиля или приготовление пищи. Нарушение этой способности вызывает апраксию – неврологическое состояние, при котором пациент теряет способность выполнять знакомые движения или решать задачи, несмотря на сохранение желаний и физических возможностей для этого. К часто описываемым типам апраксии относят идеомоторную, концептуальную, конечностно-кинетическую и орофациальную [13]. С учетом акцента настоящих исследований на ограничениях больших языковых моделей следует подчеркнуть, что апраксия может возникать и при отсутствии каких-либо языковых нарушений, несмотря на близость областей в коре головного мозга, вовлеченных в праксис и обработку языка [14], что доказывает важность изучения интеллекта, ответственного за физическое взаимодействие.

Таким образом, интеллект представляет собой совокупность разнообразных способностей и навыков, которые могут быть весьма разнородными по своей природе и использовать различные механизмы реализации. Исторические и современные определения интеллекта включают в себя как общие способности к логическому рассуждению, абстрактному мышлению и адаптации к

новым условиям, так и конкретные навыки, такие как память, числовое понимание и пространственная визуализация. В интеллектуальном ландшафте каждый из этих навыков играет свою уникальную роль, формируя комплексную картину человеческого интеллекта.

Н. Gardner [15] в попытке охватить основные формы интеллекта предложил концепцию множественности его категорий. Анализ классификации различных форм позволил выделить наиболее обсуждаемые категории: IQ (intelligence quotient), EQ (emotional quotient) и PI (physical intelligence). IQ относится к классическому логическому мышлению и эрудиции, EQ отражает эмоциональное понимание, эмпатию, способность взаимодействовать с другими людьми, а PI определяет способность тела к физическому взаимодействию с реальным миром, включая управление частями тела и органами, а также адаптацию к окружающей среде. Следует отметить, что в отношении последней формы интеллекта существует множество направлений исследований и интерпретаций [16], таких как физический интеллект (physical quotient – PQ), воплощенный интеллект (embodied intelligence – EI), воплощенное познание (embodied cognition – EC) и телесно-кинестетический интеллект. Перечисленные направления скорее дополняют, чем конкурируют друг с другом, но общим для них является развитие концепции о ключевой роли физической активности, моторных навыках и сенсорном восприятии в нашем мышлении и обучении. Далее будет использован весь их спектр в зависимости от контекста.

В контексте существующего ИИ большие языковые модели демонстрируют значительные успехи в областях, связанных с IQ, предлагая правильные ответы на основе анализа огромных объемов текстовой и визуальной информации. Однако они сталкиваются с ограничениями при решении задач, требующих глубокого эмоционального понимания человека (EQ), и еще большие проблемы возникают в части непосредственного физического взаимодействия с реальным миром (PI). Прогресс в области робототехники привел к широкому использованию роботов в промышленности, но ввиду низкого уровня PI они все еще далеки от универсальности, автономии и адаптивности, сопоставимой даже с возможностями простейших организмов.

С экономической точки зрения анализ соответствия форм интеллекта и существующих для них рынков труда констатирует, что виды деятельности, связанные с IQ в чистом виде, занимают только 6–7 % рынка, доля физического воплощенного интеллекта (PI) среди востребованных профессий – более 33 % и свыше 60 % – в сочетании с EQ [17]. Большая часть рынка труда требует непосредственного антропоморфного взаимодействия с окружающими физическими объектами в реальном времени, что соответствует биологическим нервным системам, сформировавшимся в процессе эволюции путем непосредственного контакта с реальным миром. В то же время существующие реализации ИИ создаются на основе огромных объемов опосредованной информации, представленной в языковой форме, и предполагают диалоговую форму взаимодействия, преимущественно через текстовые или преобразованные в текст голосовые сообщения.

Следует отметить, что данную ситуацию прекрасно осознает и крупнейший производитель решений ИИ: «*The next wave of AI is **physical AI**. AI that understands the laws of physics. AI that can work among us*» («Следующая волна ИИ – это физический ИИ. ИИ, понимающий законы физики. ИИ, который может работать среди нас»), – спрогнозировал CEO Nvidia Дженсен Хуанг [18]. Исследователи отмечают, что происходит новый сдвиг парадигмы от эпохи «интернет-ИИ» к «воплощенному ИИ». В предыдущей парадигме алгоритмы и агенты ИИ обучались на наборах данных, состоящих из изображений или текста, которые в основном были получены из интернета. Этот подход, хотя и позволил достичь значительных успехов в области машинного обучения и компьютерного зрения, имел свои ограничения, связанные с контекстуальностью и применимостью знаний в реальных условиях. В новой парадигме PI-акцент смещается на обучение через непосредственное взаимодействие с окружающей средой, в том числе в симуляторах. Это взаимодействие осуществляется посредством эгоцентрического восприятия, которое напоминает человеческое восприятие мира. Воплощенные агенты ИИ могут двигаться, чувствовать и реагировать на стимулы в окружающей среде, что позволяет им лучше понимать контекст и применять полученные знания на практике [19].

*Воплощенное познание* – это концепция, предполагающая глубокую зависимость интеллекта от особенностей физического агента, то есть, когда аспекты

тела за пределами центрального мозга играют значительную причинную или физически конститутивную роли в когнитивной обработке [20]. *Воплощенный интеллект* – это подход к разработке и пониманию разумного поведения агентов через учет жесткой связи между ними и их окружением (*situatedness*), ограничениями собственного физического тела, перцептивной и моторной системы и мозга агента (*embodiment*). Возникновение области воплощенного интеллекта тесно связано с параллельным развитием вычислительной информатики и робототехники, где основное внимание уделяется морфологическим вычислениям и сенсорно-моторной координации в моделях эволюционной робототехники, а также нейро- и когнитивных наук [21].

Существующая и доминирующая парадигма «интернет-ИИ» привела к формированию соответствующих архитектур нейронных сетей, эффективно решающих задачи классификации, генерации текста и визуализации информации. Однако эпоха «воплощенного ИИ» требует глубокого пересмотра используемых архитектур нейронных сетей, в том числе с использованием биоинспирированного подхода. Этот подход предполагает создание архитектурных аналогов биологических сетей, которые являются результатом полумиллиарда лет эволюции, способны адаптироваться и обучаться в реальном времени через взаимодействие с физическим миром. Кроме того, учитывая эволюционную природу биологического воплощенного интеллекта, важнейшей и, вероятно, ключевой стадией формирования его искусственного аналога является обучение агента воплощенного интеллекта, которое предполагает по аналогии с живыми организмами три следующих этапа.

*Генетический эволюционный отбор* – формирование физического тела агента, приобретающего на этом этапе наиболее оптимальную форму, сегментацию с устойчивыми параметрами. Процесс аналогичен естественному отбору в природе.

*Первичное обучение в среде* – начальное обучение агента в среде, подобное тому, как это происходит с животными в их первые годы жизни. В его ходе формируются параметры, соответствующие как специфике среды, так и особенностям конкретного экземпляра, что позволяет агенту адаптироваться к окружающей среде и приобрести базовые навыки, необходимые для выживания и функционирования.

*Отладка непрерывного обучения* – тестирование и настройка процесса непрерывного обучения и адаптации агента к изменяющимся условиям среды.

Для моделирования всех названных этапов необходимы симуляторы среды и конкуренции, которые позволяют существенно ускорить соответствующие процессы и минимизировать материальные затраты, фактически являясь генераторами неявных знаний.

### **3. МОЗЖЕЧОК КАК РЕЗУЛЬТАТ НЕЙРОСЕТЕВОЙ ЭВОЛЮЦИИ**

Эволюция многоклеточных организмов началась, когда некоторые клетки утратили свою индивидуальность, став частями крупных систем. Это привело к появлению различных биологических ветвей (царств) – растений, грибов и животных. У животных развилась нервная система, позволившая быстро и целенаправленно взаимодействовать между клетками, улучшая координацию и управление движениями через специализированные клетки – нейроны [22].

Исторически происхождение нервных систем обсуждается в свете двух концептуально различных моделей – «ввод–вывод» (*input–output model: IO*) и «внутренняя координация» (*internal coordination model: IC*). Эти модели определяют две разные функции нервной системы как устройства управления. Согласно модели *IO*, основная роль нервной системы заключается в *получении сенсорной информации и ее обработке для обеспечения необходимой двигательной реакции*. Модель *IC* основана на концепции о центральной роли ранних нервных систем в *стимулировании и координации внутренней активности крупных многоклеточных организаций* (рисунки 1).

Отличие между моделями на абстрактном уровне заключается в двух принципиально различных видах координации. Системы, основанные на *IO*, обеспечивают согласованность действия организма с окружающей средой, то есть координацию между действием и состояниями, где действие является выбором самого организма, а целью – приведение внутренних параметров к требуемым величинам, исходя из внешних факторов. Целью системы, основанной на *IC*, *напротив*, является координация различных аспектов того, что делает сам организм. В этом случае он приводит микродействия частей системы к требуемым параметрам, необходимым для макродействия в целом, но с учетом состояния внешней среды.

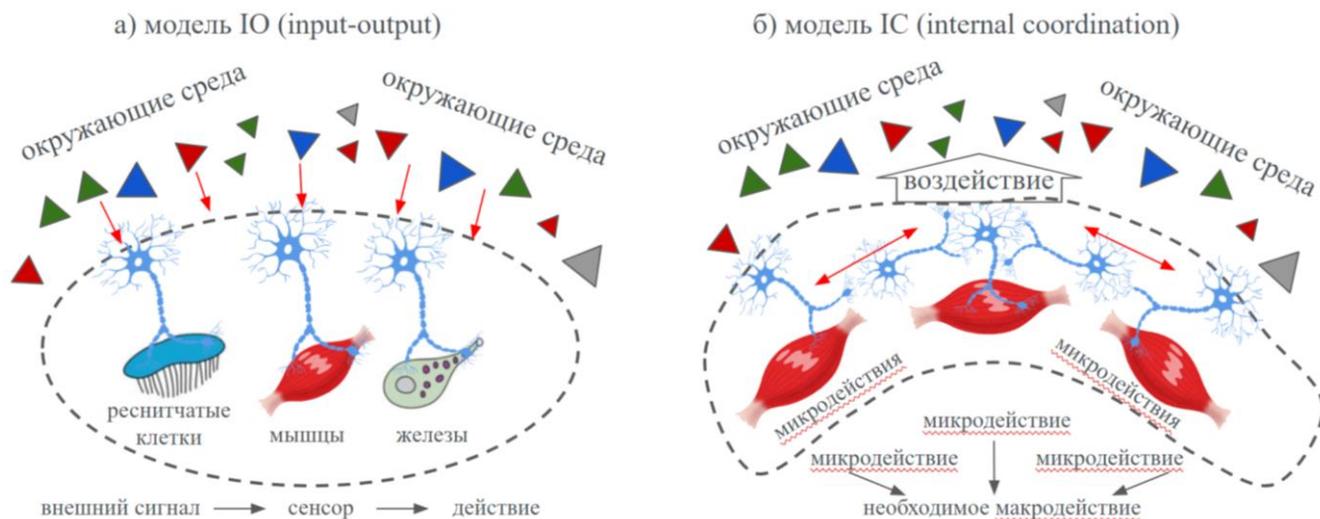


Рис. 1. Две концептуальные модели нервных систем: а) модель ввода–вывода; б) модель внутренней координации

Таким образом, в то время как модель *IO* предполагает эффекторную систему и определяет ее алгоритмическую реакцию, модель *IC* подчеркивает эволюционный сдвиг, связанный с созданием новых многоклеточных эффекторов. В частности, важным эволюционным достижением стала способность использования организмами большого количества сократительных тканей (мышц) – до 700 у позвоночных и до 1500 – у насекомых. При этом общая масса мышц существенно больше, чем масса других органов, и может достигать более половины веса тела. В то же время организация скоординированного сократительного движения сотнями мышц – очень сложная задача, которую не следует воспринимать как нечто само собой разумеющееся, что иногда случается при обсуждении концепции *IO*.

За прошедшие пятьсот миллионов лет эволюции от первых децентрализованных нейронных сетей, появившихся у кишечнополостных и гребневиков, до центральной нервной системы человека нервные системы претерпели множество трансформаций, результатом которых стало возникновение специализированных отделов головного мозга животных, позволяющих осуществлять управление сложными системами. Поставленная задача по определению архитектуры, способной решать задачи внутренней координации с помощью биоинспирированного подхода, может быть выполнена через нахождение и исследование отделов

нервной системы, присущих большинству животных, отвечающих за координацию движения частей тела и их регулярных структур, анализ которых позволит понять принципы построения и масштабирования.

В ходе изучения и перебора различных областей нервных систем биологических организмов можно предположить, что наиболее подходящим органом для первичной реализации выбранного подхода является мозжечок. Он традиционно рассматривается как полнофункциональный орган, осуществляющий контроль и координацию движений, поддержание позы, равновесия и мышечного тонуса. Имеются данные, показывающие участие мозжечка в реализации широкого спектра моторных функций, таких как обучение, планирование, временное согласование. При опухолях мозжечка у 95,5 % больных выявляются статокINETические нарушения [23]. При этом повреждения мозжечка не приводят к полной утрате способности двигаться, но вызывают нарушенную координированность движений, что, в частности, проявляется в виде тремора, которые напоминают колебания неисправной системы управления.

Особенностью мозжечка является удивительно правильная и простая клеточная организация, которая повторяется во всей его коре [24]. Его топография позволяет предположить, что он функционально неоднороден, а его повторяющиеся модули (microcomplexes) обрабатывают различную информацию, зависящую от местоположения корковых входных сигналов. Ito M предположил, что вклад мозжечка в когнитивные функции аналогичен его роли в контроле движения. Согласно этой теории, мозжечок формирует внутреннюю модель взаимодействия посредством повторяющихся действий и обратной связи, что в случае знакомых сценариев позволяет мозжечку эффективно выполнять скоординированные движения, обратная связь которых имеет существенную задержку [25]. Предполагается, что аналогичные процессы происходят в широком спектре умственных операций.

Эти особенности свидетельствуют о возможности существования простой, но чрезвычайно универсальной и эффективной архитектуры нейронных сетей, позволяющей формировать сложные физические модели как частей тела самого организма, так и объектов внешнего мира.

#### 4. НЕЙРОАРХИТЕКТУРА И ОБЩЕПРИНЯТЫЕ МОДЕЛИ МОЗЖЕЧКА

Цитоархитектура мозжечка состоит из трех слоев. Под ними находится белое вещество, содержащее миелинизированные нервные волокна (рисунок 2).



Рис. 2. Слои коры мозжечка и белое вещество под ними

Кора мозжечка состоит из следующих слоев:

– *молекулярного*, являющегося внешним, содержащим огромное количество параллельных волокон и уплощенные *дендритные деревья* клеток Пуркинье и Гольджи. Также здесь находятся два типа ингибирующих интернейронов: звездчатые клетки и корзинчатые клетки;

– *слоя Пуркинье*, представляющего собой узкую зону, содержащую тела клеток Пуркинье, которые являются одними из самых крупных нейронов мозга. Дендритные деревья клеток Пуркинье сильно уплощены, что позволяет им пересекаться с параллельными волокнами;

– *зернистого* – нижнего слоя, содержащего зернистые клетки, являющиеся самыми многочисленными нейронами мозга. Зернистые клетки получают возбуждающие входы от моховидных волокон и передают их через параллельные волокна к клеткам Пуркинье. В этом слое находятся интернейроны, такие как клетки Гольджи, которые модулируют активность зернистых клеток.

*Белое вещество мозжечка* расположено под корой и состоит преимущественно из миелинизированных нервных волокон, которые обеспечивают связь между корой мозжечка и другими частями центральной нервной системы.

В коре мозжечка выделяют шесть классических типов нейронов, более 99 % из них – это клетки видов, приведенных в таблице 4 [26].

Таблица 4.

	<i>Granule cells</i> гранулярные клетки	<i>Golgi cells</i> клетки Гольджи	<i>Purkinje cells</i> клетки Пуркинье	<i>Stellate cells</i> звездчатые клетки
Человек	$1.01 \cdot 10^{11}$	$8.1 \cdot 10^7$	$3 \cdot 10^7$	$1.6 \cdot 10^9$
Кошка	$2 \cdot 10^9$	$10^6$	$10^6$	$3 \cdot 10^7$
Крыса	$2.65 \cdot 10^8$	$6.4 \cdot 10^5$	$6.1 \cdot 10^5$	$6.9 \cdot 10^6$

В свою очередь, преобладающими элементами в нейронной сети коры мозжечка являются гранулярные клетки (*granule cells*), которые, по некоторым оценкам, составляют до 99 % всех нейронов мозжечка.

Согласно современному представлению, существует три основные модели мозжечка, каждая из которых играет ключевую роль в понимании функций этой структуры мозга [27]. Модели предсказания (*Forward Models*), внутренней обратной связи (*Internal Feedback Models*) и оптимального обратного контроля (*Optimal Feedback Control Models*) дают представление о современном уровне понимания участия мозжечка в моторном контроле и обучении.

Имеющиеся интерпретации функционального назначения мозжечка отталкиваются от необходимости решения важнейшей проблемы в биологическом управлении моторикой – неизбежной временной задержки афферентных сенсорных сигналов при достижении центральной нервной системы. Мозг всегда получает информацию о теле и окружающей среде с некоторым опозданием. Например, визуальные сигналы достигают первичной зрительной коры через 30 мс, а теменной коры – через 80 мс после начала стимула. В целом время задержки составляет от 10 мс у мелких животных и до 100 мс у крупных, что сопоставимо с временными масштабами быстрых движений.

Соответственно, существующее объяснение работы мозжечка строится на предположении, что он решает проблему задержки сенсорной обратной связи путем вычисления будущего состояния тела на основе текущей оценки тела и афферентного сигнала управления движением (рисунок 3). Предполагается, что

предсказательное вычисление эмулирует или моделирует фактическое движение тела, по сути, решая уравнение движения тела во времени и предвосхищая будущее положение, отсюда и название – внутренняя прямая модель [28].

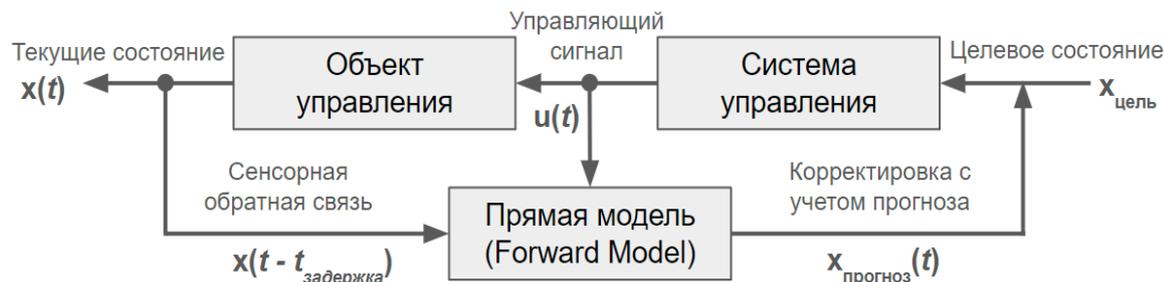


Рис. 3. Внутренняя прямая модель

*Внутренняя прямая модель* предсказывает состояние тела во времени, которое затем используется контроллером обратной связи, тем самым обеспечивая быстрые, стабильные и точные движения. Управление обратной связью, основанное на прогнозировании, является внутренней обратной связью. Существует ряд доказательств, подтверждающих гипотезу предсказательной прямой модели и внутренней обратной связи, полученных в исследованиях нейровизуализации, исследованиях неинвазивной стимуляции и психофизических исследованиях на людях. В целом мозг предсказывает последствие своего действия, сравнивает предсказание с фактическим последствием и улучшает следующее действие как в двигательном обучении на основе ошибок, так и в обучении с подкреплением на основе подкрепления.

Предсказания внутренних моделей, называемых прямыми моделями, потому что они преобразуют двигательные команды в сенсорные последствия, могут использоваться как для создания калиброванных движений на протяжении всей жизни, так и для улучшения способности сенсорной системы оценивать состояние тела и окружающего мира. Прямые модели полезны только в том случае, если они производят непредвзятые прогнозы. Имеющиеся данные показывают, что прямые модели остаются калиброванными посредством двигательной адаптации: обучения, обусловленного ошибками сенсорного прогнозирования [29].

Кроме того, предполагается, что прямая модель, в дополнение к прогнозным вычислениям, обеспечивает расчет матриц усиления как для контроллера

обратной связи, так и для *фильтрации Калмана*. Модель оптимального управления с обратной связью (*optimal feedback control – OFC*) формирует единую структуру, которая объединяет различные вычислительные процессы в обучении и управлении акторами. Основным элементом модели OFC является вычисление двух матриц усиления (матрицы усиления Калмана и матрицы усиления обратной связи).

Как итог, внутренняя прямая модель обеспечивает три ключевые роли в обучении и управлении моторикой: (1) *прогнозирование состояния для компенсации задержки сенсорной обратной связи*; (2) *прогнозирование состояния для вычисления ошибки между прогнозируемым и фактическим результатами* и (3) *вычисление усиления фильтра Калмана и обратной связи*. Множественность вычислительных функций мозжечка подтверждается двигательными дисфункциями при нарушении его работы, в совокупности известных как мозжечковая атаксия, при этом пациенты с мозжечковыми нарушениями страдают от неспособности к двигательной адаптации и обучению.

## **5. МОЗЖЕЧКОВАЯ НЕЙРОСЕТЬ ФИЗИЧЕСКОГО ИНТЕЛЛЕКТА**

У нас есть способность контролировать движения в различных ситуациях, от простых движений конечностей до сложнейших гимнастических упражнений. И выполнение даже простых движений глаз и рук является чрезвычайно сложным с теоретической точки зрения, так как требует координации множества мышц. При этом мышцы быстро устают, изменяя свои реакции от одного движения к другому, а передача сигналов по нервам происходит значительно медленнее, чем требуется. Однако, несмотря на эти ограничения, нервная система способна адаптироваться и компенсировать их, обеспечивая точные движения на протяжении всей жизни. Мозжечок постоянно корректирует ошибки движений, сравнивая запланированные и фактические результаты [29].

Современные исследователи, основываясь на формальном соответствии между экспериментально полученными данными и уравнениями фильтра Калмана, предполагают следующие вычислительные шаги в мозжечковых цепях (рисунок 4) [28, 30].



Рис. 4. Схемы мозжечковых контуров и соответствующие вычислительные шаги из разных источников.

(1) клетки Пуркинье (PCs) вычисляют предсказательное состояние из текущей оценки, передаваемой моховидными (мшистыми) волокнами (MFs) (предсказательные вычисления);

(2) активность глубоких ядер мозжечка (DNC) объединяет предсказанное состояние от активности PCs и сенсорную обратную связь от активности MFs (фильтрационные вычисления);

(3) активность DNC предсказывает будущий вход для MFs (предсказание мозжечка).

Предполагается, что данная модель мозжечка выполняет не только внутреннее предсказание, но и оптимальную интеграцию предсказанного состояния и сенсорных сигналов обратной связи.

Как упоминалось ранее, мы имеем аналогию с фильтром Калмана, являющимся эффективным рекурсивным фильтром, основанным на прогнозной оценке вектора состояния динамической системы, с использованием ряда неполных и зашумленных измерений ее состояния. Этот фильтр, введенный Рудольфом Калманом в 1960 году, широко применяется в обработке сигналов, инженерных и эконометрических моделях.

Фильтр, так же, как мозжечок, работает в формате предсказания-коррекции, состоящем из этапов обновления по времени и измерениям. Математическая теория фильтра Калмана и его различных интерпретаций широко представлена в научной литературе [31], здесь только отметим, что идея алгоритма Калмана состоит в нахождении наилучшего приближения к истинной координате  $x_{k+1}$  при комбинировании предсказанного значения  $\hat{x}_{k+1|k}$  и показания сенсора  $z_{k+1}$  (рисунок 5).

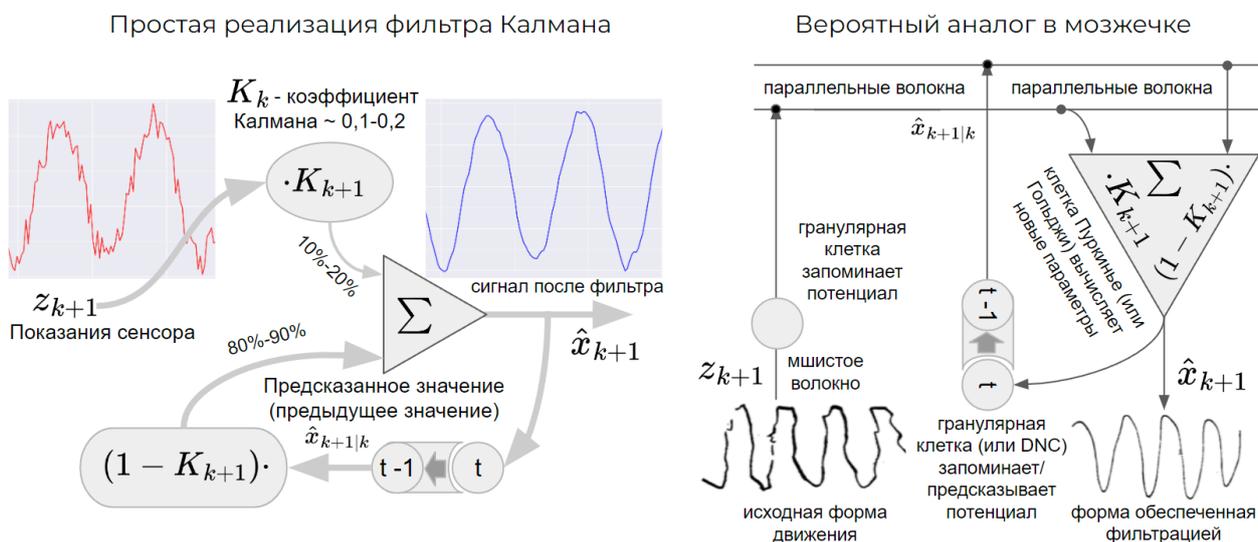


Рис. 5. Простейшая реализация фильтра Калмана и ее возможная интерпретация в структуре мозжечка

Назначаются веса для этих двух источников информации с помощью коэффициента Калмана  $K_{k+1}$ . Таким образом, оценка координаты  $x_{k+1}$  на очередном шаге вычисляется как  $\hat{x}_{k+1} = K_{k+1}z_{k+1} + (1 - K_{k+1})\hat{x}_{k+1|k}$ , где  $\hat{x}_{k+1|k}$  является предсказанием на основе предыдущего шага. Коэффициент Калмана  $K_{k+1}$  выбирается так, чтобы минимизировать среднеквадратичную ошибку между оценочной  $\hat{x}_{k+1}$  и истинной координатой  $x_{k+1}$ . Если сенсор точный,  $K_{k+1}$  будет ближе к единице, иначе вес предсказанного значения будет больше. В результате фильтр Калмана эффективно снижает влияние шума и улучшает точность оценки состояния системы.

На рисунке 5 также показана возможная интерпретация фильтра как нейробиологической структуры, содержащей рассмотренный мозжечковый контур. С целью демонстрации состоятельности данной гипотезы (рисунок 6) автором настоящей работы подготовлены код на языке программирования Python, демонстрирующий работу вышеприведенной версии линейного фильтра Калмана для синусоиды со случайными помехами (1–4), и иллюстрация попытки пациента с заболеванием мозжечка воспроизвести верхнюю синусоидальную кривую (А, В) [32].

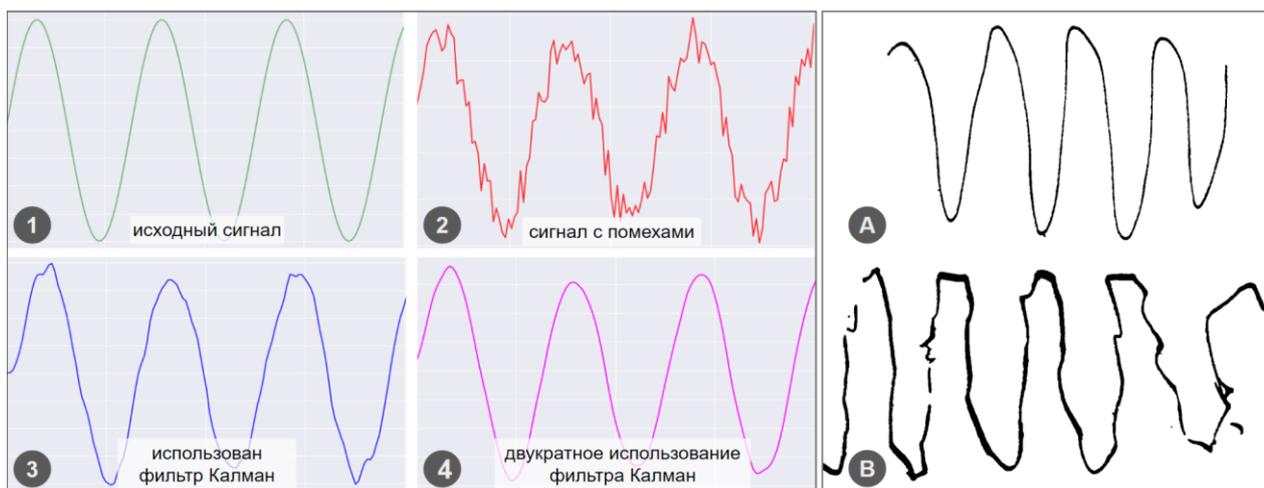


Рис. 6. Программная реализация линейного фильтра Калмана (1–4) и рисунок пациента с заболеванием мозжечка

Однако следует отметить, что предлагаемые современными исследователями схемы межклеточного взаимодействия (рисунок 4) не в полной мере отвечают требованиям построения фильтра Калмана, так как для возникновения полноценного контура необходима передача сигнала как  $DNC \Rightarrow MF \Rightarrow GC$ .

## 6. РАЗВИТИЕ АРХИТЕКТУРЫ МОДЕЛИ ФИЗИЧЕСКОГО ИНТЕЛЛЕКТА

Мозжечок является одним из древнейших разделов мозга, он имеется у представителей всех позвоночных и содержит более половины всех нейронов мозга млекопитающих [33]. Очевидно, что сводить его функционал к простой рекуррентной фильтрации – чрезмерное упрощение. Более того, сам процесс рекуррентного предсказания быстро усложняется при росте глубины прогноза и кинематической сложности частей тела организма. В то же время известно, что

искусственные нейронные сети с рекуррентными связями способны аппроксимировать любые динамические системы [34]. Вследствие этого двигательная последовательность может быть смоделирована нейросетями как процесс, который развивается в течение определенного периода. Следовательно, мозжечок должен содержать архитектуру, которая позволяет из простых повторяющихся сегментов сформировать сложнейшую динамическую модель всего многоэлементного тела организма, способную к адаптации к внешнему миру через непрерывное обучение. Далее предложена к рассмотрению гипотеза о механизме построения такой системы.

Кинестетический интеллект для достижения желаемого результата управляемым им организмом должен опираться на прогнозные модели взаимодействия частей тела между собой и окружающей средой. Учитывая, что сами живые существа находятся в реальном физическом мире, такие модели должны строиться на основе законов классической механики, позволяющих, в свою очередь, описать любую механическую систему с помощью дифференциальных уравнений. Ньютон отразил эту взаимосвязь в виде анаграммы, смысл которой в современных терминах можно вольно передать так: «*Законы природы выражаются дифференциальными уравнениями*» [35].

Покажем, каким образом может функционировать биологический аналоговый мозжечковый компьютер на примере нахождения вычислительного решения классического дифференциального уравнения гармонических колебаний:

$$\ddot{x} = -w^2 x \quad \text{where : } \dot{x} = \frac{dx}{dt}; \quad \ddot{x} = \frac{d^2x}{dt^2} = \frac{d\dot{x}}{dt}$$

где  $x$  – осциллирующий параметр,  $\dot{x}$  – скорость и  $\ddot{x}$  – ускорение его изменения. Схема простого аналогового компьютера, обеспечивающего численное решение данного уравнения методом Эйлера, приведена на рисунке 7.

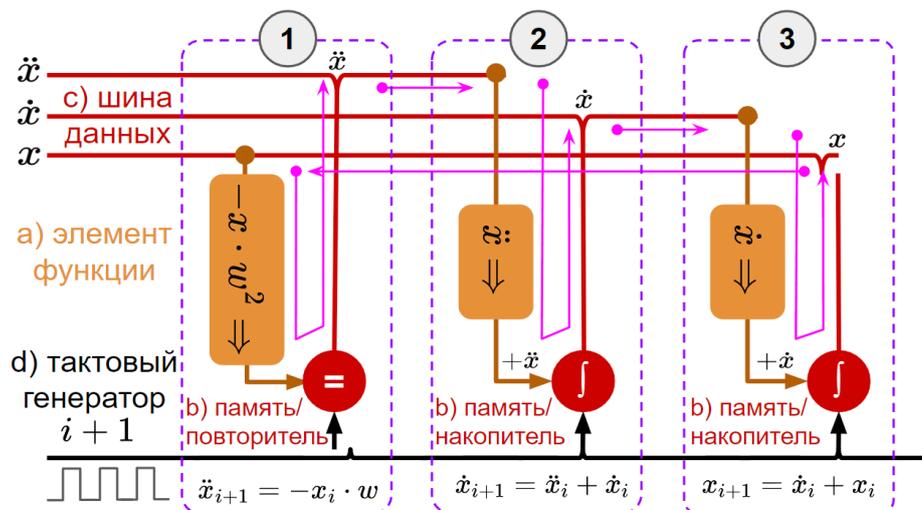


Рис. 7. Схема аналогового компьютера, решающего уравнение  $\ddot{x} = -w^2 x$ .

В нем три сегмента (1–3), состоящие из типовых элементов классического аналогового компьютера: операционный блок (а), *использующий параметры шины данных (с) и осуществляющий над ними простые арифметические операции*, а также элемент памяти (b), *сохраняющий или интегрирующий входящий сигнал и поддерживающий уровень параметра в шине данных*.

Краткое описание элементов компьютера и выполняемых ими операций:

(1) сегмент – усиливает/аттенюирует сигнал  $x$  в  $-w^2$  раз, сохраняет и поддерживает уровень в шине  $\ddot{x}$ ;

(2) сегмент – передает параметр без изменений на интегрирующий элемент, а также поддерживает уровень в шине  $\dot{x}$ ;

(3) сегмент – сходный с предыдущим, то есть передает параметр без изменений на интегрирующий элемент, а также поддерживает уровень в шине  $x$ .

Таким образом, сегменты образуют полноценный замкнутый контур, в котором процессы соответствуют модели гармонических колебаний и который решает в реальном времени дифференциальное уравнение.

Возвращаясь к цитоархитектуре мозжечка, мы можем выявить в его структуре два схожих вида сегмента, показанных на рисунке 8.

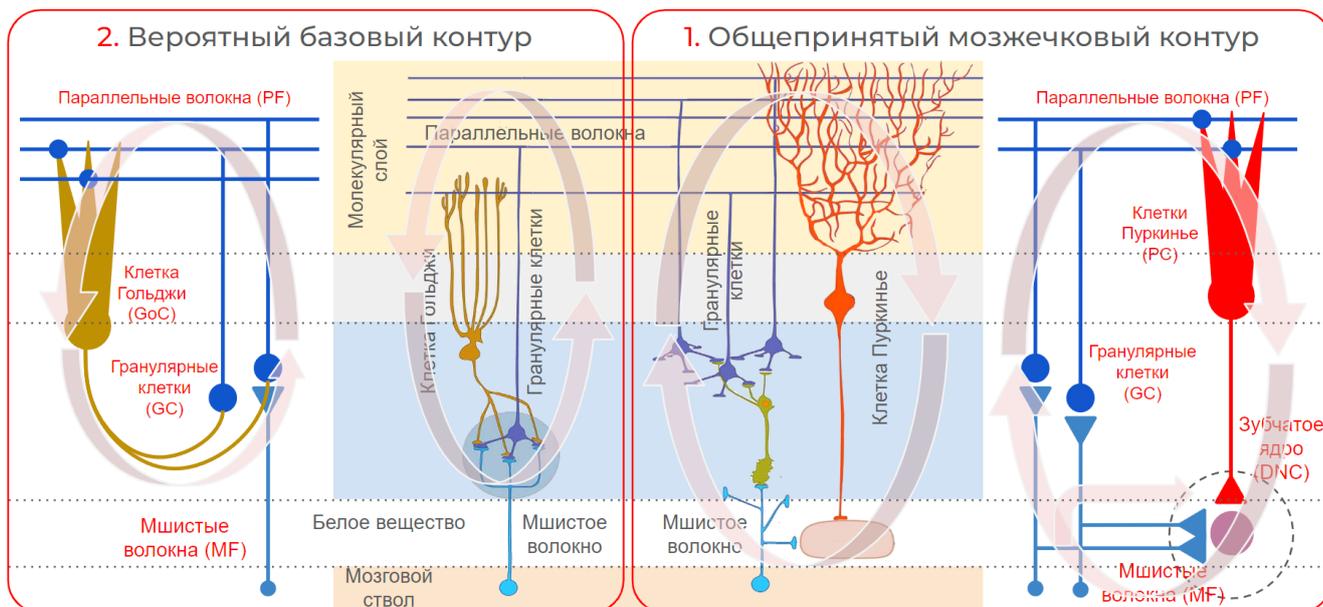


Рис. 8. Два вероятных базовых сегмента биологического аналогового компьютера

При отображении биологической архитектуры была использована структура коры мозжечка взрослого человека, состоящая из четырех отдельных слоев:

(1) поверхностно-молекулярного слоя, бедного клетками структуры, богатого аксонами – параллельными волокнами гранулярных (звездчатых) клеток (GC), дендритами клеток Пуркинье (PC);

(2) узкого слоя PC, включающего монослой сомат PC.

Под слоем PC находится

(3) гранулярный слой, плотно упакованный соматами GC и клетками Гольджи (GoC).

Три клеточных слоя покрывают

(4) слой белого вещества, который включает кортикальные афферентные и эфферентные аксонные пути [36].

По мнению автора, гораздо более вероятным выглядит второй вариант слева, где роли в сегменте распределены следующим образом:

(a) *клетка Гольджи (GoC)* выполняет роль операционного блока, способного принимать параметры из параллельных волокон и проводить над ними простые арифметические операции, что в принципе согласуется с классическим представлением о работе нейрона;

(b) *гранулярная клетка (GC)* получает от аксонов GoC параметры и выполняет роль элемента памяти, сохраняющего или интегрирующего полученные параметры и поддерживающего их уровень в параллельных волокнах (внутренняя шина данных).

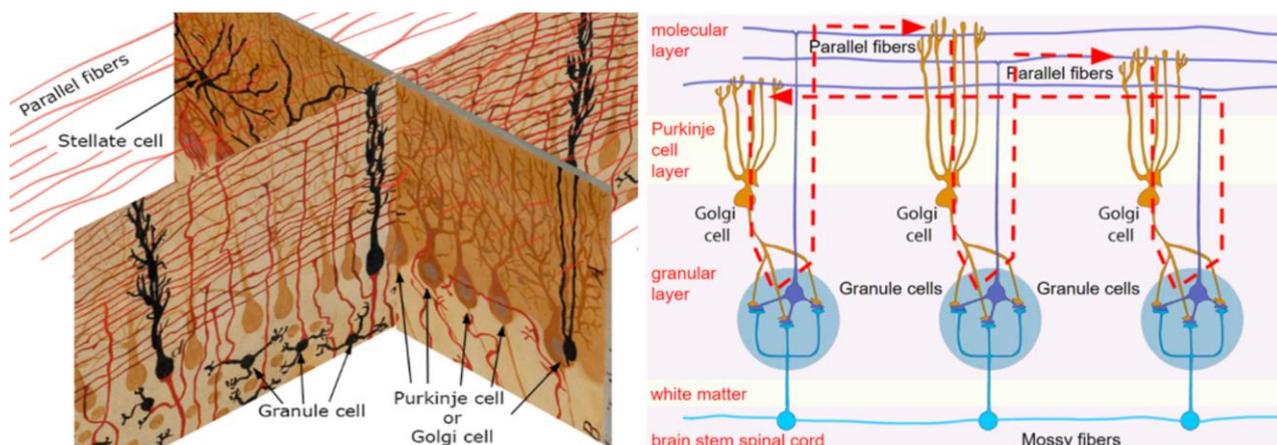


Рис. 9 – Изометрическая проекция и схема биологического аналогового компьютера, решающего дифференциальное уравнение

На рисунке 9 справа показана изометрическая проекция коры мозжечка с использованием рисунков Santiago Ramon y Cajal [37], отображающих основные нервные клетки и их повторяющиеся элементы в архитектуре, а слева – возможная модель биологического аналогового компьютера, решающего дифференциальное уравнение гармонических колебаний, построенная на базе предложенной концепции.

В обоснование приведенной концепции можно привести утверждение, что на уровне молекулярного слоя клетки Гольджи принимают асимметричные синаптические контакты от параллельных волокон и участвуют в механизмах *feed-forward inhibition* и *feedback inhibition loops*, индуцируя синхронную ритмичную активность в гранулярных клетках (рисунок 10) [38]. Исследователи продемонстрировали ингибирующую природу клеток Гольджи и показали, что организация цепей зернистого слоя основана на характерных петлях ингибирования прямой и обратной связи, направленных к дендритам зернистых клеток. При

этом клетки Гольджи являются крупнейшими и наиболее многочисленными интернейронами зернистого слоя, который содержит одну клетку Гольджи на каждые несколько сотен или тысяч зернистых клеток (~6000 у кошек; ~1200 у людей, ~400 у крыс) [39].

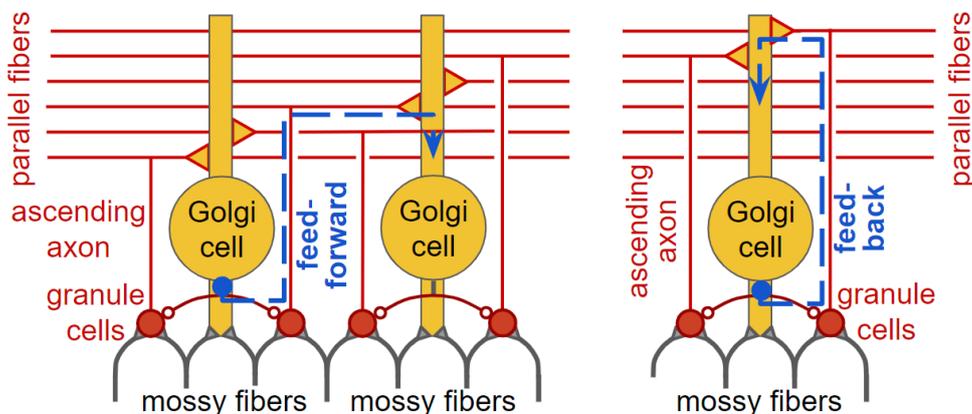


Рис. 10. Схема связей интернейронов при формировании механизма возвратного торможения в коре мозжечка: прямая петля и петля обратной связи.

Предлагаемая архитектура может быть легко масштабирована до метода Рунге–Кутты не только классического четвертого, но и более высоких порядков. Это приводит к росту количества используемых нейронов и замедлению процесса прогнозирования, но одновременно и к значительному повышению точности. Так как для многих животных точность движения является крайне критическим параметром естественного отбора, вероятно, для части прогнозных процессов сформированы именно такие сегменты.

## 7. ОСОБЕННОСТИ ЦИФРОВОГО МОДЕЛИРОВАНИЯ ОРГАНИЧЕСКИХ НЕЙРОННЫХ СЕТЕЙ

Экспериментальные результаты нейробиологии привели исследователей к определению трех поколений моделей нейронных сетей [40]. Третье поколение в качестве вычислительных элементов использует спайковые (импульсные) нейроны (spiking neurons or integrate-and-fire neurons), сеть из которых (spiking neural networks – SNN) гораздо более точно имитирует естественные органические нейронные сети. В SNN нейроны не передают информацию в виде вычис-

ляемого постоянного потенциала в каждом цикле распространения и для каждого нейрона (как это происходит с типичными многослойными перцептронными сетями), а направляют сигнал только тогда, когда мембранный потенциал достигает определенного значения, называемого порогом (the threshold). В этот момент нейрон срабатывает и генерирует потенциал действия, или спайк – кратковременное изменение мембранного потенциала, которое распространяется по длинному аксону.

Как следствие, создание точной модели аналогового биокомпьютера на базе архитектуры мозжечка с учетом реализации spiking neural networks требует создания принципиально новых нейроморфных процессоров, радикально отличающихся от компьютерной архитектуры фон Неймана, доминирующей в IT-отрасли последние полвека. В этой сфере ведутся активные разработки: Akida™ от BrainChip, Neurogrid от Stanford University, SpiNNaker от University of Manchester, IBM TrueNorth chip.

По этой причине, на первый взгляд, между предложенной архитектурой мозжечка и спайковыми нейронными сетями имеются фундаментальные противоречия, так как каждая из переменных в дифференциальном уравнении, описывающая предложенную архитектуру, определяется некоторым потенциалом, непрерывно изменяющимся во времени. В свою очередь, спайковая модель оперирует импульсами, точнее, частотой импульсов, то есть мозжечковая модель в большей степени соответствует второму поколению искусственных нейронных сетей. Однако spiking может рассматриваться как разновидность частотной модуляции (frequency modulation), то есть в качестве одного из видов аналоговой модуляции, при которой модулирующий сигнал управляет частотой несущего колебания, а амплитуда остается относительно постоянной.

В качестве доказательства состоятельности предложенной гипотезы рассмотрим динамическую модель биологической активности нейрона на примере модели Izhikevich, которая относится к классу моделей с дискретным временем и представляет собой точечные отображения. Модель Izhikevich изначально разработана в непрерывном времени, но ее дискретизация с временным шагом 1 мс с использованием метода Эйлера может быть описана следующим выражением [41]:

$$\begin{aligned} & \text{if } v_n < 30 \begin{cases} v_{n+1} = 0.04 \cdot v_n^2 + 6 \cdot v_n + 140 - u_n + I \\ u_{n+1} = 0.004 \cdot v_n + 0.98 \cdot u_n \end{cases} \\ & \text{otherwise} \begin{cases} v_{n+1} = c \\ u_{n+1} = u_n + d \end{cases} \end{aligned}$$

где  $v$  – мембранный потенциал,  $u$  – медленная восстанавливающая переменная, параметр  $c$  определяет напряжение при переустановке;  $I$  – ионный ток, инжектированный в нейрон, благодаря которому и происходит изменение мембранного потенциала.

Медленная подсистема имеет особенности: когда генерируется спайк, медленная переменная испытывает резкий скачок, равный значению параметра  $d$ . Быстро-медленные свойства модели позволяют ей воспроизводить разнообразные типы колебательной активности, в частности, спайк-бёрстовые колебания.

На рисунке 11 показана зависимость частоты импульса от величины тока с использованием модели Izhikevich.

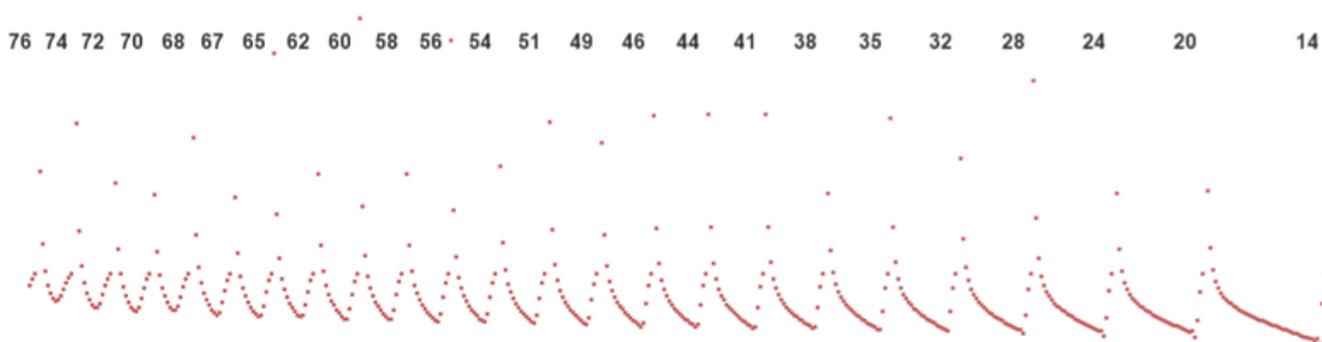


Рис. 11. Частотная модуляция в spiking neural networks. Сверху показана величина тока  $I$ . Частота всплесков пропорциональна величине тока

Изображение быстрых изменений есть не что иное, как классическая модель «накопления и сброса». Hodgkin, основоположник бифуркаций в нейронной динамике, стимулировал аксон кальмара импульсами различной амплитуды и выявил три вида нейронной возбудимости:

*Class I* – в зависимости от силы подаваемого тока потенциалы действия могут генерироваться с низкими частотами;

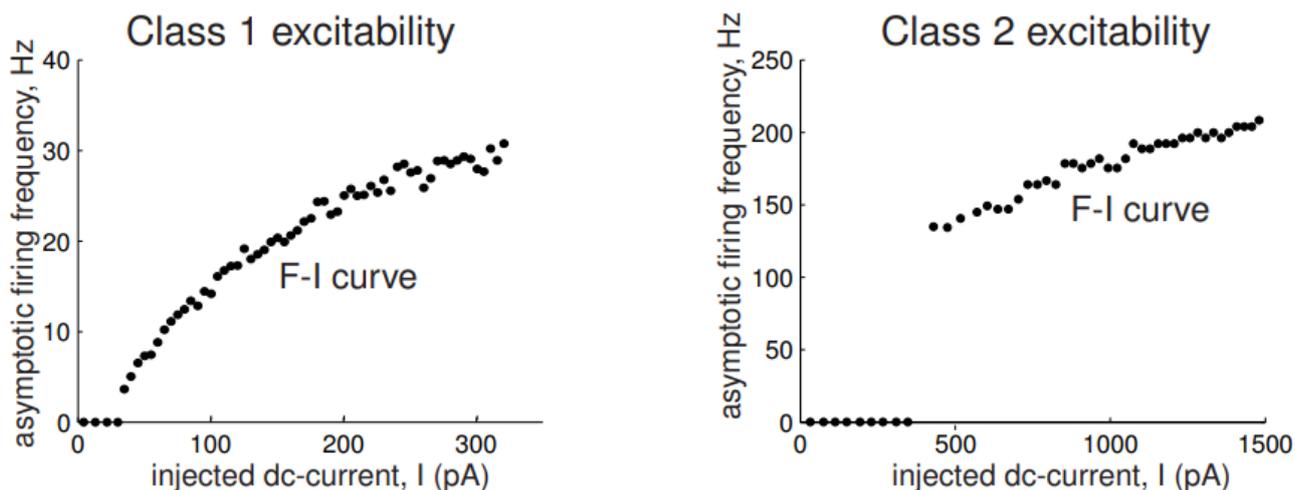


Рис. 12. Frequency-current (F-I) curves of cortical pyramidal neuron and brainstem mesV neuron

*Class II* – потенциал действия генерируется в определенной полосе частот;

*Class III* – откликом на импульсный ток является генерация одного потенциала действия.

На рисунке 12 изображены frequency-current (F-I) curves активности нейрона для I и II классов возбудимости [42].

Таким образом, учитывая, что потенциал  $v$  служит источником итогового тока  $I$ , биологические нейроны определяются как частотное представление амплитудной модели нейронных сетей. При этом оно включает в свою операционную работу понятие времени.

По всей видимости, эволюционная природа выбранного естественным отбором спайкового метода основано на гораздо большей помехоустойчивости. Здесь уместно сравнение с частотной модуляцией (FM) – технологией, используемой в телекоммуникациях, радиовещании и обработке сигналов. Она гораздо менее восприимчива к радиочастотным помехам, чем сигнал амплитудной модуляции (AM) равной мощности. Однако искусственные нейронные сети гораздо легче и эффективнее реализовать на компьютерах архитектуры фон Неймана, непосредственно использовав амплитудное представление. К тому же абсолютную точность и помехоустойчивость обеспечивает принцип хранения и передачи уровня сигнала в данной архитектуре – через его двоичное кодирование.

Работа биологического аналогового компьютера носит непрерывный характер. Даже если мы имеем дело с частотной модуляцией, то и плавность изменения частот непрерывна. В то же время архитектура фон Неймана изначально содержит дискретный итерационный способ вычислений. По этой причине на ранее приведенном схематическом изображении цитоархитектуры мозжечка, решающего дифференциальное уравнение гармонических колебаний, одному из моховидных волокон (*mossy fiber*) были приданы свойства тактового генератора. В реальности *mossy fiber* являются основным и универсальным источником афферентных сигналов, поступающих в мозжечок.

Согласно теореме Котельникова (*The Nyquist–Shannon sampling theorem*), «любую функцию  $F(t)$ , состоящую из частот от 0 до  $f$ , можно непрерывно передавать с любой точностью при помощи чисел, следующих друг за другом менее чем через  $1/(2f)$  секунды». То есть переход от сигналов, непрерывных во времени, к сигналам, дискретным во времени, может быть осуществлен без потерь при условии необходимой частоты дискретности. Таким образом, в случае принятия этих двух допущений биоинспирированный алгоритм построения нейронных сетей на базе архитектуры мозжечка, позволяющего находить вычислительные решения систем дифференциальных уравнений, может быть легко реализован в классических цифровых компьютерах и языках их программирования, при этом такое упрощение соответствует концепции построения биологического эталона.

## **8. МОЗЖЕЧОК КАК АНАЛОГОВЫЙ КОМПЬЮТЕР ОБЩЕГО НАЗНАЧЕНИЯ**

Модель мозжечка в полной мере может соответствовать принципам построения классических аналоговых компьютеров, длительное время являвшихся единственным инструментом научных и военных расчетов. Согласно существующим определениям [43], название аналоговых вычислительных машин возникло как отражение принципа построения таких систем, основанного на подборе физических компонентов (биологических, химических, электрических, механических, оптических и т. п.), процессы в которых протекают аналогичным образом. Так как в реальном мире большинство динамических моделей описы-

вают системами дифференциальных уравнений, подбирается физический компонент, процессы в котором представлены теми же математическими выражениями. Таким образом, создается полная аналогия моделируемого процесса.

Теорию аналогового компьютера *общего назначения* (general purpose analog computer – GPAC) впервые предложил К. Шеннон в рамках доказательства теоремы, согласно которой самую общую систему обыкновенных дифференциальных уравнений

$$f_k(x, y_1, y_1' \dots y_1^m; y_2, y_2' \dots y_2^m \dots y_n, y_n' \dots y_n^m) = 0; \text{ где } k = 1, 2 \dots n$$

$m$ -го порядка от  $n$ -зависимых переменных можно решить на дифференциальном анализаторе с использованием конечного числа только двух типов устройств:

– *интеграторов*, обеспечивающих выходной сигнал пропорционально интегралу (обычно по времени) от входного сигнала. То есть устройство получает параметры  $u$  и  $v$ , выдает  $w = \int_{v_0}^v (u + a)dv$ , где  $a$  – произвольная константа;

– *сумматоров*, обеспечивающих выходной сигнал, равный  $w = u + v$  (в более комплексной формулировке определение выглядит как объединение сумматоров и умножителя с получением функции  $Y = \sum_{k=1}^N a_k x_k$ , где  $a_k$  – действительные константы).

Уравнения Шеннона отличаются тем, что содержат лишь операции интегрирования, суммирования и умножения переменной на коэффициент. Отсутствие функциональных преобразований позволяет упростить и унифицировать процесс численного интегрирования дифференциальных уравнений в форме Шеннона. Для этого достаточно в исходных уравнениях, заданных в нормальной форме Коши, произвести замену переменных.

В отличие от уравнений в нормальной форме Коши, уравнения Шеннона не содержат общего для всех уравнений множителя, представляющего собой дифференциал независимой переменной. Отсутствие такого множителя указывает на то, что уравнения Шеннона требуют интегрирования не по Риману, а по Стильтьесу. Интегрирование по Стильтьесу отличается от интегрирования по Риману тем, что оно позволяет учитывать скачкообразные изменения в интегрируемой функции, что делает его более гибким и подходящим для обработки разрывных функций.

Исключением из теоремы являются довольно редко встречающиеся гипертрансцендентные (трансцендентно-трансцендентные) функции, например, гамма-функция или дзета-функция Римана [44].

Таким образом, можно провести аналогию между необходимыми элементами ГРАС К. Шеннона, реализациями в аналоговых вычислительных машинах (АВМ) и их вероятными биологическими аналогами в мозжечке (см. Таблица 5).

Таблица 5.

Устройство ГРАС по К.Шеннону и АВМ	Возможный аналог в мозжечке
<p><i>интеграторы, установщики вещественных констант</i> - в классических АВМ интеграторы реализуются с использованием конденсаторов и операционных усилителей, которые позволяют накапливать потенциал пропорционально входному сигналу и в последующем сохранять его</p>	<p><i>гранулярные клетки (granule cells)</i> – накапливают или/и запоминают потенциал, поддерживают его уровень в параллельных волокнах</p>
<p><i>сумматоры, умножители</i> – АВМ сумматоры реализуются с помощью резисторов и операционных усилителей генераторы функций</p>	<p><i>клетки Гольджи (Golgi cells)</i> – получают сигналы от множества входов и суммируют их, выполняя функции, аналогичные сумматорам и умножителям в аналоговых компьютерах, функционируют во внутреннем контуре;</p> <p><i>клетки Пуркинье (Purkinje cells)</i> – аналогичны <i>клетки Гольджи</i>, но являются единственными нейронами, «выходными» из мозжечка</p>

Таким образом, в мозжечке содержатся все необходимые виды функциональных элементов для определения его в качестве универсального аналогового компьютера общего назначения.

В связи с некоторой предвзятостью в отношении аналоговых компьютеров следует отметить, что причиной их вытеснения цифровыми компьютерами стала специфика программирования – моделирование процессов реального мира было возможным при условии глубокого понимания физической природы явления и наличия математической интерпретации через аппарат дифференциальных уравнений. В результате аналоговые машины занимали нишу научных, инженерных или военных приборов с механическим процессом программирования, ограниченной сложностью моделей и невысокой скоростью обсчета. Однако, как будет показано далее на примере биологических организмов, эти ограничения могли быть преодолены в процессе органической эволюции.

Феноменальный прогресс в цифровой электронике привел к тому, что аналоговые вычисления гораздо эффективнее производят современные цифровые компьютеры, имеющие архитектуру фон Неймана. Более того, существует огромное множество программных решений, моделирующих механику сплошных сред, теплопередачу, распространения электромагнитных волн и пр. на основе решения описывающих их систем дифференциальных уравнений с использованием методов конечных элементов (Finite element method), конечных разностей (Finite-Difference Method, FDM) или конечных разностей во времени (Finite-Difference Time-Domain, FDTD) для моделирования, которые в некоторой степени схожи с предлагаемым подходом.

Настоящая работа предлагает альтернативную концепцию существующим системам искусственного интеллекта, формирование другого направления в архитектурах искусственных нейронных сетей. Учитывая гомеостатическую природу многоклеточных организмов, лежащую в основе структуры мозжечка, в отличие от традиционных нейронных сетей с однонаправленной передачей информации (от входных к выходным нейронам), предлагаемая архитектура больше соответствует машине Больцмана (Boltzmann machine) и сети Хопфилда (Hopfield model) [45]. Нейронные сети мозжечка также имеют многочисленные цепи обратной связи, что обеспечивает циркуляцию информации внутри сети до достижения устойчивого энергетического состояния. Математические интерпретации и программные приложения, разработанные на базе этой нейросетевой архитектуры, позволяют моделировать сложные физико-механические про-

цессы, которые традиционно описываются системами дифференциальных уравнений, что значительно расширяет возможности ИИ в управлении динамическими системами.

Для демонстрации возможностей предложенного подхода в области моделирования автором в опубликованных научных работах приведены примеры использования данной архитектуры для вычислительного решения задачи трех тел [46] и исследования процессов распространения волн в неоднородной среде [47] (рисунок 13).

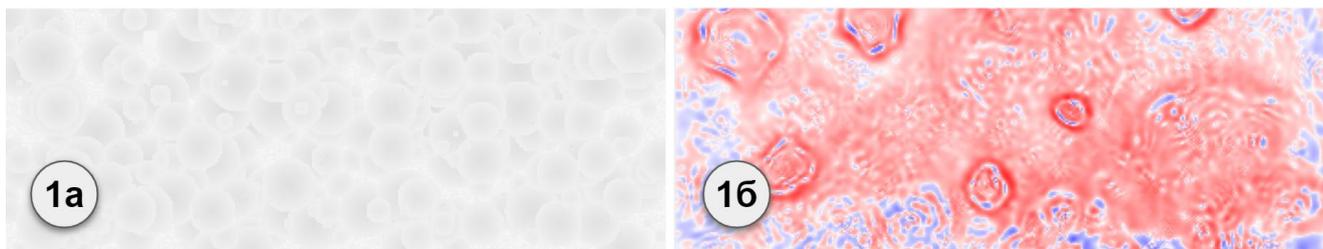


Рис. 13. Неоднородность среды (1a) и распространения волн в ней (16)

## 9. ФОРМИРОВАНИЕ МОДЕЛИ ФИЗИЧЕСКОГО ИНТЕЛЛЕКТА

По всей видимости, образование живых многоклеточных организмов сопровождалось острой необходимостью как внутренней координации частей тела, так и обеспечения взаимодействия с внешней средой. При этом стремительно растущая сложность самих организмов и необходимость локомоции потребовали создания нервной системы, способной сформировать точную кинестетическую модель частей тела, необходимую для эффективного управления мускулатурой.

Эволюция за последние 600 миллионов лет породила «бесконечное» число форм, начиная с древнего билатерального червя и заканчивая множеством разнообразных морфологий животных. Более того, все животные демонстрируют удивительную степень воплощенного интеллекта, используя свою развитую морфологию для реализации сложнейших задач. Область воплощенного познания утверждает, что разумному поведению могут быстро научиться агенты, морфология которых хорошо адаптирована к окружающей среде.

Воплощенный интеллект позволяет организмам управлять сложным ансамблем составных частей их тел, обеспечивая адекватное разумное поведение в окружающем их реальном мире [48]. Особенностью физико-анатомического

строения биологических организмов является возможность представления частей его тела в виде кинематических цепей (kinematic chain), см. рисунок 14. Соответственно, кинематические цепи играют ключевую роль в проектировании и управлении робототехническими системами. В классическом определении кинематическая цепь является совокупностью твердых тел, соединенных шарнирами для обеспечения ограниченного движения, которое является математической моделью механической системы.

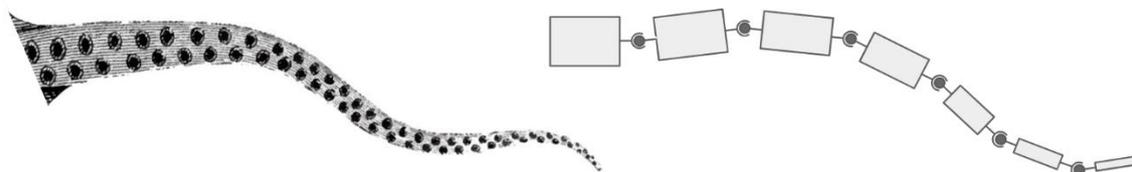


Рис. 14. Щупальце осьминога и представление в виде кинематической цепи

Ключевыми компонентами таких систем являются механические узлы - приводы (актуаторы), обеспечивающие движение частей объекта относительно друг друга, а также физический интеллект, обеспечивающий управление узлами с учетом их внутреннего и внешнего взаимодействия. Первая компонента была разработана уже много лет назад – конструкции приводов, по физическим параметрам равные и даже превосходящие мышцы биологических организмов. Современные промышленные высокоскоростные манипуляторы легко справляются с прецизионными операциями, такими как игра на музыкальных инструментах, теннис, снукер и т. д. Высокомоментные суставные двигатели, используемые сегодня, позволяют строить роботов, способных двигаться на четырех и даже двух конечностях, подобно большинству млекопитающих в природе.

Однако существующие системы управления актуаторами не только очень далеки от человеческих возможностей, но даже близко не подошли к способности конкурировать с биологическими организмами. Для человека требуется гемостатическое оперативное управление 640 мышцами, а количество мышц у насекомых еще больше.

Использование предложенной архитектуры нейронных сетей может приблизить решение этой ключевой задачи робототехнических систем. *Продемонстрируем использование данной архитектуры на примере управления простой моделью щупальца осьминога.*

Щупальце осьминога представляет собой удивительно сложную и высокоорганизованную структуру, состоящую из множества мышечных волокон, которые обеспечивают широкий спектр движений. При этом 180 млн нейронов в центральном мозге связаны с более чем 40 млн нейронов в каждом из восьми щупальцев через относительно небольшое количество эфферентов (~32 тыс.) и афферентов (~140 тыс.). Моторный контроль этого животного включает в себя уникальную воплощенную организацию взаимодействия между нервной системой, морфологией тела и средой выполнения задач животного [49].

Задачей настоящей главы являются определение и описание базовых элементов нейросети, использование которых позволяет построить простые механические аналоги биологических организмов. Наиболее простая аналогия нейронных сетей с глубокими обратными связями – это замкнутые энергетические системы, по этой причине оптимальнее всего строить модель механической системы через закон сохранения энергии.

Энергия механической системы может быть представлена в виде суммы двух существенно различных членов: кинетической энергии ( $T$ ), зависящей от скоростей, и потенциальной энергии ( $U$ ), зависящей только от координат частиц [50]:

$$E = T(q, \dot{q}) + U(q); \quad E = \sum_a \frac{m_a v_a^2}{2} + U(r_1, r_2, \dots)$$

Таким образом, любая сколь-либо сложная механическая система может быть представлена как набор двух видов универсальных элементов, отражающих кинетическую и потенциальную энергии.

Отталкиваясь от данного положения, можно ввести понятия двух видов элементов:

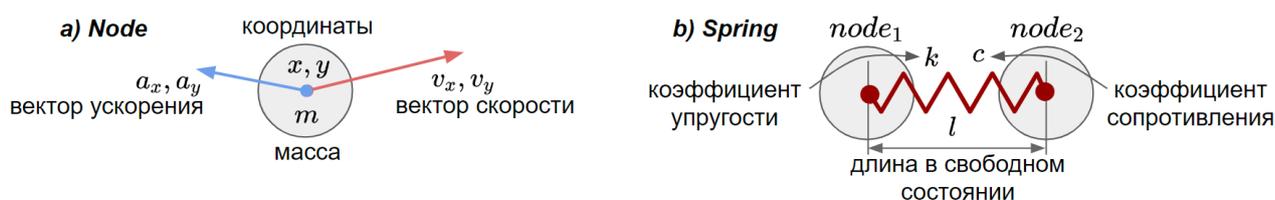


Рис. 15. Два вида базовых универсальных элементов механической системы

1. Узел (Node, рисунок 15а) – кинетический/механический элемент системы ( $T$ ), выполняющий следующие роли: накопление кинетической энергии;

сочление, к которому крепятся пружины (spring); другие виды взаимодействия со средой, которые будут приведены ниже. Данный реактивный элемент отражает базовое свойство всех механических систем – наличие инерционной массы. Для рассматриваемого случая он обеспечивает учет, в том числе, массы и элементов spring.

Node для двухмерной модели может быть описан следующими параметрами:  $m$  – масса,  $x$ ,  $y$  – координаты,  $\dot{x}$ ,  $\dot{y}$  – скорости;  $\ddot{x}$ ,  $\ddot{y}$  – ускорения.

2. Управляемая пружина/мышца (Spring, рисунок 15b) – пространственный элемент, позволяющий: накапливать потенциальную энергию ( $U$ ); формировать пространственные структуры за счет упругого удерживания узлов (node) на определенном расстоянии. Является своего рода мышцей, то есть некоторые параметры элемента могут быть изменены нервной системой.

Это крайне универсальный – активный, реактивный и пассивный – элемент, то есть может создавать, поглощать и накапливать/отдавать энергию. Кроме того, именно с помощью него строится пространственная структура тела. Похож на мышцу, но способен не только сжиматься под влиянием нервных импульсов, но и разжиматься, а также при определенных параметрах заменять жесткие элементы, такие как кости.

Spring для двухмерной модели может быть описан следующими параметрами:  $l_0$  – длина пружины в свободном состоянии, то есть когда Spring имеет заданную длину, но не оказывает воздействие на тела, которые он соединяет;  $k$  – коэффициент упругости, коэффициент, связывающий в законе Гука удлинение/сжатие упругого тела и возникающую вследствие этого силу воздействия;  $c$  – коэффициент сопротивления, устанавливающий соотношение между скоростью движения связываемых тел и возникающей при этом силой сопротивления,

позволяет демпфировать, то есть гасить колебания;  $node_1$ ,  $node_2$  – ссылки на тела, которые связывает spring между собой.

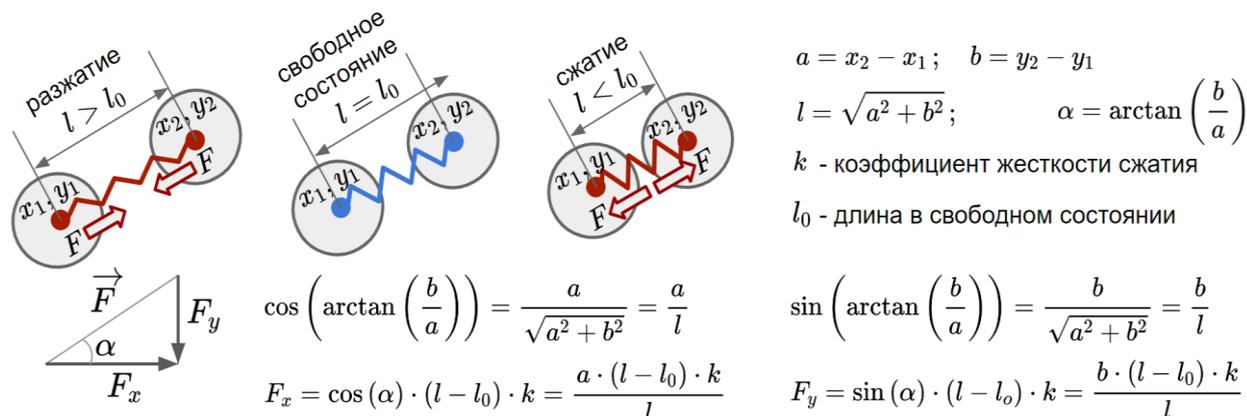


Рис. 16. Расчет силы воздействия spring на nodes

Элемент spring управляется нейронной сетью через задание величины  $l$ , фактически уменьшая эту величину, мы вызываем силу сжатия, то есть сближения между  $node_1$  и  $node_2$ , и, наоборот: увеличивая значение  $l$ , мы вызовем силу, удаляющую  $node_1$  и  $node_2$ . Силы, воздействующие на nodes, могут быть определены после оптимизации по довольно простой формуле, исключая ресурсоемкие тригонометрические операции (рисунок 16).

Таким образом, система дифференциальных уравнений для  $i$ -го элемента spring будет иметь вид

$$\begin{cases} \ddot{x}_{i,1} + \frac{c_i}{m_{i,1}} \dot{x}_{i,1} + \frac{F_{i,x}}{m_{i,1}} = 0 \\ \ddot{y}_{i,1} + \frac{c_i}{m_{i,1}} \dot{y}_{i,1} + \frac{F_{i,y}}{m_{i,1}} = 0 \\ \ddot{x}_{i,2} + \frac{c_i}{m_{i,2}} \dot{x}_{i,2} - \frac{F_{i,x}}{m_{i,2}} = 0 \\ \ddot{y}_{i,2} + \frac{c_i}{m_{i,2}} \dot{y}_{i,2} - \frac{F_{i,y}}{m_{i,2}} = 0 \end{cases} \quad \begin{cases} l = \sqrt{(x_{i,2} - x_{i,1})^2 + (y_{i,2} - y_{i,1})^2} \\ F_{i,x} = \cos(\alpha) \cdot (l - l_0) \cdot k = \frac{(x_{i,2} - x_{i,1}) \cdot (l - l_0) \cdot k}{l} \\ F_{i,y} = \sin(\alpha) \cdot (l - l_0) \cdot k = \frac{(y_{i,2} - y_{i,1}) \cdot (l - l_0) \cdot k}{l} \end{cases}$$

где индексы 1 и 2 – это элементы node, прикрепленные к  $i$ -й spring с обеих сторон.

С точки зрения цитоархитектурного представления, на рисунке 17 показана примерная схема биологического аналогового нейрокомпьютера, решающего вычислительным методом заданную систему дифференциальных уравнений.

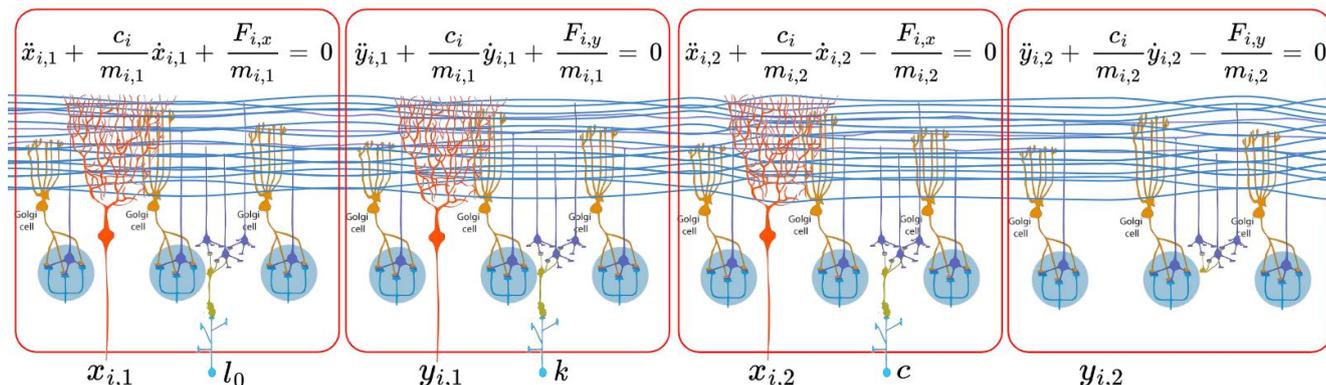


Рис. 17. Схема нейрокомпьютера, вычисляющего взаимодействие двух nodes, связанных между собой spring

Параллельные волокна содержат параметры, определяющие модель и ее состояние, являющиеся аксонами гранулярных клеток. Для 2D-представления пара nodes требует  $6 \times 2 + 1$  оперативных параметров ( $x, y, \dot{x}, \dot{y}, \ddot{x}, \ddot{y}, lr$ ) и  $1 \times 2$  фиксированных ( $m$ ), а каждая spring, объединяющая пару, требует три управляемых параметра ( $l_0, k, c$ ) и два фиксированных ( $node_1, node_2$ ) – итого 20 гранулярных клеток. Как будет показано при дальнейшей детализации модели, стремительно растет число гранулярных клеток, по всей видимости, именно это является причиной наличия в биологических системах столь существенного количества этих видов нейронов. При этом параметры и, соответственно, гранулярные клетки можно разделить на три группы, определяющие:

- *морфологические (генетические) особенности* – признаки, приобретенные при формировании организма. В данном случае это nodes соединяющихся springs ( $b_1, b_2$ ), то есть конструкция каркаса тела и системы органов;

- *параметры, формирующиеся в процессе адаптации* организма к локальным особенностям окружающей среды. Примером может служить нейромышечная память. Для рассматриваемой модели формируется через сенсорную обратную связь путем подстройки параметров, характеризующих свойства springs и частично nodes:  $l_0, k, c, m$ ;

- *текущие параметры* (параметры фазового пространства). Как правило, характеризуются быстрой динамикой изменения, для данного случая это  $x, y, \dot{x}, \dot{y}, \ddot{x}, \ddot{y}$  и  $lr$ .

Таким образом, возникает альтернативная существующей гипотеза о процессе обучения не только через пластичность синаптических соединений в

нейронных сетях, но и через изменение потенциала в гранулярных клетках. Также стоит отметить роль клеток Пуркинье как главных эфферентных нейронов мозжечковой коры – трансформация информации, полученной от параллельных волокон, и передача обработанных сигналов к глубоким мозжечковым ядрам, которые затем влияют на моторные команды.

Программирование соответствующий модели можно представить как процесс, включающий в себя как минимум четыре уровня:

– *морфологическое программирование воплощенного интеллекта* – создания пространственной кинематической схемы, описывающей параметры механических элементов и их взаимосвязь друг с другом; для рассматриваемого случая это расположение nodes, а также определение элементов, которые соединяют springs;

– *определение базовых параметров*, элементов воплощенного интеллекта, то есть определение базового состояния параметров, позволяющих иметь оптимальную для существующей среды форму и состояние; для нашего случая это параметры, характеризующие свойства springs и частично nodes:  $l_0, k, c, m$ ;

– *формирование сенсорного восприятия элементами воплощенного интеллекта* – определение локальных петель обратной связи, позволяющих изменять базовые параметры элементов воплощенного интеллекта и обеспечивающих общую динамику базового уровня;

– *создания общего центра координации, существенно повышающего глубину возможной адаптации* – создание базы гомеостатических устойчивых состояний в зависимости от внутренних потребностей или внешнего влияния и затрагивающие большое количество элементов воплощенного интеллекта.

При этом нейронная архитектура позволяет осуществить эволюционную донстройку параметров.

## **10. МОРФОЛОГИЧЕСКИЙ УРОВЕНЬ МОДЕЛИ ФИЗИЧЕСКОГО ИНТЕЛЛЕКТА**

Безусловно, структура биологических организмов гораздо сложнее, чем предложенное упрощение, а мозжечковая нейроархитектура, являясь универсальным аналоговым компьютером общего назначения, способна управлять гораздо более сложными физическими системами. Однако даже такое представ-

ление позволяет решать задачи физического моделирования комплексных объектов. Данное упрощение приводит предложенную модель к одной из интерпретаций метода конечных элементов (Finite element method) – численному методу решения дифференциальных уравнений в частных производных, широко используемых в инженерном и физическом моделировании. Метод включает дискретизацию сложной геометрии объекта на простые элементы, формирование уравнений для каждого из них и их последующую сборку в систему уравнений, которую затем решают для нахождения приближенных решений. Названный метод широко используется в анализе напряжений в конструкциях, теплопередачи, течения жидкостей, электромагнитных полей и других областях, где точное аналитическое решение сложно или невозможно получить. В свою очередь, рассматриваемый нейросетевой подход позволяет расширить данный метод и использовать его для создания динамических систем, адаптирующихся к внешней среде, реализации элементов воплощенного интеллекта, а также нахождения оптимальной конструкции через эволюционные алгоритмы.

Первый и второй уровни программирования модели – создание пространственной конструкции тела и подбор параметров, позволяющих иметь эластичную конструкцию. Данный этап требует использования инструментов, схожих по функционалу с графическими редакторами, оперирующими базовыми элементами, в данном случае это *nodes* и *springs*. Для этих целей автором написан на Python простой векторный редактор формирования каркаса с использованием *nodes* и *springs*, включающий *software engine* (программный движок), позволяющий в реальном времени моделировать деформацию конструкций под внешним воздействием, а также проводить настройку параметров [51]. На рисунке 18

представлены простейшие конструкции и процесс изменения их состояния во времени.

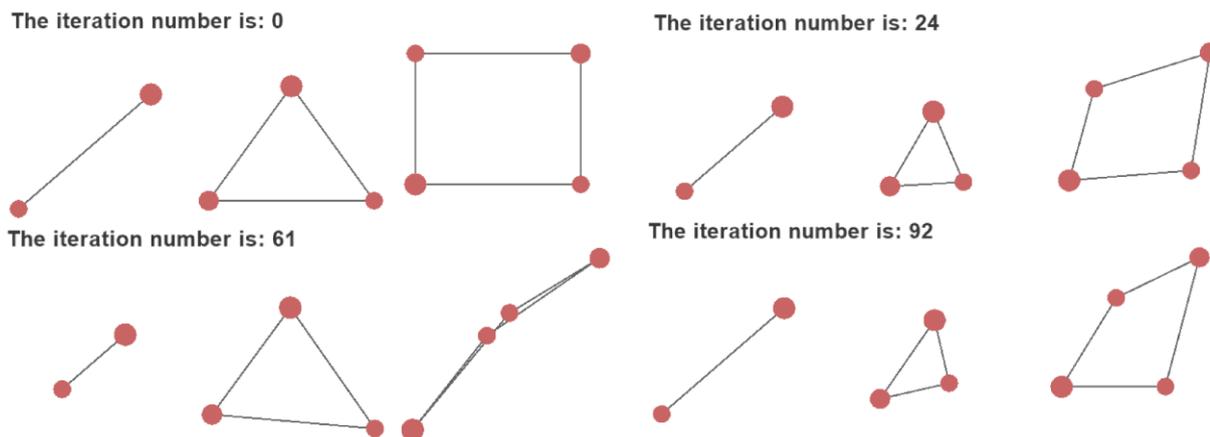


Рис. 18. 2–4-элементные базовые конструкции и их изменения во времени

Предложенная форма программирования динамических механических объектов позволяет конструировать и подвергать внешнему воздействию системы из десятков *springs* и *nodes*, то есть исследовать относительно сложные модели.

Задача формирования каркаса из *nodes* и *springs* в первом приближении совпадает с принципами конструирования ферм (лат. *firmus* – прочный), являющихся базовым разделом в строительной механике. Задача ферм схожа с биологической – оставаться геометрически неизменяемой после замены жестких узлов шарнирными в ее элементах. Для определенных нами элементов усилия растяжения – сжатия возникают только у *springs*, при этом *nodes* выполняют роль шарниров. Фермы также строятся из прямолинейных стержней, соединенных в узлах в геометрически неизменяемую систему, к которой нагрузка прикладывается только в узлах [52]. Фермы зародились в эпоху деревянного строительства, и металлические фермы являются наследниками многих инженерных находок той эпохи. Развитие железных дорог в первой половине XIX века привело к срочной потребности в мостах, способных нести тяжелые движущиеся грузы, и в новых формах зданий для вокзалов и системы обслуживания подвижного состава. Это послужило быстрому эволюционному прогрессу инженерии, появлению целого ряда новых конструктивных схем и формированию базовых конструкций

[53], таких как ферма Уоррена (Warren)  и ферма Пратта (Pratt) .

Для последней часто используется преднапряжение – сжатие раскосов. Данные фермы стали прародителями множества других мостовых конструкций, таких как фермы Bailey, Baltimore, Bollman, Bowstring, Brown, Cantilever.

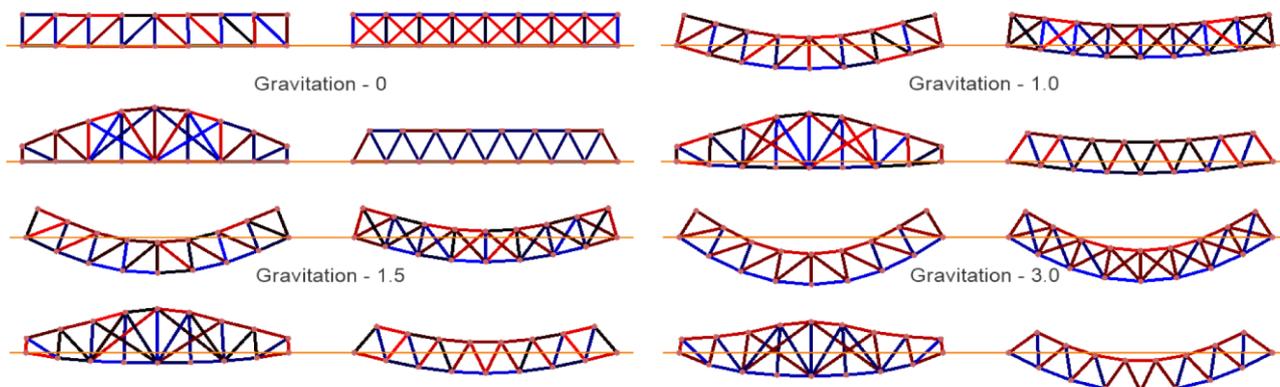


Рис. 19. Изменение формы ферм при нагрузках [54]

Используя software engine, можно запрограммировать и смоделировать их деформацию под нагрузками любых конструкции ферм, на рисунке 19 показаны четыре вида ферм в разных гравитационных полях. Красным цветом отображается сжатие, а синим – растяжение springs, а интенсивность цвета отражает величину нагрузки с нормировкой на всю конструкцию.

Особый интерес в применении предложенного алгоритма при проектировании сложных механических конструкций вызывает потенциальная возможность своего рода обучения используемой в них нейронной сетью для решения оптимизационных задач. Метод градиентного спуска и генетические алгоритмы, примененные к параметрам настройки сети, а с математической точки зрения – к коэффициентам в системе дифференциальных уравнений, позволяют найти оптимальную форму фермы или предложить более простую конструкцию.

## 11. МОДЕЛЬ ЩУПАЛЬЦА И СЕНСОРНОЕ ВОСПРИЯТИЕ

По аналогии с биологическими организмами модель должна обеспечивать сочетание трех характеристик: жесткости конструкции, сохраняющей устойчивую форму, во избежание повреждения внутренних органов; минимального

количества несущих и управляющих элементов для экономии энергии на создание и поддержание структуры; гибкости и пластичности в процессе изменения формы для движений в среде, в том числе локомоции.

Применительно к выбранному в исследовании примеру синтетического щупальца, в рамках первых двух уровней программирования модели оптимально использовать существующий конструктив щупальцев *octopus rubescens*, продукт 500 млн лет эволюции. В нем присутствуют три основных вида мышц, расположенных определенным образом (рисунок 20) [55]:

- а) *поперечные мышцы (Transverse Muscles, TM)* – окружают осевую нервную цепочку и расположены перпендикулярно к осевой линии щупальца; сокращение приводит к удлинению щупальца за счет сокращения его поперечного сечения;
- б) *продольные мышцы (Longitudinal Muscles, LM)* – проходят параллельно осевой нервной цепочке вдоль всей длины щупальца; их сокращение приводит к укорочению и изгибу щупальца, что позволяет ему сгибаться и выполнять сложные движения;
- в) *косые мышцы (Oblique Muscles, OM)* – обвивают продольные и поперечные мышцы по спирали; сокращение косых мышц приводит к скручиванию щупальца, что позволяет ему закручиваться вокруг объектов и выполнять сложные трехмерные манипуляции.

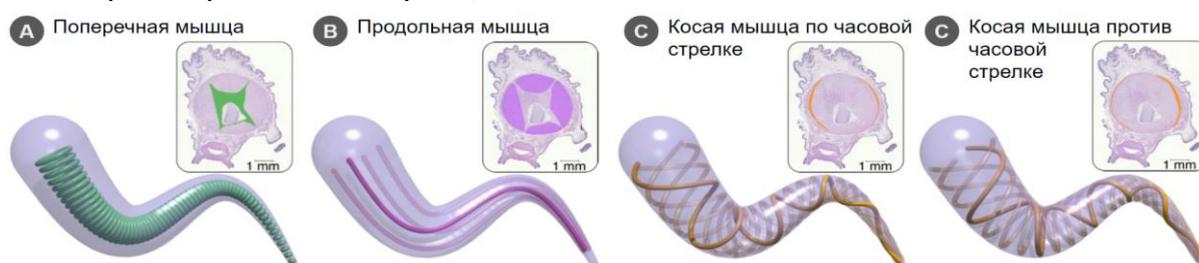


Рис. 20. Три вида мышц в щупальце *octopus rubescens*

Эти три группы мышц совместно обеспечивают осьминогу исключительную гибкость и возможность выполнения разнообразных движений и действий.

Осьминоги имеют гидростатический скелет, который использует несжимаемую жидкость внутри тела для поддержания его формы и создания структуры для движения. В отличие от твердых скелетов, таких как у позвоночных или насе-

комых, в гидростатическом скелете несущими элементами являются полости, заполненные несжимаемой жидкостью (водой), которая создает внутреннее давление, поддерживающее форму тела.

По этой причине кинетическая модель должна содержать каркас, являющийся своего рода аналогом цилиндрических полостей, заполненных жидкостью под давлением. Поиск возможных решений в редакторе приводит к следующему представлению пространственной программной модели (рисунок 21).

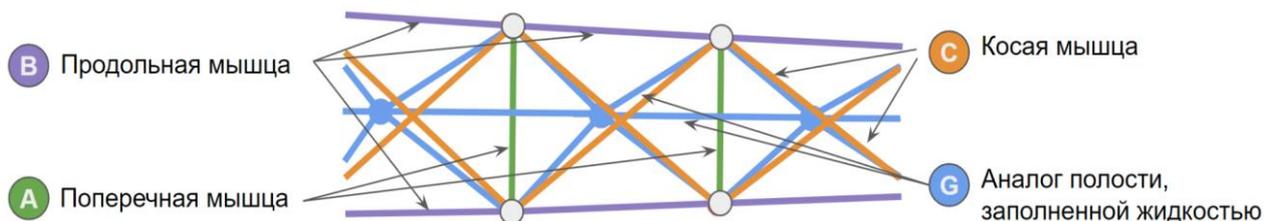


Рис. 21. Вариант аналога гидростатического скелета из nodes и springs

В полной мере возможности предлагаемой биоинспирированной нейрo-архитектуры воплощенного интеллекта раскрываются в случае реализации сенсорного восприятия на внешнее раздражение, с учетом физических особенностей реального мира.

Экзистенциальной особенностью предложенной нейросетевой архитектуры является способность проявлять свою активность с сохранением физической стабильности модели аналогично биологическим системам, поддерживающим гомеостаз. Гомеостатические сети способны адаптироваться к изменяющимся условиям и реагировать на внешние стимулы существенно гибче и эффективнее, так как подразумевают постоянное нахождение баланса между составными частями и внешней средой. В свою очередь, необходимость сенсорного восприятия для достижения требуемой реакции может находить разные формы влияния на параметры текущего гомеостаза. В процессе эволюции могло возникнуть множество видов влияния на нервную систему организма внешних раздражителей. В данной статье рассмотрена только одна из концепций – изменение параметров spring через локальную сенсорную чувствительность.

В категории параметров, формирующиеся в процессе адаптации, определен коэффициент характеризующих свободную длину springs –  $l_0$ , его изменение полностью аналогично сокращению или расслаблению мышечных волокон, которые зависят от уровней поступающих эфферентных сигналов нервной системы. Соответственно, если сопрячь значение этого параметра с направлением нормали springs и удаленностью от источника раздражения, то мы получим модель, направляющую сегменты щупальца в сторону раздражителя (рисунок 22).

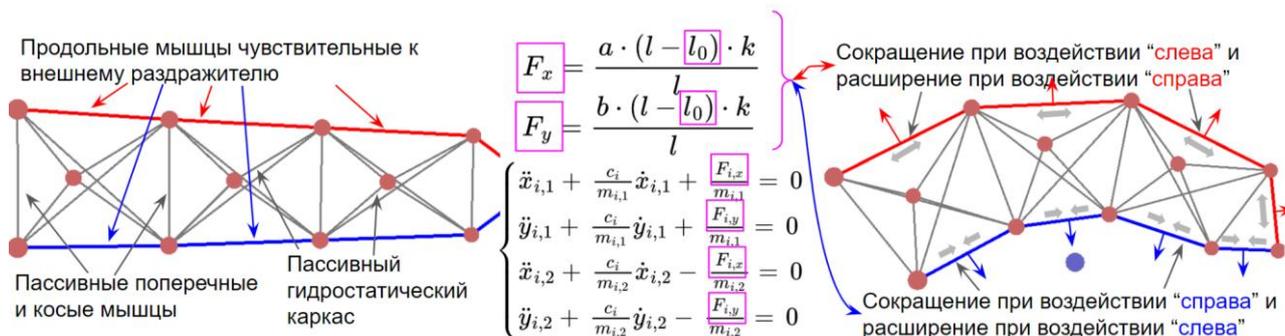


Рис. 22. Организация сенсорного восприятия springs

Стоит отметить, что модель является примером воплощенного или своего рода роевого интеллекта, у которой нет центрального аппарата, координирующего сокращения каждой мышцы, решение принимается локально, но в итоге мы получаем осмысленное общее поведение, при этом важнейшим фактором является учет физического мира и возможность синхронизации с реальным состоянием сегментов. Кроме того, здесь показано, насколько легко с эволюционной точки зрения могла сформироваться нервная система организмов, позволяющая оптимально реагировать на изменения в окружающей среде.

Ниже приведены скриншоты реагирования модели на внешний раздражитель в случае реализации в software engine рассмотренного локального сенсорного восприятия (рисунок 23). По указанной ссылке можно перейти к записи реакции модели щупальца во времени [56].

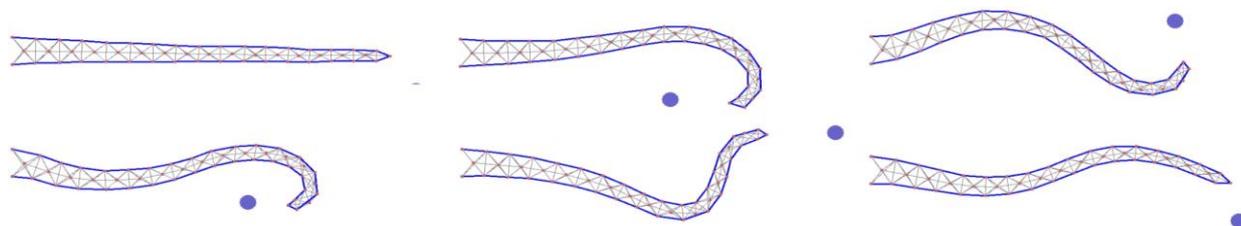


Рис. 26. Реакция нейромодели щупальца на раздражитель

В приведенном примере реализована самая простая модель сенсорного реагирования, по всей видимости, в случае наращивания сложности и дообучения нейросети можно получить гораздо более разнообразные и эффективные формы реагирования.

## **12. ЗАКЛЮЧЕНИЕ**

Изначально интеллект формировался как воплощенный в части механизма управления телом, нервная система стала биологическим аналоговым компьютером, моделирующим механические процессы в нем с учетом особенностей окружающей среды.

Безусловно, частое упоминание аналоговых вычислительных машин ведет к вопросу об их итоговой неконкурентоспособности цифровым компьютерам, оказавшим революционное влияние на технический прогресс XXI века. Однако цифровые машины, несмотря на грандиозный прогресс, колоссальную вычислительную мощность и размеры памяти, до сих пор не могут конкурировать с биологическим интеллектом человека при решении подавляющего большинства прикладных задач и повсеместно замещать его, особенно в областях физического труда и социальных задач.

Воплощенное познание – концепция, предполагающая глубокую зависимость интеллекта от особенностей физического агента, то есть, когда аспекты тела за пределами мозга играют значительную причинную или физически конститутивную роль в когнитивной обработке [57]. В то же время на определенном этапе эволюции высшие разделы нервной системы обрели способности, которые мы совсем не отождествляем с физическим телом и воплощенным познанием, но в своей основе даже мозг человека остается все той же кибернетической системой адаптации тела к окружающей среде.

Обширная нервная система развивалась в первую очередь ради необходимости справляться с координацией тела, но в итоге усложнилась настолько, что возникли другие способности, по сути, как «побочный продукт». По всей видимости, некоторые способности, например распознавание человеческих лиц, могут быть своего рода таким «побочным продуктом». Тогда как прочие, например, решение задач, являются результатом эволюционных изменений мозга, связанных с занятием организмами высокорисковых экологических ниш [58].

По всей видимости, биологические аналоговые компьютеры в силу эволюционного развития способны быстро формировать модели, поведение которых аналогично сложным физическим системам как самого организма, так и внешним объектам. Так или иначе это означает, что они способны решать системы дифференциальных уравнений в миллионы раз большей размерности, чем лучшие из последних образцов аналоговых вычислительных машин. Кроме того, как показано в рассмотренной нейроархитектуре, модели могут легко автосинхронизировать свои параметры с состоянием реального объекта, прогнозируя его поведение с небольшой, но критически важной для выживания глубиной во времени.

Важнейшей частью создания воплощенного интеллекта является подбор ключевых, долгосрочных параметров, которые по сути и формируют окончательную модель, а с математической точки зрения, нахождение оптимальных коэффициентов в системах дифференциальных уравнений в процессе обучения. При этом процесс обучения не основан на использовании классических датасетов и предполагает использование симуляторов физической реальности, что требует совершенно других инструментов программирования воплощенного интеллекта, совмещающих в себе средства создания пространственных моделей, программные движки (software engines) и симуляторы среды. Совместно они позволяют осуществлять морфологическое программирование распределенных элементов, создавать цепи сенсорного восприятия, обучать модели с использованием методов градиентного спуска, проводить первичный и последующий эволюционный подбор их базовых параметров с использованием генетических алгоритмов [19].

На этапе эволюционного обучения моделей агентов воплощенного интеллекта программные движки и симуляторы создают виртуальные среды, максимально приближенные к реальным условиям, включая сопрягаемые электромеханические системы. Это позволяет агентам с минимальными затратами приобретать базовые навыки и адаптироваться к среде до их развертывания в физическом мире. Механизмы генетического эволюционного отбора должны позволять модифицировать физические формы и структуры агентов, анализируя их

адаптивность и приемлемость скорости оптимизации параметров. По всей видимости, ключевым фактором успеха является не столько сама архитектура, сколько наличие на всех этапах инструментов симуляции должного уровня для формирования и программирования воплощенного интеллекта. По сути, эти инструменты представляют собой вычислительные аналоги биологических экологических ниш, которые требуют создания аналоговых систем иерархически более высокого порядка, чем сами модели организмов, развивающиеся в них.

### СПИСОК ЛИТЕРАТУРЫ

1. *Bubeck S. et al.* Sparks of artificial general intelligence: Early experiments with gpt-4 // arXiv preprint arXiv:2303.12712. 2023.
2. *Achiam J. et al.* Gpt-4 technical report // arXiv preprint arXiv:2303.08774. 2023.
3. *Brown T.B.* Language models are few-shot learners // arXiv preprint arXiv:2005.14165. 2020.
4. TOP 500. June 2024  
URL: <https://www.top500.org/lists/top500/2024/06/>. 2024
5. *Paul A.* OpenAI argues it is 'impossible' to train ChatGPT without copyrighted work // Popular Science. 2024.
6. *Olivera F.* Memory systems in organizations: an empirical investigation of mechanisms for knowledge collection, storage and access // Journal of Management Studies. 2000. Vol. 37, No. 6. P. 811–832.
7. *Chen H., Vondrick C., Mao C.* Selfie: Self-interpretation of large language model embeddings // arXiv preprint arXiv:2403.10949. 2024.
8. *Marks S., Tegmark M.* The geometry of truth: Emergent linear structure in large language model representations of true/false datasets // arXiv preprint arXiv:2310.06824. 2023.
9. *Abramski K. et al.* Cognitive network science reveals bias in gpt-3, gpt-3.5 turbo, and gpt-4 mirroring math anxiety in high-school students // Big Data and Cognitive Computing. 2023. Vol. 7, No. 3. P. 124.
10. *Crowder J.A. et al.* Implicit learning in artificial intelligence // Artificial Psychology: Psychological Modeling and Testing of AI Systems. 2020. P. 139–147.

11. *Seger C.A.* Implicit learning // *Psychological bulletin*. 1994. Vol. 115, No. 2. P. 163–196.
12. *Olivera F.* Memory systems in organizations: an empirical investigation of mechanisms for knowledge collection, storage and access // *Journal of Management Studies*. 2000. Vol. 37, No. 6. P. 811–832.
13. *Rajan S., Pantelyat A.* Apraxias // *eLS*. 2018. P. 1–11.
14. *Goldenberg G.* Apraxia and the parietal lobes // *Neuropsychologia*. 2009. Vol. 47, No. 6. P. 1449–1459.
15. *Gardner H.E.* *Frames of mind: The theory of multiple intelligences*. Basic books, 2011.
16. *Sitti M.* Physical intelligence as a new paradigm // *Extreme Mechanics Letters*. 2021. Vol. 46. P. 101340.
17. Федеральная служба государственной статистики (2021) Рабочая сила, занятость и безработица в России в 2021. Статистический сборник. Таблица 2.33.
18. Nvidia CEO Jensen Huang says robots are the next wave of AI 2024
19. *Duan J. et al.* A survey of embodied ai: From simulators to research tasks // *IEEE Transactions on Emerging Topics in Computational Intelligence*. 2022. Vol. 6, No. 2. P. 230–244.
20. *Wilson R.A., Foglia L.* Embodied Cognition, in «The Stanford Encyclopedia of Philosophy». 2017.
21. *Cangelosi A. et al.* Embodied intelligence // *Springer handbook of computational intelligence*. 2015. P. 697–714.
22. *Jékely G., Keijzer F., Godfrey-Smith P.* An option space for early neural evolution // *Philosophical Transactions of the Royal Society B: Biological Sciences*. 2015. Vol. 370, No. 1684. P. 20150181.
23. *Иргер И.М.* Клиника и хирургическое лечение опухолей мозжечка. М.: Медгиз, 1959.
24. *Itō M.* *The cerebellum and neural control*. Raven press, 1984.
25. *Kawato M. et al.* 50 years since the Marr, Ito, and Albus models of the cerebellum // *Neuroscience*. 2021. Vol. 462. P. 151–174.
26. *Kalinichenko S.G., Motavkin P.A.* *Cerebellar Cortex*; Institute Marine Biology FEB RAS. Moscow: Nauka, 2005.

27. *Tanaka H. et al.* The cerebro-cerebellum as a locus of forward model: a review // *Frontiers in systems neuroscience*. 2020. Vol. 14. P. 19.
28. *Miall R.C., Wolpert D.M.* Forward models for physiological motor control // *Neural networks*. 1996. Vol. 9, No. 8. P. 1265–1279.
29. *Shadmehr R., Smith M.A., Krakauer J.W.* Error correction, sensory prediction, and adaptation in motor control // *Annual review of neuroscience*. 2010. Vol. 33, No. 1. P. 89–108.
30. *Habas C. et al.* Deep cerebellar nuclei (DCN) and language // *The linguistic cerebellum*. Academic Press, 2016. P. 337–353.
31. *Kalman R.E.* A New Approach to Linear Filtering and Prediction Problems // *Journal of Basic Engineering*. 1960. Vol. 82, No. 1. P. 35.
32. *Thomas A.* Cerebellar functions [Electronic resource] / André Thomas. New York: Journal of Nervous and Mental Disease Pub. Co. 1912. P. 244, Figure 67 (Monograph series; issue 12).
33. *Herculano-Houzel S.* Coordinated scaling of cortical and cerebellar numbers of neurons // *Frontiers in neuroanatomy*. 2010. Vol. 4. P. 952.
34. *Funahashi K., Nakamura Y.* Approximation of dynamical systems by continuous time recurrent neural networks // *Neural networks*. 1993. Vol. 6, No. 6. P. 801–806.
35. *Арнольд В.И.* Обыкновенные дифференциальные уравнения. МЦНМО. 2014. С. 5.
36. *Consalez G.G. et al.* Origins, development, and compartmentation of the granule cells of the cerebellum // *Frontiers in neural circuits*. 2021. Vol. 14. P. 611841.
37. Universidad Complutense de Madrid. Cuadros originales delineados por Santiago Ramón y Cajal y pintados por Ramón Padró. Corteza cerebelosa. URL: <https://www.ucm.es/seccionbiocel/historia>
38. *De Schutter E., Vos B., Maex R.* The function of cerebellar Golgi cells revisited // *Progress in brain research*. 2000. Vol. 124. P. 81–93.
39. *D'Angelo E. et al.* The cerebellar Golgi cell and spatiotemporal organization of granular layer activity // *Frontiers in neural circuits*. 2013. Vol. 7. P. 93.
40. *Maass W.* Networks of spiking neurons: the third generation of neural network models // *Neural networks*. 1997. Vol. 10, No. 9. P. 1659–1671.

41. *Izhikevich E.M., Hoppensteadt F.* Classification of bursting mappings // International Journal of Bifurcation and Chaos. 2004. Vol. 14, No. 11. P. 3847–3854.
42. *Izhikevich E.M.* Dynamical systems in neuroscience: The geometry of excitability and bursting. MIT press, 2007.
43. *Small J.S.* The analogue alternative: The electronic analogue computer in Britain and the USA, 1930–1975. Routledge, 2013.
44. *Чукуров Н.Г.* Численный метод решения обыкновенных дифференциальных уравнений с помощью приведения их к форме Шеннона // Матем. моделирование. 2020. Т. 32, № 8. С. 3–20.
45. *Marullo C., Agliari E.* Boltzmann machines as generalized Hopfield networks: a review of recent results and outlooks // Entropy. 2020. Vol. 23, No. 1. P. 34.
46. *Nurutdinov A.R., Latypov R.K.* A Novel Artificial Neural Networks Architecture Based on Cerebellum Model // Lobachevskii Journal of Mathematics. 2023. Vol. 44, No. 2. P. 733–746.
47. *Nurutdinov A., Latypov R.* Dynamically Predicting Wi-Fi Coverage Mapping Using Bioinspired Neural Networks // 2023 International Conference on Software, Telecommunications and Computer Networks (SoftCOM). IEEE, 2023. P. 1–6.
48. *Gupta A. et al.* Embodied intelligence via learning and evolution // Nature communications. 2021. Vol. 12, No. 1. P. 5721.
49. *Zullo L. et al.* Motor control pathways in the nervous system of Octopus vulgaris arm // Journal of Comparative Physiology A. 2019. Vol. 205. P. 271–279.
50. *Ландау Л.Д., Лифшиц Е.М.* Теоретическая физика. Издание 5-е, стереотипное. М.: Физматлит. 2004. Т. I. Механика. С. 26.
51. Cerebellum cytoarchitecture for solving the equation of harmonic oscillations. URL: <https://github.com/airatn/Cerebellum-cytoarchitecture-for-solving-the-equation-of-harmonic-oscillations>
52. *Муханов К.К.* Область применения и классификации ферм // Металлические конструкции. 1976. С. 287–293.
53. *Перельмутер А.В.* Очерки по истории металлических конструкций. Издательство АСВ, 2012.
54. ferms. URL: <https://youtu.be/GVK1D8-qoIE>

55. *Chang H.S. et al.* Energy-shaping control of a muscular octopus arm moving in three dimensions // *Proceedings of the Royal Society A*. 2023. Vol. 479, No. 2270. P. 20220593.

56. *tentacle*. URL: <https://youtu.be/en6EwpKJr6U>

57. *Wilson R.A., Foglia L.* Embodied Cognition, in «The Stanford Encyclopedia of Philosophy», 2017.

58. *Godfrey-Smith P.* Other minds: The octopus, the sea, and the deep origins of consciousness. Farrar, Straus and Giroux, 2016.

---

## NEURAL NETWORK ARCHITECTURE OF EMBODIED INTELLIGENCE

**A. R. Nurutdinov**<sup>[0009-0007-0918-0879]</sup>

*PJSC "Tattelecom" (Embodied Artificial Intelligence Laboratory), Kazan, Russia*  
ayrat.nurutdinov@gmail.com

### **Abstract**

In recent years, advances in artificial intelligence (AI) and machine learning have been driven by advances in the development of large language models (LLMs) based on deep neural networks. At the same time, despite its substantial capabilities, LLMs have fundamental limitations such as spontaneous unreliability in facts and judgments; making simple errors that are dissonant with high competence in general; credulity, manifested by a willingness to accept a user's knowingly false claims as true; and lack of knowledge about events that have occurred after training has been completed.

Probably the key reason is that bioinspired intelligence learning occurs through the assimilation of implicit knowledge by an embodied form of intelligence to solve interactive real-world physical problems. Bioinspired studies of the nervous systems of organisms suggest that the cerebellum, which coordinates movement and maintains balance, is a prime candidate for uncovering methods for realizing embodied physical intelligence. Its simple repetitive structure and ability to control complex movements offer hope for the possibility of creating an analog to adaptive neural networks.

This paper explores the bioinspired architecture of the cerebellum as a form of analog computational networks capable of modeling complex real-world physical systems. As a simple example, a realization of embodied AI in the form of a multi-component model of an octopus tentacle is presented, demonstrating the potential in creating adaptive physical systems that learn and interact with the environment.

**Keywords:** *artificial neural network, large language model, implicit learning, cerebellum model, analog computing, embodied cognition, soft robotics, octopus,.*

## REFERENCES

1. *Bubeck S. et al.* Sparks of artificial general intelligence: Early experiments with gpt-4 // arXiv preprint arXiv:2303.12712. 2023.
2. *Achiam J. et al.* Gpt-4 technical report // arXiv preprint arXiv:2303.08774. 2023.
3. *Brown T.B.* Language models are few-shot learners // arXiv preprint arXiv:2005.14165. 2020.
4. TOP 500. June 2024  
URL: <https://www.top500.org/lists/top500/2024/06/>. 2024
5. *Paul A.* OpenAI argues it is 'impossible' to train ChatGPT without copyrighted work // Popular Science. 2024.
6. *Olivera F.* Memory systems in organizations: an empirical investigation of mechanisms for knowledge collection, storage and access // Journal of Management Studies. 2000. Vol. 37, No. 6. P. 811–832.
7. *Chen H., Vondrick C., Mao C.* Selfie: Self-interpretation of large language model embeddings // arXiv preprint arXiv:2403.10949. 2024.
8. *Marks S., Tegmark M.* The geometry of truth: Emergent linear structure in large language model representations of true/false datasets // arXiv preprint arXiv:2310.06824. 2023.
9. *Abramski K. et al.* Cognitive network science reveals bias in gpt-3, gpt-3.5 turbo, and gpt-4 mirroring math anxiety in high-school students // Big Data and Cognitive Computing. 2023. Vol. 7, No. 3. P. 124.
10. *Crowder J.A. et al.* Implicit learning in artificial intelligence // Artificial Psychology: Psychological Modeling and Testing of AI Systems. 2020. P. 139–147.

11. *Seger C.A.* Implicit learning // Psychological bulletin. 1994. Vol. 115, No. 2. P. 163–196.
12. *Olivera F.* Memory systems in organizations: an empirical investigation of mechanisms for knowledge collection, storage and access // Journal of Management Studies. 2000. Vol. 37, No. 6. P. 811–832.
13. *Rajan S., Pantelyat A.* Apraxias // eLS. 2018. P. 1–11.
14. *Goldenberg G.* Apraxia and the parietal lobes // Neuropsychologia. 2009. Vol. 47, No. 6. P. 1449–1459.
15. *Gardner H.E.* Frames of mind: The theory of multiple intelligences. Basic books, 2011.
16. *Sitti M.* Physical intelligence as a new paradigm // Extreme Mechanics Letters. 2021. Vol. 46. P. 101340.
17. Federal'naya sluzhba gosudarstvennoj statistiki (2021) Rabochaya sila, zanyatost' i bezrabotica v Rossii v 2021. Statisticheskij sbornik. Tablica 2.33.
18. Nvidia CEO Jensen Huang says robots are the next wave of AI 2024
19. *Duan J. et al.* A survey of embodied ai: From simulators to research tasks // IEEE Transactions on Emerging Topics in Computational Intelligence. 2022. Vol. 6, No. 2. P. 230–244.
20. *Wilson R.A., Foglia L.* Embodied Cognition, in «The Stanford Encyclopedia of Philosophy». 2017.
21. *Cangelosi A. et al.* Embodied intelligence // Springer handbook of computational intelligence. 2015. P. 697–714.
22. *Jékely G., Keijzer F., Godfrey-Smith P.* An option space for early neural evolution // Philosophical Transactions of the Royal Society B: Biological Sciences. 2015. Vol. 370, No. 1684. P. 20150181.
23. *Irger I.M.* Klinika i hirurgicheskoe lechenie opuholej mozzhechka. M.: Medgiz, 1959.
24. *Itō M.* The cerebellum and neural control. Raven press, 1984.
25. *Kawato M. et al.* 50 years since the Marr, Ito, and Albus models of the cerebellum // Neuroscience. 2021. Vol. 462. P. 151–174.
26. *Kalinichenko S.G., Motavkin P.A.* Cerebellar Cortex; Institute Marine Biology FEB RAS. Moscow: Nauka, 2005.

27. *Tanaka H. et al.* The cerebro-cerebellum as a locus of forward model: a review // *Frontiers in systems neuroscience*. 2020. Vol. 14. P. 19.
28. *Miall R.C., Wolpert D.M.* Forward models for physiological motor control // *Neural networks*. 1996. Vol. 9, No. 8. P. 1265–1279.
29. *Shadmehr R., Smith M.A., Krakauer J.W.* Error correction, sensory prediction, and adaptation in motor control // *Annual review of neuroscience*. 2010. Vol. 33, No. 1. P. 89–108.
30. *Habas C. et al.* Deep cerebellar nuclei (DCN) and language // *The linguistic cerebellum*. Academic Press, 2016. P. 337–353.
31. *Kalman R.E.* A New Approach to Linear Filtering and Prediction Problems // *Journal of Basic Engineering*. 1960. Vol. 82, No. 1. P. 35.
32. *Thomas A.* Cerebellar functions [Electronic resource] / André Thomas. New York: Journal of Nervous and Mental Disease Pub. Co. 1912. P. 244, Figure 67 (Monograph series; issue 12).
33. *Herculano-Houzel S.* Coordinated scaling of cortical and cerebellar numbers of neurons // *Frontiers in neuroanatomy*. 2010. Vol. 4. P. 952.
34. *Funahashi K., Nakamura Y.* Approximation of dynamical systems by continuous time recurrent neural networks // *Neural networks*. 1993. Vol. 6, No. 6. P. 801–806.
35. *Arnol'd V.I.* Obyknovennye differencial'nye uravneniya. M.: MCNMO, 2014. S. 5.
36. *Consalez G.G. et al.* Origins, development, and compartmentation of the granule cells of the cerebellum // *Frontiers in neural circuits*. 2021. Vol. 14. P. 611841.
37. Universidad Complutense de Madrid. Cuadros originales delineados por Santiago Ramón y Cajal y pintados por Ramón Padró. Corteza cerebelosa. URL: <https://www.ucm.es/seccionbiocel/historia>
38. *De Schutter E., Vos B., Maex R.* The function of cerebellar Golgi cells revisited // *Progress in brain research*. 2000. Vol. 124. P. 81–93.
39. *D'Angelo E. et al.* The cerebellar Golgi cell and spatiotemporal organization of granular layer activity // *Frontiers in neural circuits*. 2013. Vol. 7. P. 93.
40. *Maass W.* Networks of spiking neurons: the third generation of neural network models // *Neural networks*. 1997. Vol. 10, No. 9. P. 1659–1671.

41. *Izhikevich E.M., Hoppensteadt F.* Classification of bursting mappings // International Journal of Bifurcation and Chaos. 2004. Vol. 14, No. 11. P. 3847–3854.
42. *Izhikevich E.M.* Dynamical systems in neuroscience: The geometry of excitability and bursting. MIT press, 2007.
43. *Small J.S.* The analogue alternative: The electronic analogue computer in Britain and the USA, 1930–1975. Routledge, 2013.
44. *Chikurov N.G.* Chislennyj metod resheniya obyknovennyh differencial'nyh uravnenij s pomoshch'yu privedeniya ih k forme SHennona // Matem. Modelirovanie. 2020. T.32, № 8. S. 3–20.
45. *Marullo C., Agliari E.* Boltzmann machines as generalized Hopfield networks: a review of recent results and outlooks // Entropy. 2020. Vol. 23, No. 1. P. 34.
46. *Nurutdinov A.R., Latypov R.K.* A Novel Artificial Neural Networks Architecture Based on Cerebellum Model // Lobachevskii Journal of Mathematics. 2023. Vol. 44, No. 2. P. 733–746.
47. *Nurutdinov A., Latypov R.* Dynamically Predicting Wi-Fi Coverage Mapping Using Bioinspired Neural Networks // 2023 International Conference on Software, Telecommunications and Computer Networks (SoftCOM). IEEE, 2023. P. 1–6.
48. *Gupta A. et al.* Embodied intelligence via learning and evolution // Nature communications. 2021. Vol. 12, No. 1. P. 5721.
49. *Zullo L. et al.* Motor control pathways in the nervous system of Octopus vulgaris arm // Journal of Comparative Physiology A. 2019. Vol. 205. P. 271–279.
50. *Landau L.D., Lifshic E.M.* Teoreticheskaya fizika. Izdanie 5-e, stereotipnoe. M.: Fizmatlit, 2004. T. I. Mekhanika. S. 26.
51. Cerebellum cytoarchitecture for solving the equation of harmonic oscillations. URL: <https://github.com/airatn/Cerebellum-cytoarchitecture-for-solving-the-equation-of-harmonic-oscillations>
52. *Muhanov K.K.* Oblast' primeneniya i klassifikacii ferm // Metallicheskie konstrukcii. 1976. S. 287–293.
53. *Perel'muter A.V.* Ocherki po istorii metallicheskih konstrukcij. Izdatel'stvo ASV, 2012.
54. ferm. URL: <https://youtu.be/GVK1D8-qoE>

55. *Chang H.S. et al.* Energy-shaping control of a muscular octopus arm moving in three dimensions // *Proceedings of the Royal Society A*. 2023. Vol. 479, No. 2270. P. 20220593.

56. tentacle. URL: <https://youtu.be/en6EwpKJr6U>

57. *Wilson R.A., Foglia L.* Embodied Cognition, in «The Stanford Encyclopedia of Philosophy», 2017.

58. *Godfrey-Smith P.* Other minds: The octopus, the sea, and the deep origins of consciousness. Farrar, Straus and Giroux, 2016.

---

### СВЕДЕНИЯ ОБ АВТОРЕ



**НУРУТДИНОВ Айрат Рафкатович** – Генеральный директор ПАО «Таттелеком», руководитель лаборатории воплощенного искусственного интеллекта. Основные направления научных исследований: воплощенные формы искусственного интеллекта, архитектуры нейронных сетей, компьютерное моделирование.

**Ayrat Rafkatovich NURUTDINOV** – General Director of PJSC Tattelcom, Head of the Laboratory of embodied artificial intelligence. Main areas of research: embodied forms of artificial intelligence, neural network architectures and computer simulation.

email: [ayrat.nurutdinov@gmail.com](mailto:ayrat.nurutdinov@gmail.com)

ORCID: 0009-0007-0918-0879

*Материал поступил в редакцию 12 июня 2024 года*