

DOI: 10.7868/S2658655X26020011
УДК 612.8, 004.8

Обзорная статья

Использование систем искусственного интеллекта в современных нейроповеденческих исследованиях

К.В. Апухтин^{1,*}, А.Э. Золотова², А.О. Леуенко³, В.Н. Перфилова⁴,
А.В. Калувев^{5,6}

¹Направление «Нейробиология», Научный центр генетики и наук о жизни,
Научно-технологический университет «Сириус»,
Федеральная территория Сириус, Российская Федерация

²Институт биомедицинских систем и биотехнологий,
Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Российская Федерация

³Направление «Математическая робототехника»,
Научный центр информационных технологий и искусственного интеллекта,
Научно-технологический университет «Сириус»,
Федеральная территория Сириус, Российская Федерация

⁴Волгоградский государственный медицинский университет,
Волгоград, Российская Федерация

⁵Институт экспериментальной медицины, Национальный медицинский
исследовательский центр имени В.А. Алмазова МЗ РФ,
Санкт-Петербург, Российская Федерация

⁶Институт трансляционной биомедицины,
Санкт-Петербургский государственный университет,
Санкт-Петербург, Российская Федерация

*E-mail: kirillapuhtin@mail.ru

Аннотация. Искусственный интеллект (ИИ) активно внедряется в биомедицину для анализа больших данных. В современных исследованиях поведения ИИ активно применяется для оценки аффективных расстройств и других патологических состояний центральной нервной системы, в том числе расстройства аутистического спектра, нейродегенеративных заболеваний, неврологических расстройств и гиперактивности. Подходы, основанные на использовании ИИ, применяются также для высокопроизводительного доклинического скрининга лекарственных препаратов, фенотипирования генетических мутантов, анализа социального поведения и оценки отдельных двигательных паттернов. В последнее время ИИ находит широкое применение при анализе поведения рыб зебранию (*Danio rerio*, zebrafish), вслед за остальными модельными организмами (мышь, крыса, *C. elegans*, *Drosophila*), что особенно важно для выявления общих эволюционно-консервативных нейробиологических механизмов и фенотипов. В целом ИИ существенно

расширяет потенциал нейробиологических исследований, ускоряя доклинические исследования и разработку инновационных терапевтических подходов, а также выявляя новые, ранее неизвестные фенотипы. В работе обсуждаются накопленные данные по применению ИИ в современных нейроповеденческих исследованиях, а также оцениваются проблемы и перспективы в данной области.

Ключевые слова: искусственный интеллект, машинное обучение, мышь, крыса, с. *Elegans*, *drosophila*, нейробиология, поведение, *Danio rerio*

Финансирование. Финансирование проекта осуществлялось Министерством науки и высшего образования Российской Федерации (соглашение № 075-10-2025-017 от 27.02.2025 г.).

Соблюдение этических стандартов. Настоящая статья не содержит исследований с использованием животных или участием людей в качестве объектов.

Конфликт интересов. Авторы декларируют отсутствие конфликтов интересов, связанных с публикацией.

Вклад авторов в публикацию. КАВ, АКВ – идея статьи; АКВ, ЗАЭ, ЛАО – подготовка рукописи статьи; ЛАО, АКВ – иллюстрации; КАВ, АКВ, ЗАЭ, ЛАО, ПВН – обсуждение результатов, интерпретация данных, а также подготовка и одобрение итоговой версии рукописи.

Благодарности. Авторы выражают признательность Илье Ларину (НТУ «Сирiuс») за обсуждение работы.

Ссылка для цитирования: Апухтин К.В., Золотова А.Э., Леуенко А.О., Перфилова В.Н., Калуев А.В. Использование систем искусственного интеллекта в современных нейроповеденческих исследованиях. *Российский физиологический журнал им. И.М. Сеченова / Russian Journal of Physiology*. 2026. Т. 112. № 2. С. 363–428. <https://doi.org/10.7868/S2658655X26020011>

Using Artificial Intelligence Systems in Modern Neurobehavioral Research

K.V. Apukhtin^{1,*}, A.E. Zolotova², A.O. Leunenکو³, V.N. Perfilova⁴,
A.V. Kaluev^{5,6}

¹*Neurobiology Program, Scientific Center for Genetics and Life Sciences, Sirius University of Science and Technology, Federal Territory Sirius, Russian Federation*

²*Institute of Biomedical Systems and Biotechnologies, Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russian Federation*

³*Mathematical Robotics, Scientific Center for Information Technologies and Artificial Intelligence, Sirius University of Science and Technology, Federal Territory Sirius, Russian Federation*

⁴*Volgograd State Medical University, Volgograd, Russian Federation*

⁵*Institute of Experimental Medicine, Almazov National Medical Research Center, Ministry of Health of the Russian Federation, St. Petersburg, Russian Federation*

⁶*Institute of Translational Biomedicine, St. Petersburg State University, St. Petersburg, Russian Federation*

*E-mail: kirillapuhtin@mail.ru

Abstract. Artificial intelligence (AI) is extensively used in biomedicine for big data analyses. In neurobehavioral research, AI helps model affective disorders and other pathological conditions of the central nervous system (CNS), including autism, neurodegenerative and neurological disorders. AI-based approaches are also used for high-throughput preclinical screening of drugs, phenotyping of genetic mutants, analysis of social behavior, and assessment of individual motor patterns. Recently, AI has been applied to assess behavior of zebrafish (*Danio rerio*) and other model organisms (mice, rats, *C. elegans*, *Drosophila*), particularly important for identifying common evolutionary-conservative neurobiological mechanisms and phenotypes. Overall, AI markedly expands the potential of neurobiological research, enriching the methodological base and accelerating preclinical research and the development of innovative therapeutic approaches, as well as identifying novel, previously unknown phenotypes. Here, we discuss the mounting evidence of the application of AI in modern neurobehavioral research, and critically evaluate the existing problems, challenges and prospects in this field.

Keywords: artificial intelligence, machine learning, mice, rat, *c. Elegans*, *drosophila*, neuroscience, behavior, zebrafish

Funding. The project was funded by the Ministry of Science and Higher Education of the Russian Federation (agreement No. 075-10-2025-017 dated 27 February 2025).

Ethics declarations. This article does not contain any research involving animals or humans as subjects.

Conflict of interests. The authors declare that they have no conflicts of interest related to the publication.

Authors contribution. KAV, AKV – the idea of the article; AKV, ZAE, LAO – preparing the manuscript; LAO, AKV – preparing the illustrations; KAV, AKV, ZAE, LAO, PVN – discussing the results, interpreting the data, and preparing and approving the final version of the manuscript.

Acknowledgements. The authors would like to express their gratitude to Ilya Larin (NRU “Sirius”) for discussing the work.

For Citation: Apukhtin K.V., Zolotova A.E., Leunenkov A.O., Perfilova V.N., Kaluev A.V. Using artificial intelligence systems in modern neurobehavioral research. *Rossiiskij fiziologicheskij zhurnal im. I.M. Sechenova / Russian Journal of Physiology*. 2026;112(2):363–428. (In Russ.)
<https://doi.org/10.7868/S2658655X26020011>

ВВЕДЕНИЕ

Искусственный интеллект (ИИ) представляет собой совокупность методов и технологий, направленных на создание программных и аппаратных средств, способных решать интеллектуальные задачи, которые ранее считались доступными исключительно человеку [1]. Ключевым направлением развития ИИ является машинное обучение (МО, machine learning), основанное на построении алгоритмов, способных выявлять закономерности в данных и адаптивно модифицировать собственные параметры, самостоятельно формируя модели решения задач на основе опыта и накопленных выборок [2]. Способный анализировать огромные объемы данных и выявлять их сложные и скрытые закономерности, ИИ стал неотъемлемой частью биомедицины [3–5] и широко применяется для изучения генома и транскриптома [6, 7], клинической визуализации [8–10] и разработки персонализированных методов лечения [11]. ИИ также активно используется в нейробиологии, помогая характеризовать нейроморфологические изменения, индивидуальное или групповое поведение животных, иерархию двигательных паттернов и их динамику [12, 13] и обнаруживать новые, ранее неизвестные поведенческие фенотипы [14, 15]. В настоящей работе оценивается роль ИИ в нейробиологии поведения и рассматриваются текущие методы и перспективы их дальнейшего применения.

АРХИТЕКТУРЫ ИИ

МО использует как относительно простые алгоритмы (например, регрессионные модели, regression models), так и решающие деревья (decision trees), градиентные бустинги (gradient boosting) и глубокое обучение (deep learning), где многослойные нейронные сети автоматически выявляют иерархические представления данных [2, 16]. Ключевой технологией современного ИИ являются искусственные нейронные сети (ИНС, artificial neural networks, ANNs) – математические модели, отдаленно вдохновленные структурой нервной системы, строительными блоками которых являются перцептроны Розенблатта [17] (простейшие нейроны с пороговой активацией (см. дополнительные материалы, рис. Д1)), которые могут быть объединены

в сети. Многослойный перцептрон (MLP) представляет собой тип искусственной нейронной сети, состоящей из нескольких слоев нейронов. На практике скрытые и выходные слои MLP реализуются как полносвязные (dense) слои, то есть каждый нейрон соединен со всеми нейронами следующего слоя. Такая архитектура способна анализировать сложные нелинейные зависимости. Критическим достижением стало открытие алгоритма обратного распространения ошибки (backpropagation), позволяющего обучать веса многослойных сетей путем эффективного вычисления градиента ошибки и корректировки весов [11, 18]. В последующие десятилетия были разработаны специализированные архитектуры ИНС, оптимизированные под разные типы данных. Одним из наиболее значимых их типов являются так называемые сверточные нейронные сети (СНС, Convolutional Neural Networks, CNN) [19–21], в которых нейроны скрытых слоев организованы в виде двумерных карт признаков, а связи реализуют операцию свертки: каждый нейрон принимает сигнал не от всех нейронов предыдущего слоя, а только от небольшого локального рецептивного поля. Один обучаемый фильтр (ядро свертки) сканирует все изображение, выделяя определенный признак (например, контур или угол (рис. 1)).

Иерархическая структура слоев позволяет СНС эффективно распознавать изображения, анализируя признаки от общих к частным, и показала высокую эффективность в задачах распознавания образов и символов [19, 22], в том числе на основе обучения на миллионах изображений (рис. 1). Особенно активно СНС начали использоваться в биологии и медицине. Например, в медицинской диагностике СНС успешно используются для анализа медицинских изображений (например, для выявления наличия и точных границ опухолей мозга), демонстрируя высокие показатели точности и надежности [23], а также для обработки микроскопических изображений по микрофотографиям [24]. В свою очередь, проценты точности вычисляются как доля кадров/эпизодов, где предсказанный класс (например, кадр или фрагмент видео) совпал с ручной разметкой эксперта. Аналогичные подходы широко используются для анализа клеточных структур и нейронных сетей мозга [25–27]. СНС также применяются для автоматического анализа поведения модельных организмов, в том числе грызунов [28] и рыб зебранию (*zebrafish*, *Danio rerio*) [29].

Для обработки временных последовательностей (речи, текстов, сигналов датчиков и др.) также используются рекуррентные нейронные сети (РНС, Recurrent Neural Networks, RNN) [30, 31], в которых реализуется механизм циклической связи, позволяющий запоминать предшествующее состояние. Сеть использует два основных источника информации: текущие входные данные и собственное «внутреннее состояние» — своего рода кратковременную память, которая обновляется на каждом шаге. Эти данные преобразуются с помощью обучаемых параметров и проходят через математическую функцию, которая позволяет учитывать нелинейные зависимости между элементами последовательности. Следующим шагом развития РНС стала усовершенствованная архитектура — краткосрочная память с долгосрочным эффектом (ДКП, Long short-term memory, LSTM) [32–34]. Сети ДКП вводят ячейку памяти и специальные гейты (входа, выхода, забывания), которые регулируют поток информации, сохраняют долгосрочные зависимости и предотвращают затухание градиента. Благодаря ДКП и похожим моделям РНС впервые стали успешно применяться в задачах машинного перевода, расшифровки генетических последовательностей, анализе временных рядов (например, электроэнцефалограмм и электрокардиограмм) и др. [35].

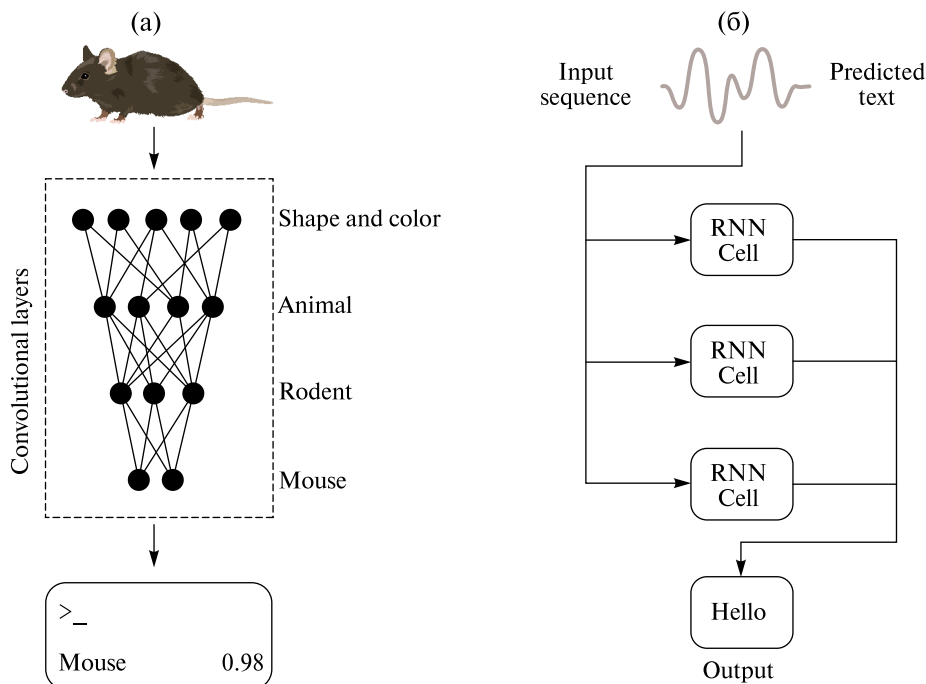


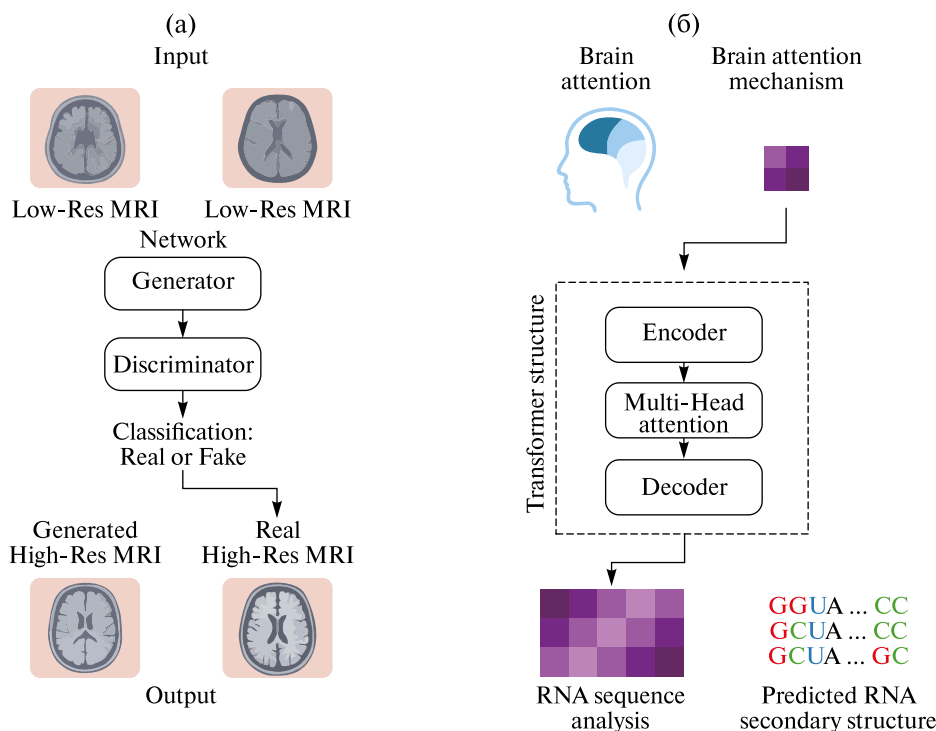
Рис. 1. Схематическое представление архитектур нейронных сетей. (а) – сверточная нейронная сеть (СНС) для задачи классификации изображений. На вход подается изображение мыши, которое последовательно проходит через несколько сверточных слоев. Первый слой выделяет базовые характеристики изображения («форма и цвет»), второй объединяет эти признаки в более общую категорию «животное», третий – конкретизирует классификацию до уровня «грызун», а четвертый слой производит окончательную идентификацию («мышь»). На выходе сеть выдает результат классификации с вероятностью 0,98, что указывает на высокую уверенность модели в своем предсказании. (б) – рекуррентная нейронная сеть (РНС), предназначенная для обработки последовательных данных. На вход подается последовательность (сигнал или текст), которая обрабатывается через цепочку связанных РНС-ячеек. Каждая ячейка получает информацию от предыдущей ячейки и передает свое состояние следующей, что позволяет сети учитывать контекст и зависимости в последовательности. На выходе сеть генерирует предсказание (например, слово «Hello»)

Fig. 1. Schematic representation of neural network architectures. (a) – A convolutional neural network (CNN) for the image classification task. The input is a mouse image, which is sequentially processed through several convolutional layers. The first layer identifies the basic characteristics of the image – “shape and color”; the second layer combines these features into a more general category “animal”; the third layer refines the classification to the “rodent” level; the fourth layer makes the final identification – “mouse”. At the output, the network produces a classification result with probability 0.98, indicating that the model is highly confident in its prediction. (b) – A recurrent neural network (RNN) designed to process sequential data. A sequence (in this case, a signal or text) is given as input, which is processed through a chain of connected RNN cells. Each cell receives information from the previous cell and transmits its state to the next, which allows the network to take into account the context and dependencies in the sequence. At the output, the network generates a prediction (e.g., the word “Hello”)

Важным достижением также стали генеративно-сопоставительные сети (ГСС, Generative Adversarial Networks, GAN) [36–38], состоящие из двух частей – генератора искусственных образцов данных (например, изображений) и дискриминатора для различения сгенерированных и реальных образцов. На каждом этапе обучения генератор настраивается таким образом, чтобы обманывать дискриминатор, а дискриминатор – чтобы точнее выявлять искусственные образцы. В процессе такого двустороннего обучения обе модели постоянно улучшаются, и в результате генератор становится способен формировать реалистичные данные, сопоставимые по качеству с настоящими. Благодаря этому принципу ГСС нашли широкое применение в различных прикладных задачах, например, для создания фотореалистичных изображений людей, объектов и сцен, которых не существует в реальности [39]. Кроме того, ГСС активно используются для улучшения разрешения изображений [40], особенно перспективно их использование в биомедицинской визуализации, где получение большого количества размеченных изображений (например, снимки с магнитно-резонансной томографии (МРТ) с вручную выделенными врачом очагами поражения мозга) зачастую затруднено ограниченным количеством данных [41]. В таких случаях ГСС позволяют синтезировать дополнительные изображения (например, МРТ) для обогащения обучающих выборок, что особенно важно при редких заболеваниях [42], улучшая качество диагностики.

Важным шагом в обработке последовательностей стала архитектура «трансформер» (transformer) [43–45], которая заменяет рекуррентность механизмом внимания (attention), чтобы модель могла учитывать взаимосвязи между элементами последовательности независимо от их положения. В отличие от РНС, обрабатывающих данные последовательно, механизм внимания позволяет анализировать весь входной контекст параллельно, что существенно повышает эффективность и точность обработки данных [43]. После этого модель формирует обновленное представление текущего элемента как взвешенную сумму всех значений, где веса определяют значимость каждой части входа [46, 47]. В результате модель учится выделять релевантную информацию для каждого элемента, автоматически фокусируясь на наиболее значимых участках входной последовательности. Таким образом, трансформеры анализируют данные как мозг, выделяя важные детали в тексте. Такой механизм уже сейчас применяется при анализе генома для предсказания уровня экспрессии генов по нуклеотидной последовательности [48, 49], а также пониманию текстов, где смысл может определяться словами, находящимися далеко друг от друга. Внимание позволяет ИИ сохранять глобальный контекст и учитывать структурные связи между элементами, что делает его одним из наиболее мощных и универсальных инструментов современного глубокого обучения [50].

В биомедицине трансформеры широко применяются для анализа клинической документации, автоматического кодирования медицинских диагнозов и извлечения информации из неструктурированных электронных медицинских записей [51, 52]. Позднее были предложены модификации трансформеров для работы с изображениями для автоматической классификации и сегментации изображений КТ, МРТ и цифровых гистологических срезов [50, 53]. Трансформеры также показали эффективность в задачах анализа многоканальных физиологических сигналов. В частности, модель PFTSleep, разработанная для классификации стадий сна на основе полноночных полисомнографических данных (включая ЭЭГ, ЭМГ, ЭКГ и дыхание), достигла точности, сравнимой с результатами специалистов, и продемонстрировала высокую устойчивость к индивидуальным вариациям [54] (рис. 2, табл. 1).



ПРИМЕНЕНИЕ СИСТЕМ ИИ В НЕЙРОМЕДИЦИНЕ

Важным приложением ИИ в нейробиологии является обработка визуальных данных, где СНС обеспечивают автоматическую сегментацию опухолевых тканей на МРТ, классификацию нейродегенеративных патологий и диагностику структурных аномалий головного мозга, что подтверждается исследованиями в области нейровизуализации [55]. С помощью СНС можно прогнозировать и оценивать риск развития деменции, предсказывать эпилептические припадки на основе показаний имплантированных датчиков и моделировать прогрессирование симптомов при болезни Паркинсона, что способствует раннему вмешательству и персонализированному планированию терапии [55]. Чаще всего СНС используются для решения задач инстанс-сегментации (instance segmentation) и семантической сегментации (semantic segmentation) изображений. Примеры применения ИИ включают классификацию гистопатологических изображений [56], сегментацию опухолей на сканах головного мозга [57] и другие задачи нейровизуализации [58].

Отдельного внимания заслуживает разработка терапевтических решений, поскольку глубокое обучение используется для проектирования биомолекул (антител, слитных белков), направленных на лечение нейроиммунных патологий, таких как рассеянный склероз, а системы адаптивной нейростимуляции в реальном времени предотвращают эпилептические приступы за счет анализа паттернов мозговой активности [57, 59, 60]. Для решения таких задач, как моделирование молекул,

Рис. 2. Схематическое представление основных архитектур нейронных сетей. (а) – генеративно-сопоставительная сеть (ГСС), применяемая для улучшения качества МРТ-изображений мозга. На ее вход подаются МРТ-снимки низкого разрешения, которые проходят через генератор – компонент сети, создающий изображения высокого разрешения. Параллельно работает дискриминатор, который анализирует сгенерированные изображения и определяет, являются ли они реальными (настоящие МРТ высокого разрешения) или поддельными (созданными генератором). Через итеративный процесс обучения генератор учится создавать все более реалистичные изображения высокого разрешения. (б) – архитектура трансформера для обработки последовательностей. В центре схематически представлен вычислительный механизм внимания (attention mechanism) – алгоритм, который позволяет модели автоматически определять степень важности каждого элемента входной последовательности при анализе конкретного фрагмента данных, аналогично тому, как исследователь сосредотачивает внимание на наиболее значимых участках нейробиологической записи. Структура трансформера включает два основных компонента. Кодировщик (энкодер) выполняет роль анализатора входных данных, преобразуя исходную последовательность нуклеотидов в богатые контекстом скрытые представления через стеки слоев с механизмом многоголового внимания (multi-head attention), которые позволяют модели одновременно учитывать взаимосвязи между всеми позициями последовательности. Декодер – функционирует как генератор выходных данных, использующий обработанные энкодером представления для пошагового создания целевой последовательности (в данном случае – предсказания вторичной структуры РНК), применяя механизм внимания как к собственным предыдущим выходам, так и к контекстным представлениям от энкодера. В данном примере трансформер используется для анализа РНК (представленных последовательностью нуклеотидов GGUA...CC и т.д.) и предсказания их вторичной структуры, что визуализируется цветовой картой справа

Fig. 2. Schematic representation of the main neural network architectures. Panel (a) shows a generative-adversarial network (GAN) applied to enhance the quality of MRI brain images. Low-resolution MRI scans are input into the network and processed by a generator, a component of the network that produces high-resolution images. In parallel, a discriminator works to analyze the generated images and determine whether they are real (true high-resolution MRI) or fake (generated by the generator). Through an iterative learning process, the generator learns to produce increasingly realistic high-resolution images. Panel (b) shows the Transformer architecture, a revolutionary model for sequence processing. The computational attention mechanism is schematically represented in the center, as an algorithm that allows the model to automatically determine the importance of each element in the input sequence when analyzing a specific data fragment, analogous to how a researcher focuses attention on the most significant segments of a neurobiological recording. The encoder acts as an analyzer of input data, transforming the original nucleotide sequence into rich, context-aware hidden representations through stacks of multi-head attention layers, which enable the model to simultaneously capture relationships between all sequence positions. The decoder functions as a generator of output data, using the encoder's processed representations to iteratively produce the target sequence (in this case, predicting RNA secondary structure), applying attention to both its own previous outputs and the contextual representations from the encoder. In this example, the Transformer is used to analyze RNA sequences (represented by nucleotide sequences such as GGUA...CC, etc.) and predict their secondary structure, which is visualized by the color map on the right

используется Natural Language Processing (NLP). РНС применяются также для анализа речевых сигналов, что открывает возможности неинвазивной диагностики болезней Альцгеймера и Паркинсона, а также аффективных и стрессорных расстройств [61–66]. Автоматический анализ коммуникативных нарушений в диалогах пациентов с неврологами с помощью ИИ может быть использован для дифференциации пациентов с нейродегенеративными расстройствами и функциональными нарушениями памяти [67, 68], существенно повышая точность клинической диагностики по речи пациентов [62]. В клинике также часто используются и другие методы ИИ, например интеллектуальный виртуальный агент, который преобразует текст в речь и автоматически ее распознает, а также ведет беседы с пользователями [69], извлекая специальные признаки из речи и текста, что позволяет более точно оценивать когнитивные функции (например, память пациентов).

Таблица 1. Краткий сравнительный анализ основных архитектур искусственного интеллекта
Table 1. Brief comparison of the main architectures of artificial intelligence

Архитектура	Структура и принцип работы	Применение в нейробиологии	Преимущества/ограничения
СНС	Многослойная структура: сверточные слои с фильтрами для выделения признаков, пулинг-слои для уменьшения размерности, полносвязные слои для классификации. Принцип: локальная связность, разделение весов, иерархическое извлечение признаков от простых (края, контуры) к сложным (объекты)	Анализ МРТ/КТ изображений, трекинг позы животных, классификация гистологических срезов, анализ микроскопических изображений нейронов	Высокая точность распознавания. Требуют больших данных, вычислительно затратны
РНС/ДКП	Рекуррентная структура с циклическими связями и внутренней памятью. ДКП содержит ячейки памяти с тремя гейтами (забывания, входа, выхода). Принцип: обработка последовательностей с сохранением контекста предыдущих элементов	Анализ ЭЭГ/ЭКГ временных рядов, распознавание речевых нарушений, анализ последовательностей поведенческих актов	Память о контексте. Существует проблема затухающего градиента (vanishing gradient problem), медленное обучение
ГСС	Состязательная архитектура из двух сетей: генератора (создает данные из шума) и дискриминатора (различает реальные и сгенерированные данные). Принцип: минимаксная игра, где генератор обучается обманывать дискриминатор, а дискриминатор – различать подделки	Синтез медицинских изображений для обучения, улучшение качества МРТ, генерация недостающих данных, создание синтетических наборов для редких патологий	Генерация высококачественных данных. Нестабильность обучения, сложность оценки качества
Трансформер	Механизм внимания для параллельной обработки с использованием энкодера для кодирования входа и декодера для генерации выхода. Принцип: параллельная обработка с вычислением весов важности для каждого элемента последовательности	Анализ ДНК/РНК последовательностей, обработка клинических текстов, предсказание структуры белков, мультимодальный анализ нейроданных	Учет дальних зависимостей, параллелизация (parallelization). Квадратичная сложность, большие требования к памяти

Методы ИИ активно применяются в обработке биоэлектрических и гемодинамических сигналов мозга, в том числе на основе ЭЭГ и магнитоэнцефалографии (МЭГ), для изучения пространственно-временных компонентов нейронной активности и их связи с мозговыми структурами [70]. Например, распространенными методами обработки данных ЭЭГ и МЭГ являются Representational Similarity Analysis (RSA) [71, 72] и пространственно более точный Representational Dissimilarity Component Analysis (Re-DisCA) [70]. ИИ также используется для анализа морфологии нейронов. Например, на основе трехмерных изображений с использованием программного обеспечения SpineTool анализ дендритных шипиков [73], играющих ключевую роль в синаптической передаче и нейропластичности [74–76], показал точность 77%, сопоставимую с таковой ручной оценки экспертами [73], и выявил, что традиционная классификация на грибовидные, тонкие и короткие шипики является грубой и что их форма и размеры представляют собой континуум, а не дискретные категории [73].

Нарушения речи – широко распространенная проблема у неврологических пациентов, и особое внимание уделяется интерфейсу мозг–компьютер (Brain-Computer Interface, BCI), который связывает нервную систему с внешними устройствами [77] и позволяет декодировать нейронную активность и использовать ее для управления устройствами или восстановления поведенческих функций [78–80] и речи [81, 82]. Декодирование речи возможно на основе нейронной активности, записанной с помощью минимально инвазивных внутричерепных электродов [83], и помогает пациентам с нарушениями речи (например, при афазии или параличе, в том числе в интракортикальном речевом BCI) [84, 85].

ПРИМЕНЕНИЕ ИИ ДЛЯ АНАЛИЗА ПОВЕДЕНИЯ

Развитие технологий ИИ привело к их применению в нейроповеденческих исследованиях, создав методы автоматизации и количественной оценки поведения животных с высоким разрешением для анализа двигательной активности, выявления сложных поведенческих паттернов и оценки реакций на фармакологические препараты [86, 87]. Исторически нейробиологи вручную оценивали поведение (например, фиксируя время, проведенное грызуном в открытом секторе лабиринта, или частоту определенных актов) [88, 89], что является затратным по времени и требует специальной подготовки исследователей. Поэтому использование обученной нейросети уменьшает использование человеческого ресурса и повышает производительность. Современные алгоритмы компьютерного зрения способны автоматически отслеживать позу животных, распознавать определенные типы поведения и открывать новые, ранее не описанные поведенческие шаблоны [89]. Методы ИИ уже сейчас вытесняют традиционные подходы, обеспечивая более быстрое определение поз, которые во времени могут быть преобразованы в кинематику, динамику и действия [14, 90–92]. Это обеспечивает объективность и высокое разрешение в анализе поведения, позволяя ставить более точные количественные задачи и выдвигать новые гипотезы.

Ключевым аспектом при анализе поведения является поза животного [93–95], регистрируемая при помощи видео (с использованием оптических меток) [90] или безмаркерно (основываясь на моделях тела, например цилиндрических, с анализом краевых характеристик) [96], методами компьютерного зрения (использующими текстуру или цвет для выделения объекта на фоне) [97, 98], а также вручную (с оценкой геометрических параметров, например длины шага или симметрии

походки, с последующей алгоритмической интерпретацией) [99–101]. Полученные данные позволяют отслеживать кинематические и динамические модели движения, а также классифицировать поведенческие акты [14, 90–92], что делает анализ позы фундаментальным инструментом в нейробиологии, например при изучении нейромоторных патологий или эффектов фармакологических воздействий.

Автоматическое отслеживание позы и траектории животных на видео позволяет восстановить координаты ключевых точек тела (суставов, конечностей и т.д.) на каждом кадре [90]. Например, алгоритм DeepLabCut [102] использует СНС для определения положения заданных пользователем точек на теле животного (мышь, крыса, рыба и дрозофилы) на видеозаписи, достигая точности, как у экспериментаторов при ручном подсчете [102]. Методология DeepLabCut основана на обучении с частичным контролем [103], и пользователю достаточно вручную разметить небольшое количество кадров, отмечая ключевые точки тела животного (лапы, голову, хвост) [90, 104], чтобы нейросеть обучилась предсказывать их положение на новых данных, причем даже в условиях низкой освещенности, при плохом качестве видео или частичном перекрытии изображения [105].

По позе возможна также классификация или сегментация поведения на определенные категории. Здесь применяются как обучаемые подходы (когда категории поведения заранее определены и алгоритм обучается их распознавать на размеченных данных), так и без обучения (когда алгоритм самостоятельно выявляет устойчивые паттерны движений без ручной разметки) [106]. К первым относятся сети, обученные различать «кормление», «груминг» и «бег» у мышей по координатам их тела [107–109], ко вторым – методы кластеризации последовательностей позы, такие как Motion Sequencing (MoSeq) и B-SOiD [110, 111], которые автоматически разбивают непрерывное поведение на дискретные повторяющиеся элементы. Это повторяющееся поведение иногда соответствует известным действиям, а иногда представляет новые паттерны, на которые исследователь ранее не обращал внимания.

Алгоритмы ИИ позволяют также идентифицировать физиологическое состояние и прогнозировать реакции животных. Например, анализ траектории плавания зебр в тесте нового аквариума с помощью глубоких сетей позволяет определить уровень ее тревожности (преимущественное нахождение у дна аквариума вместо исследования верхней части) [112]. В экспериментах на грызунах автоматический разбор тонких особенностей походки (нарушение симметрии шага, волочение лапы и т.п.) дает возможность диагностировать неврологические дефициты и отслеживать восстановление после инсульта [108]. Кроме того, предиктивные модели способны по ранним признакам поведения прогнозировать, как животное отреагирует на тот или иной стимул или лечение (например, выявлять потенциально тревожных особей до проведения теста или оценивать эффективность седативного препарата по изменениям в спонтанной активности).

Существуют многочисленные иные методы ИИ для оценки поведения модельных животных. Например, система Social LEAP Estimates Animal Poses (SLEAP) анализирует позы нескольких животных на основе глубокого обучения с высокой точностью обработки изображения [113], а система EthoVision сочетает аппаратное и программное обеспечение для анализа движения через выделение контуров и цветовых характеристик [114–118]. Автоматизированный анализ поведения с использованием ИИ обеспечивает большую глубину, охват и строгость экспериментального дизайна, изучая больше переменных и включая больше элементов управления [119].

Также возможно отслеживание не только поведения животного, но и его нейронной активности (например, при помощи кальциевой визуализации нейронов гиппокампа, полученных с помощью минископа). Для точного определения положения и позы мыши в реальном времени использовали нейронную сеть YOLO-Pose-v8, которая обучена на небольшом датасете из 375 размеченных вручную [120]. Система с высокой точностью отслеживает 7 ключевых точек на теле: нос, уши, хвост, лапы. Но для перехода от простого трекинга к классификации сложных поведенческих актов был применен YOLO-Pose-v11 с механизмом внимания. Эти данные позволили распознать три типа поведения животных: бег, сидение и груминг, при обучении на большем количестве кадров (порядка 29 тысяч) достигнув точности в 96–98% [120], таким образом напрямую соотнеся поведенческие данные с нейрональной активностью.

ПРИМЕНЕНИЕ ИИ ДЛЯ ИЗУЧЕНИЯ ОТДЕЛЬНЫХ ФОРМ ПОВЕДЕНИЯ ГРЫЗУНОВ

Важным поведенческим фенотипом грызунов является аутогруминг, участвующий в поддержании гигиены и регуляции физиологически важных процессов, включая терморегуляцию, социальную коммуникацию и избавление от паразитов [121]. Это один из наиболее часто наблюдаемых видов поведения грызунов, имеющий выраженную микроструктуру с характерной цефало-каудальной прогрессией [122, 123] под контролем базальных ганглиев, миндалина, гипоталамуса и коры [124–126]. Нарушение груминга имеет значение при моделировании нейропсихических заболеваний, например аутизма и обсессивно-компульсивного расстройства (ОКР) [123, 127–129], и ИИ предлагает новые возможности для анализа груминга в эксперименте, автоматизируя его и повышая точность [107]. С помощью компьютерного зрения и СНС анализируются видеозаписи, выделяются ключевые точки тела животного [130], а трехмерная реконструкция позволяет проанализировать амплитуду и симметрию движений [131]. Кроме того, ИИ может предсказывать эффект фармакологических агентов на продолжительность груминга [132, 133].

Оценка позы – важная задача компьютерного зрения, которая направлена на определение пространственного положения ключевых точек тела грызунов (например, головы, лап, хвоста) на изображениях или видео [108, 109]. Данная технология позволяет количественно анализировать движения и позы мышей с использованием 2D- и 3D-подходов. 2D-оценка определяет координаты ключевых точек в двухмерном пространстве. Так, модель GM-SCENet (на основе Hourglass network) достигает точности почти 98% на мышах с болезнью Паркинсона [134]. 3D-оценка восстанавливает трехмерную позу из монохромных или множественных изображений – например, используя структурные леса (structured forests) для оценки 3D-позы мышей в искаженных широкоугольных изображениях, что позволяет анализировать поведение в условиях ограниченной видимости [135]. Для трекинга позы в 3D-пространстве также используется программа SIPEC (Segmentation, Identification, Pose Estimation, and Classification), выполняющая сегментацию (выделяя объекты в видеокдрах с помощью масок и ограничивающих рамок) для идентификации животных, оценки их поз и классификации поведения [28]. Это важно при изучении социальных взаимодействий и анализа поведения в естественной среде (например, у приматов) без сложного оборудования или предварительной оценки позы. Программа DANNCE (3-Dimensional Aligned Neural Network for Computational

Ethology), преобразующая 2D-изображения с нескольких камер в 3D-данные, позволяет нейросети выстраивать пространственные взаимодействия между различными частями тела животного [136], важные для анализа как частоты актов, так и кинематического анализа движений во время груминга. DANNCE также применима для анализа изменений поведения генетически модифицированных животных [136] и способна выявлять изменения в паттернах груминга, которые могут быть связаны с дисфункцией нейронных цепей, например у мышей с мутациями в генах, связанных с аутизмом или обсессивно-компульсивном расстройством [136–138].

Система Microsoft Kinect с инфракрасной камерой глубины позволяет работать в темноте (что актуально для ночных животных) и получать 3D-данные о положении животного [139]. Анализ включает несколько этапов. На этапе предобработки для повышения качества глубинных изображений применяются гауссово размытие (для шумоподавления) и морфологические операции (для коррекции формы тела животного). Затем на очищенных изображениях выделяются контуры тела, которые используются для вычисления геометрических признаков, таких как площадь, радиус, округлость и скорость. Support Vector Machine применяется для классификации поведения и адаптации к разным условиям освещения. В свою очередь, классификация делится на 5 типов поведения (стояние, ходьба, уход за шерстью, вставание на задние лапы, вращение) с высокой точностью оценки (до 95% при ярком свете и 89% в темноте) классификации наблюдаемого поведения животных по сравнению с разметкой экспериментаторами [139].

Для трекинга поз животных также используется Anipose – открытый инструментарий (Toolkit) на Python для 3D-трекинга поз животных [140]. Он расширяет функции DeepLabCut (для 2D-трекинга) благодаря добавлению модулей для калибровки камер, фильтрации данных (удаление шумов и исправление ошибок нейросетей), триангуляции 3D-поз (преобразование 2D-точек в 3D с учетом пространственно-временной регуляризации) и визуализации [140]. Другим примером автоматизированной системы для 3D-анализа и классификации поведения грызунов с использованием камер глубины и МО является CaT-z [141], которая воспроизводит 3D-трекинг анатомических точек (нос, голова, основание хвоста, кончик хвоста) в динамических условиях, в том числе в темноте, и показывает поведенческие различия между линиями крыс Wistar Kyoto (WKY) и Wistar [141].

В качестве альтернативы видеотрекингу предлагается подход с использованием инерционных датчиков (inertial measurement unit, IMU), которые регистрируют компактные 3D-кинематические данные, не зависящие от условий окружающей среды. Представленный метод DISSeCT (Decomposing Inertial Sequences by Segmentation and Clustering in Tandem) [142] использует неконтролируемое обнаружение точек (без предварительного обучения экспертом) для сегментации данных и вероятностную кластеризацию для выделения поведения и отдельных паттернов в виде ориентировочных движений, груминга и локомоции. Этот новый метод позволяет проводить анализ поведения с минимальными вычислительными затратами и выявлять как явные, так и тонкие моторные изменения, например в модели болезни Паркинсона у мышей, где оценивается скорость, амплитуда, плавность и стабильность движений [142].

Система МО JAABA (Janelia Automatic Animal Behavior Annotator) [143] обучается по аннотациям экспертов автоматически распознавать поведение животных (например, груминг) и анализирует пространственно-временные паттерны (вместо статистических изображений) с высокой точностью (>80–90%), успешно

выявляя повышенный уровень груминга у мышей с нокаутом гена *SAPAP3* [143]. В целом данные технологии могут быть применены и к другим важным доменам поведения — в том числе тревожности и социальности. Например, система видеотслеживания оказалась эффективна в открытом поле для количественной оценки тигмотаксиса (склонности держаться возле стен) [144] как меры тревожности у мышей, а также для количественной оценки социального поведения во время взаимодействия между грызунами [145].

Как отмечалось ранее, исторически нейробиологи вручную оценивали поведение, и такой подход, основанный на наблюдении и экспертной оценке квалифицированных исследователей, заложил фундамент современных знаний о поведении животных. Например, опытный специалист может легко визуально определить, подействовал ли психотропный препарат на животное и без дополнительных измерений. В то же время методы ИИ предлагают решение интеграции интерпретации данных между специалистами путем автоматизации и формализации такого анализа. Как указано выше, ИИ способен достигать точности, сопоставимой с ручной экспертной оценкой [102, 139], при этом значительно сокращая время обработки данных и позволяя анализировать большие объемы информации, включая сложные пространственно-временные паттерны.

Таблица 2. Краткое представление основных методов, описанных при анализе поведения грызунов

Table 2. Brief presentation of the main methods described in the analysis of rodent behavior

Инструмент (архитектура, программа)	Тип (2D/3D)	Полученные данные	Точность, %	Минимальные требования	Ссылки
Anipose	3D	3D-трекинг поз животных (на основе 2D-точек)	Ошибка позиции <1,6 мм (мышь), <0,14 мм (муха), <86 мм (человек) в 90% кадров. Ошибка углов <16 в 90% кадров. После фильтрации ошибка снижается на мухах и человеке	DeepLabCut, камеры для калибровки, Python	[140]
CaT-z	3D	3D-трекинг анатомических точек животных	76,9–84,9 (в зависимости от количества классов поведения)	Камеры глубины, ПК с Qt Creator, 30 мин аннотированного видео для обучения	[141]
DeepLabCut	2D/3D	Траектории 10 ключевых точек на теле животных, кинематический анализ	Высокая (ошибка трекинга: ~5,12 пикселей для тестовых данных)	Нейросети для анализа изображений, Python	[146]

Таблица 2. Окончание

Table 2. End

Инструмент (архитектура, программа)	Тип (2D/3D)	Полученные данные	Точность, %	Минимальные требования	Ссылки
GM-SCENet	2D	2D-оценка поз мышей с болезнью Паркинсона	98%	Hourglass-сеть, видеоданные	[134]
DANNCE	3D	3D-трекинг движений, количественная оценка фаз груминга и двигательной активности	79% (3 камеры, крысы), 94% (мыши), до 97% (5+ камер)	Несколько синхронизированных камер, нейронная сеть DANNCE	[136]
Microsoft Kinect + ИИ методы (SVM, CV)	3D	3D-положение животных, геометрические признаки, классификация поведения на 5 типов	95% (яркий свет), 89% (темнота)	Kinect с ИК-камерой, ИИ-алгоритмы (SVM, CV, морфологические операции)	[139]
SIPEC (Mask R-CNN, DenseNet, Xception)	3D	3D-трекинг позы животных в условиях социальных взаимодействий	78% (приматы), 99% (мыши)	Мультикамерная система, обучение Mask R-CNN	[28]
JAABA+Mott	2D	Длительность (с), количество эпизодов, их временное распределение; распознавание элементов груминга и различение груминга от других поведенческих актов (прыжков)	83–95%	Windows 7 64-bit, Intel Xeon W3530 (4 ядра, 2,8 ГГц), 12 ГБ ОЗУ, камера Basler GigE	[133]
JAABA	3D	Исследование груминг выборки из 2457 мышей 62 различных штаммов и проведено геномное исследование ассоциаций (GWAS) для определения его генетической архитектуры	92%	96 ГБ ОЗУ, GPU, JAABA, GEMMA, Nextflow, Singularity, TensorFlow/PyTorch	[107]

ПРИМЕНЕНИЕ ИИ НА ДРУГИХ МОДЕЛЬНЫХ ОРГАНИЗМАХ

Поведение мушек дрозофил (*Drosophila melanogaster*) часто оценивается в нейробиологии, однако их малые размеры требуют применения специальных систем, способных с высокой точностью обрабатывать видеоматериалы и проводить детальный анализ поведенческих паттернов. Исследования на дрозофилах с использованием ИИ довольно распространены и включают автоматизированный мониторинг и количественный анализ поведения при кормлении [147] и действии токсических факторов [148]. Система Страх, сочетающая безмаркерный трекинг группы особей с МО, оценивает социальное взаимодействие путем фонового вычитания, кластеризации объектов, сопоставления идентичностей и выявления паттернов поведения (погоны, касания) [149] на основе адаптации DeepLabCut [117, 150] с точностью ~97% [149]. Программа FlydAI (FlyDetector AI) автоматизирует подсчет мух дикого типа и мутантов [151]. Для фенотипирования сна мух используют платформу FlyVISTA, которая за счет высокого разрешения видео фиксирует движения мухи в специальной камере, позволяя отслеживать даже мелкие детали (например, положение антенн) [152]. Трекинг позы осуществляется алгоритмом DeepLabCut (на основе ResNet-50) для 35 точек на теле [152]. FlyVISTA идентифицирует 5 категорий поведения: вытягивание хоботка (PE) как маркер глубокого сна; переключение халтер (HS) – новое поведение, которое проявляется исключительно во время сна или глубокой неактивности; корректировка положения ног; груминг, а также питание [152]. Существуют и другие паттерны для фенотипирования сна, например измерение порога пробуждения с использованием ИК-лазера, активируемого при 30-секундной неподвижности [152].

Другим популярным модельным организмом в нейробиологии является нематода *Caenorhabditis elegans* [153], для оценки поведения которой используется Multi-Worm Tracker (MWT), а для анализа нейронной активности – Targettrack на основе 3D Compact Network (3DCN) [154], одновременно отслеживающий до 120 особей. Система использует методы компьютерного зрения, включая фоновое вычитание, пороговую сегментацию и заливку областей (flood-fill), позволяя точно выделять контуры червя [155] и идентифицировать его поведенческие параметры, в том числе скорость движения, реверсии и адаптацию к повторяющимся стимулам [154]. Точность трекинга нейронов достигает 94%, сопоставима с ручной разметкой и позволяет выявлять динамику активности интернейронов в ответ на стимулы, включая запах [154]. Также МО применяется в нейротоксикологических исследованиях на нематодах с использованием микрофлюидного устройства vivoChip и автоматической сегментации тела, показавшая токсичность метилртути [156]. Данная технология с использованием МО указывает на то, что ИИ может ускорить доклинические исследования, обеспечивая высокую точность и воспроизводимость. Также разработана роботизированная система, которая обеспечивает стабильное и последовательное вращение *C. elegans* для многоракурсной флуоресцентной визуализации и количественной оценки морфологических характеристик с помощью точной 3D-реконструкции [157]. ИИ создает точные 3D-модели червя на основе множества 2D-изображений, которые получены во время вращения, а также сегментирует модельный организм (точно выделяет тело червя или эмбриона на изображениях), в свою очередь, супер-разрешение позволяет улучшить качество изображений с сохранением деталей [157].

ИСПОЛЬЗОВАНИЕ ИИ ДЛЯ ИЗУЧЕНИЯ ПОВЕДЕНИЯ ЗЕБРАДАНИО

Рыбы зебраданио – перспективная модель в нейробиологии, обладающая высокой генетической (~70%) и физиологической гомологией с человеком, эволюционно сохраненными нейротрансмиттерными системами, простотой экспериментальных манипуляций и возможностью высокопроизводительного скрининга генетических мутаций и лекарств для ЦНС [158, 159]. Прозрачность личинок и легкость размножения позволяют оптимально применять методы высокопроизводительного скрининга и визуализировать процессы мозга, например с помощью флуоресцентной микроскопии [160]. Личинки зебраданио особенно удобны для тестирования широкого спектра нейротропных веществ, влияющих на возбуждение и торможение ЦНС. Малые по размеру, они легко помещаются в многолуночные планшеты с веществами из большой библиотеки соединений, позволяя проводить эффективный скрининг поведения [161]. Алгоритмы ИИ позволяют выявлять как индивидуальные, так и групповые поведенческие особенности и новые двигательные фенотипы, которые могут быть неразличимы визуально или не определены ранее [12, 162, 163]. Таким образом, зебраданио дает возможность проводить поиск лекарственных препаратов с производительностью, недостижимой при использовании мышей и других крупных модельных организмов.

Для анализа социального поведения личинок рыб была разработана программа ZeChat, основанная на глубоком обучении. Она встраивает высокоразмерные динамические данные в двумерное пространство и распределяет полученные точки по отдельным поведенческим категориям, преобразуя записи социального поведения в числовые векторы для классификации. ZeChat эффективно идентифицирует поведение, характерное для социальных взаимодействий, используя глубокое обучение для его оценки после воздействия различных нейроактивных соединений [164]. Анализируя более 230 дофамин-, серотонин- и опиоидергических препаратов, влияющих на социальное поведение, ZeChat выявил, что прамипексол, пирибедил и 7-гидрокси-DPAT-NBv устраняют социальный дефицит в модели аутизма у зебраданио, вызванного введением вальпроата [164]. Трекер Z-LaP Tracker для анализа поведения личинок зебраданио [165] основан на системе DeepLabCut и в поведении 5-дневных личинок выявил эффекты после воздействия ингибиторов кальциневрина и ряда других препаратов. Поведенческие профили личинок были построены на основе 25 параметров, выявленных с помощью PCA и кластеризации. Кроме того, исследовалось действие фармакологических соединений, нацеленных на различные молекулярные пути, включая адренергические и дофаминовые рецепторы. Например, β 2-агонисты (сальметерол, арформотерол), α 1-антагонисты (празозин, доксазозин, тамсулозин), антагонисты рецепторов ангиотензина II (лозартан калия и ирбесартан), неселективные агонисты дофамина (бромокриптин и каберголин) и модуляторы серотонина (миртазапин, азенапин, суматриптан) были отмечены как потенциальные терапевтические мишени для лечения болезни Альцгеймера [165] путем коррекции ранних механизмов патогенеза.

Личинки зебраданио демонстрируют широкий спектр форм поведения, включая оптокинети́ческий ответ (OKR, optokinetic response), оптомоторный ответ (OMR, optomotor assay), препульсное торможение (prepulse inhibition, PPI), фотомоторную реакцию (photomotor response), сон, кормление, обучение и плавание [161, 166–173]. Анализ OKR измеряет плавные и саккадические движения глаз у частично обездвиженных личинок в ответ на визуальные стимулы. Анализ OMR оценивает

изменения направления плавания в ответ на движущиеся визуальные паттерны, что позволяет быстро и с высокой пропускной способностью оценивать сотни личинок одновременно. Аналогично РРІ считается надежной поведенческой моделью для исследования шизофрении, поскольку ее снижение является отличительной чертой этого расстройства. РМР возникает под действием светового стимула высокой интенсивности, вызывая стереотипную серию двигательного поведения у эмбрионов [166]. Хотя в настоящее время эти анализы включают в себя ручной подсчет, дальнейшая оптимизация может облегчить его применение для крупномасштабного скрининга химических соединений [161, 166, 174].

В РМР существует четкий паттерн поведения, где световой стимул вызывает сильную активацию длительностью 5–7 с, чему предшествует латентный период (1–2 с), а за ним следует рефрактерная фаза, во время которой базальная активность подавляется, и животные не реагируют на второй световой импульс [166]. Такое поведение можно представить в виде своеобразных поведенческих штрих-кодов, которые изменяются под действием психотропных препаратов. Под влиянием химических агентов появляются различные паттерны движения, например, психостимулирующий препарат изопротеренол увеличивает двигательную активность в тесте, а анксиолитик диазепам – снижает [166]. Агонист дофамина апоморфин удлиняет латентный период РМР, тогда как сердечный гликозид дигитоксигенин вызывает энергичную и продолжительную двигательную реакцию на стимул [166]. Также с помощью этой системы обнаружено, что антагонисты серотонинового рецептора 6-го типа (HTR6) вызывают седацию и парадоксальное возбуждение у личинок зебраданио [175]. В целом данная высокопроизводительная автоматизированная платформа способна проводить скрининг 5000 животных в день [166].

Как часть системной биологии хемоповеденческая феномика опирается на создание и анализ всеобъемлющих поведенческих наборов данных, и, аналогично транскриптомике и протеомике, область использует высокопроизводительные технологии для изучения того, как химические вещества влияют на поведение на системном уровне. Автоматизированный анализ поведения личинок зебраданио позволяет быстро собирать масштабные наборы данных, облегчая идентификацию препаратов со сходным механизмом действия и углубляя понимание взаимосвязи между лекарством и поведением. Благодаря объединению поведенческих данных с молекулярными и генетическими данными такой подход у зебраданио обладает высоким потенциалом в нейрофармакологии [161, 166, 174]. Например, ИИ оказывается чувствительнее наблюдателя при использовании ГНС EfficientNet-V6 в DeepLabCut [176], выявив стимулирующее воздействие галлюциногена псилоцибина на спонтанное исследовательское поведение, а также дозозависимый характер плавания личинок, в низких дозах (1 мкМ) увеличивая дистанцию и частоту движений, а в умеренных дозах (10 мкМ) усиливая исследовательское поведение с более прямолинейным плаванием по арене, указывая на снижение тревожности. ИИ также выявил тонкие изменения в координации движений и зигзагообразное поведение рыб, ранее не описанное в литературе [176].

В свою очередь, взрослые зебраданио демонстрируют сложное поведение, что делает их идеальной моделью для оценки воздействия нейротропных соединений на более высокоуровневые процессы в ЦНС, включая память, обучение и социальное поведение. Например, ИИ успешно кластеризует анксиогенные (феромон тревоги, кофеин, отмена морфина) и анксиолитические (флуоксетин, никотин, этанол, морфин) препараты [177], совпадая с данными при ручном анализе

поведения. Рыбы, получавшие анксиолитики, как правило, проводят больше времени в верхних зонах аквариума, что свидетельствует об уменьшении тревоги [177], а при действии анксиогенных препаратов рыбы остаются на дне аквариума, часто замирая, что свидетельствует о стрессе [177]. Применение ИИ на основе системы YOLOv8 также эффективно для обучения и прогнозирования профиля лекарственных препаратов [178], в том числе анксиогеника кофеина и анксиолитиков никотина и флуоксетина. ИИ продемонстрировал высокую точность различения эффектов никотина (вероятность 75%), кофеина (75%) и этанола (88%), тогда как эффекты флуоксетина ожидаемо плохо классифицировались, поскольку ранее были незнакомы ИИ [178]. Использование ИИ на архитектуре ResNet34 также показывает точность предсказания действия никотина (73 и 83%), ареколина (61 и 65%) [179] и других психоактивных веществ. Так, предсказание 3,4-метилendioксиметамфетамина (МДМА) достигло 71%, а диэтиламид лизергиновой кислоты (ЛСД) во всех дозировках неизменно прогнозировался как МДМА, что отражает их сходный серотонинергический профиль [179]. Точность прогнозирования кетамина увеличивалась при повышении доз и достигла 43% при 40 мг/л, а фенциклидин (РСР) показывал 80%-ную точность прогнозирования [179]. Другие вещества, такие как мескалин, кофеин, кокаин, псилоцибин и тетрагидроканнабиол (ТГК), в целом показали низкую точность прогнозирования – это свидетельствует о том, что ИИ было трудно четко классифицировать их эффекты [179]. Анализ различных производных N-бензил-2-фенилэтиламина (NBPEA) с помощью той же архитектуры ResNet34 [180] показал их существенное влияние на поведение зебр-данио. Например, 24h-NBCL в зависимости от концентрации (10 и 20 мг/л) снижал продолжительность пребывания рыб в верхней части аквариума, что указывает на усиление тревожного поведения. Кроме того, он способствует более активному перемещению по горизонтали по сравнению с контролем, что позволяет предположить специфические изменения двигательной активности. Анализ также выявил несколько поведенческих кластеров, в том числе анксиогенный для 24H-NBF, 24H-NBOMe и 34H-NBF, неактивный для 34H-NBVR, 34H-NBCL и 34H-NBOME, анксиогенно-галлюциногенный для 24H-NBVR, 24H-NBCL и 24H-NBOME, и анксиолитично-галлюциногенный для 34H-NBOM (F) [180].

Не менее важным при оценке воздействия нейротропных препаратов является анализ локомоции, например на базе архитектуры ResNet50 для классификации воздействия этанола на локомоторное поведение зебр-данио [181], где движения рыб визуализируются в виде XZ-проекций, а сегменты треков окрашиваются в соответствии с относительной скоростью. Анализ данных выявил три кластера концентраций этанола: низкие (0,5–1%), средние (1,5–2,5%) и высокие (3,5–4%). Временной анализ данных также показал феномен «отрезвления», так как низкие концентрации теряли эффект к 60-й минуте, средние – к 80-й, а большие сопровождалась высокой смертностью.

Сравнение с традиционными показателями локомоции (средняя скорость) выявило превосходство СНС в дифференциации паттернов и кластеризации препаратов. Это подтверждает, что сложные паттерны движения, улавливаемые СНС, не сводятся к простым показателям, а раскрывают новые аспекты поведения, в том числе их нелинейные временные зависимости и субкластеры [182]. Метод демонстрирует потенциал для анализа длительных экспериментов и сравнения веществ, но требует больших данных для устранения влияния индивидуальных различий. Метод автоматизированной кластеризации (clusterdv) [182] идентифицировал

13 дискретных типов плавательных движений у личинок зебрადанио, основанных на кинематических параметрах (амплитуда хвостовых движений, скорость, угловое ускорение). Эти паттерны, включая симметричное плавание (медленные типы 1 и 2) и повороты (J- и обычные повороты, С-старты и О-изгибы), формируют кластеры в многомерном пространстве, демонстрируя контекст-зависимое использование: например, J-повороты доминируют при ориентации на добычу, а С-старты – при избегании угроз [182].

Кроме анализа поведения, ИИ может использоваться для обнаружения и отслеживания сердцебиения обездвиженных вентрально расположенных личинок зебрადанио без прямого наблюдения за сердцем (Zebrafish Heart Rate Automatic Method, Z-HRAM) [183]. Этот метод хорошо подходит для анализа данных изображений с низким разрешением и низкой частотой. В целом сердцебиение, обнаруженное с помощью Z-HRAM, хорошо коррелирует с таковым, определенным с помощью соответствующей ЭКГ и ручного подсчета. В исследовании используются два подхода на основе ИИ. Первый подход направлен на поиск новых кардиопротекторных соединений в модели кардиомиопатии, индуцированной доксорубицином [184]. Второй подход заключается в автоматической сегментации желудочков сердца и оценке частоты сердечных сокращений у зебрადанио с применением глубоких нейронных сетей ZVSegnet и HRnet для анализа видеоданных.

Наконец, изучение поведения рыб зебраданио с использованием ИИ также возможно на макро- и микроуровнях. Например, ИИ позволяет оценивать не только поведение и позы отдельных особей, но и поведение группы особей (стайки рыб), в том числе отслеживая размер, степень поляризации и групповую динамику [184]. В то же время ИИ позволяет также оценить поведение отдельных частей тела рыб – например, ротовых движений, что позволяет с высокой точностью анализировать поведение зевания рыб [185], а также моделировать оральные дискинезии [186], что важно в контексте моделирования широкого спектра неврологических заболеваний человека, симптомами которых последние являются.

ОЦЕНКА ТРЕВОГИ, ДЕПРЕССИИ И СКРИНИНГ НЕЙРОТРОПНЫХ ПРЕПАРАТОВ

Поведенческие исследования на животных с использованием ИИ, направленные на изучение тревожных и депрессивных расстройств, играют ключевую роль в разработке эффективных препаратов [187] и помогают выявить источники и механизмы развития заболеваний [188]. Например, анализ царапин на черных мышках системой на основе СНС детектирует поведение, связанное с зудом, что упрощает скрининг соединений, которые уменьшают зуд, и позволяет осуществить изучение механизмов этого состояния [189]. Используя ИИ, система Chaimnail Sensitivity Test (CST) оценивает тактильную аллодинию – боль на основе анализа движений мышей [190]. Метод MO Drug-induced Behavioral Signature Analysis (DBSA) анализирует поведенческие данные, классифицируя поведенческие сигналы, которые связаны с действием лекарственных препаратов. Данный метод позволяет идентифицировать среди одобренных препаратов те, которые потенциально способны купировать поведенческие симптомы на животных моделях болезней человека, открывая для них новые показания к применению [171]. Применение ИИ в фармакологии расширяется до сферы сенсорного дефицита и его эффектов на поведение, что возможно при использовании алгоритмов МО для анализа слуховых реакций

ствола мозга и объединении их с поведенческими тестами для выявления вестибуло-моторных нарушений, как следствия кондуктивной потери слуха [191]. В целом наблюдается тенденция к тому, что ИИ уменьшает разрыв между доклиническими и клиническими исследованиями, улучшая трансляцию результатов с модельных организмов на человека.

ФЕНОТИПИРОВАНИЕ ОРГАНИЗМОВ С ГЕНЕТИЧЕСКИМИ МОДИФИКАЦИЯМИ

ИИ является важным инструментом для анализа изменений в поведении у животных с нокаутированными генами, что позволяет понять их роль в нейробиологических процессах и поведении модельных организмов. Например, ИИ выявляет морфологические и поведенческие различия между диким типом и многочисленными мутантными линиями *C. elegans* [192, 193] (*unc-8*, *unc-44*, *unc-116*) – моделями дисфункций моторных нейронов – путем оценки аверсии (так называемые реверсы/обратные движения и омега-повороты) у нормальных и мутантных червей. Для обнаружения ключевых точек использовалась модель EfficientNet, которая позволила определить координаты головы и хвоста в зашумленных изображениях [193], что может быть полезно в исследованиях нейродегенеративных заболеваний.

Новый инструмент для оценки двигательных нарушений у грызунов путем анализа движений головы во время плавания использует миниатюрный датчик SWIMU (Swimming With Inertial Measurement Unit) с 3D-акселерометром и 3D-гироскопом, закрепленным на голове животного [194]. ИИ используется для сенсорной фильтрации с помощью фильтра Калмана, позволяя объединить данные акселерометра и гироскопа и более точно определять ориентацию головы в пространстве [194]. Так, ИИ выявил отклонение в распределениях ускорений и угловых скоростей [194] у мутантных мышей *Gpr156*^{-/-} с дефектами развития отолитовых органов по сравнению с контрольной группой.

Наконец, ИИ помогает при анализе поведения не только животных, но и людей. В частности, при помощи новой открытой системы PhenoScore, объединившей анализ лицевых признаков с клиническими данными, удалось оценить фенотипические сходства у людей с редкими генетическими заболеваниями [195]. Данная программа имеет два модуля: лицевой анализ (который использует переобученную СНС-модель VGGFace2 для извлечения 4096 признаков из 2D-фотографий) и фенотипический анализ (который оценивает сходство по ключевым параметрам из библиотеки данных и сематическое подобие терминов, учитывая информативность в онтологии). Программой далее признаки лица и фенотипический анализ соединяются, распознав большинство из 40 синдромов с высокой точностью [195].

АНАЛИЗ МУЛЬТИМОДАЛЬНЫХ ДАННЫХ

Особенно перспективным приложением ИИ в нейробиологии является анализ мультимодальных данных, обеспечивающий целостное представление о физиологических и патологических состояниях организма. Интеграция различных типов информации – от нейровизуализации и клинических данных до геномики и метаболомики – позволяет повысить точность диагностики и прогнозирования заболеваний, а также развивать персонализированную медицину [196]. В нейробиологии глубокие нейронные сети (Deep Neural Network, DNN) также успешно

используются для дифференциации нормального когнитивного функционирования, легких нарушений, болезни Альцгеймера и неальцгеймеровских деменций (nADD) [197]. Интеграция нейровизуализации (МРТ), клинической информации (анамнез, демография, шкалы повседневной активности) и генетических маркеров с применением различных моделей (для изображений – СНС, для клинических и генетических таблиц – XGBoost и CatBoost) позволяет выявлять паттерны атрофии нейронов, а также клинические предикторы и полигенные риски нейродегенерации [197, 198] с повышением точности по сравнению с унимодальными подходами.

Примером мультимодальности может служить диагностика болезни Альцгеймера, где ни один метод визуализации не является достаточным для получения полноценной картины заболевания [199–201]. С помощью комплементарных данных возможно выявить патологические изменения на ранних стадиях, где МРТ предоставляет структурную информацию о мозге (объем гиппокампа, атрофия и т.д.), а позитронно-эмиссионная томография (ПЭТ) показывает метаболическую активность: уровень поглощения глюкозы или наличие амилоидных бляшек и др. Мультимодальные изображения мозга (МРТ и ПЭТ) предоставляют комплементарную информацию для диагностики нейродегенеративных заболеваний, однако в клинической практике такие данные часто бывают неполными из-за дороговизны ПЭТ-исследований и ограниченной доступности оборудования. В клинической практике часто отсутствует один или несколько видов исследований, поэтому ИИ позволяет не только комбинировать имеющиеся данные, но и генерировать отсутствующие модальности – это значительно расширяет возможности диагностики. Так, модель MLG-GAN + Mul-T (Multi-Level Guided Generative Adversarial Network) с помощью двухэтапной архитектуры глубокого обучения способна генерировать отсутствующие данные [202], после чего объединяются изображения с МРТ и ПЭТ.

Также ИИ продемонстрировал потенциал интеграции поведения и нейронной активности на примере модели зрительной коры мыши, эта модель может точно предсказывать нейронные ответы на произвольные визуальные стимулы [203]. Модель интегрирует три ключевых типа поведенческих данных – локомоцию (скорость бега на трекболе, регистрируемую оптическим энкодером с частотой 100 Гц), динамику зрачка (его диаметр и скорость изменения, отслеживаемая с помощью DeepLabCut), движения глаз (положение глаза и его ротация, определяемые через камеру слежения) [203] – и при помощи ДКП-сети преобразует поведенческие переменные в динамические представления состояния животного. Модель показала на 25–46% лучшую точность предсказания по сравнению с предыдущей моделью [204] при тестировании на одних и тех же данных [203], высокую для разных зон зрительной коры. Таким образом, ИИ оказался способен предсказать нейронную активность на основе поведения животного, анализировать влияние поведенческого состояния на обработку сенсорной информации, выявлять нейронные корреляты различных поведенческих состояний (возбуждение, внимание), а также создавать точные компьютерные модели поведения и его нейронных основ.

Системы ИИ также активно применяются в анализе мультиомных (геномных, транскриптомных, метаболомных) данных, объединяемых с медицинскими изображениями и данными электронной медицинской карты [205]. Например, ИИ используется для выявления нейрогенетических паттернов при болезни

Альцгеймера [206]. Особое значение в этом имеет лонгитюдная мультиомная интеграция, то есть анализ данных, полученных от одного организма во времени, что важно для изучения прогрессирования болезней, оценки ответа на терапию и выявления ранних биомаркеров. РНС особенно эффективны для анализа таких последовательностей, так как они способны сохранить временной контекст, работать с переменной длиной и обеспечивать компактность параметров [206].

Интерпретация результатов мультимодального анализа все чаще выполняется с помощью больших языковых моделей (БЯМ, Large Language Model, LLM), способных одновременно анализировать медицинские изображения и текстовую документацию. Это открывает новые возможности в диагностике, стратификации пациентов и персонализированной терапии, например, выявляя связи между микробиомом и когнитивными нарушениями [206]. Также примером успешной интеграции новых методов в медицине является использование графовых сверточных сетей (ГСС, Graph Convolutional Networks, GCN) для объединения данных нейровизуализации и геномики при прогнозировании аутизма и болезни Альцгеймера, достигая точности до 80% [206]. Таким образом, развитие стратегий интеграции и методов интерпретации – от СНС и РНС до БЯМ и ГСС – позволяет системам ИИ объединять сложные, разнородные биомедицинские данные в единую аналитическую систему.

ОБСУЖДЕНИЕ

Таким образом, применение ИИ активно расширяет возможности нейрорповеденческих исследований у различных модельных организмов (грызуны, рыбы, мухи, нематоды). Такой подход позволяет систематизировать разнородные исследования, выявить общие закономерности в современной нейробиологии, фенотипировать новых генетических организмов и добиться точности обработки поведения, сравнимой с точностью эксперта-человека. ИИ также снижает страдания животных в нейробиологических исследованиях, особенно с учетом этической нагрузки и призывов к более широкому применению методов анализа поведения человека [207, 208]. Тем не менее полная или частичная замена экспериментов на животных методами ИИ в нейробиологии пока представляется затруднительной. Для обеспечения их надежности и широкого внедрения необходима дальнейшая разработка и тщательная валидация алгоритмов на основе клинических и экспериментальных данных. Ключевым условием прогресса является тесное сотрудничество специалистов по ИИ, нейробиологов, этологов и клиницистов, что позволит интегрировать вычислительные технологии в исследовательскую и диагностическую практику. С точки зрения диагностической и мультимодальной практики с помощью ИИ стали доступны методы для диагностики заболеваний, которые трудно визуализировать – например, болезни Альцгеймера с помощью МРТ и ПЭТ [202]. Использование таких подходов позволит ускорить прогресс в области глубокого понимания и лечения заболеваний ЦНС, возможно, значительно сократив при этом зависимость от экспериментов на животных в будущем.

В области разработки лекарственных препаратов методы ИИ позволяют быстрее и надежнее находить фармакологические соединения, обладающие терапевтическими свойствами, и проводить полномасштабный скрининг препаратов, которые вызывают фенотипические эффекты, сходные с известными препаратами. Так, подобные методы уже позволили идентифицировать сотни соединений

с психофармакологической активностью, включая вещества с галоперидол-подобным эффектом [209]. На личинках рыб зебр аданио также возможно построить поведенческие штрих-коды – визуальную карту сходства лекарств, основанную на поведении [210], что дает представление о взаимосвязях между известными нейроактивными препаратами и неизученными соединениями, направляя дальнейшие исследования к новым молекулам, которые по фенотипическому профилю похожи на уже известные препараты. Данные исследования особенно важны при разработке препаратов для лечения нейродегенеративных и других заболеваний ЦНС, так как позволяют эффективно предсказывать нейротоксичность и терапевтическую эффективность лекарств еще на ранних этапах их создания.

Несомненно, существуют ограничения в применении ИИ для анализа данных с помощью компьютерного зрения. Например, при оценке поведения существенны индивидуальные поведенческие различия у лабораторных животных [179, 180], что затрудняет создание универсального контрольного фенотипа, необходимого для эффективного обучения ИИ и получение стабильных результатов в экспериментах. При этом для обучения ИИ необходимо, чтобы система обучалась на большом количестве однородных данных без индивидуальных различий. Под однородностью понимают строго фиксированные условия эксперимента – одинаковый возраст, пол, линия, температура, освещение, а также особенности записи – угол камеры, расстояние между объектами и т.д. Поведенческие особенности отдельных особей могут мешать созданию стабильной базы данных, необходимой для точной классификации. Аналогичное ограничение накладывают сложные фенотипы, специфичные для лекарственных средств. Например, МДМА и этанол могут проявлять различное действие в разных концентрациях и в различные отрезки времени, в то время как другие препараты, такие как бензодиазепины, имеют более узкий терапевтический коридор, что усложняет точность постановки эксперимента, валидность данных и однородность для обучения ИИ [179].

Также существует проблема переноса методик между лабораториями и различными видами лабораторных животных. Модели, обученные на данных одной лаборатории с определенным оборудованием и протоколами, часто демонстрируют значительное снижение производительности при применении к данным из другой лаборатории или при небольших изменениях в экспериментальной установке [211]. Это ограничивает обобщаемость и практическую применимость разработанных моделей ИИ в широком научном сообществе и требует разработки более чувствительных алгоритмов, способных адаптироваться к различным условиям сбора данных [212]. Ключевые проблемы, такие как трудность переноса алгоритмов между лабораториями, а также фундаментальные вопросы о пределах возможностей ИИ в распознавании поведения суммированы в табл. 3. Также одним из заметных ограничений является риск алгоритмической погрешности, когда модели могут непреднамеренно усиливать тонкие погрешности данных, использованных для обучения модели [213]. Например, если конкретное поведение недостаточно представлено или неточно обозначено, модель может неправильно классифицировать это поведение в будущих анализах, что приведет к искажению данных и их интерпретаций [214].

Еще одной существенной проблемой является «эффект черного ящика» многих современных моделей глубокого обучения, применяемых в нейроповеденческих исследованиях [215]. В отличие от традиционных статистических методов, сложные нейронные сети часто не позволяют понять механизмы принятия решений

Таблица 3. Отдельные открытые вопросы в области использования искусственного интеллекта (ИИ) в нейроповеденческих исследованиях**Table 3.** Selected open questions in the field of using AI in experimental neurobehavioral research

Вопросы
Возможно ли научить ИИ определять все известные вариации поведения грызунов – разные виды груминга, барберинга, гнездование, рытье нор, исследование незнакомой местности и т.д.? [129]
Возможно ли с помощью ИИ анализировать изменение поведения в ходе развития зебрэданио?
Возможно ли создание полностью автономного вивария с контролем всех параметров среды, подключенным к ИИ?
Как ИИ поможет в расшифровке социального поведения и агрессии?
Возможно ли создание системы с предсказанием патологий/действия веществ на основании поведенческих данных?
Как повысить переносимость алгоритмов анализа поведения между разными лабораториями и улучшить их обобщаемость, учитывая, что новые методы пока «плохо переносятся» между экспериментальными установками [211]
Какие подходы позволят сделать инструменты на основе ИИ для анализа поведения более доступными и удобными для неспециалистов?
Каким образом объединять разные данные – видеотрекинг, нейрофизиологические сигналы и сенсорную информацию – в единую аналитическую платформу для комплексного анализа поведения?
Какие существуют методы интеграции мультиомных данных (геномика, транскриптомика, протеомика и т.д.) с поведенческой фенотипизацией?
Как методы машинного обучения могут уменьшить влияние субъективности оценок исследователя и повысить воспроизводимость анализа поведения, чтобы улучшить трансляционную релевантность результатов?
Какие алгоритмы позволяют выявлять новые, ранее неучтенные паттерны поведения, и могут ли такие открытия повысить информативность анализа?
Какие методы машинного обучения позволяют заранее определить наиболее «характерных» животных для селекции моделей или других исследований на основе их поведения, избегая многопоколенного разведения [259]?

и выявить конкретные признаки, на которые ориентируется модель при классификации поведения [216]. Это затрудняет биологическую интерпретацию данных и может привести к ложноположительным результатам, которые сложно будет вычислить [217]. Важной проблемой становится также алгоритмическая предвзятость, способная усиливать стереотипы и приводить к искаженным выводам при некорректной классификации. Поэтому критически важным является создание сбалансированных баз данных (датасетов), охватывающих весь спектр изучаемого поведения, а также многократное их увеличение (так как непрозрачность моделей ограничивает воспроизводимость результатов). В свою очередь, это может ограничить понимание нейроповеденческих механизмов и затруднить применение

этих моделей в терапевтических или биологических областях, где обоснование предсказаний имеет решающее значение.

Путем преодоления этого барьера может стать разработка объяснимого ИИ (explainable AI), который помогает извлекать биологически значимые закономерности из данных, а не просто давать точный, но непрозрачный результат классификации или прогноза [218, 219]. Регуляторные и этические аспекты также представляют значительное препятствие для внедрения ИИ в фармакологические исследования и клиническую практику [220]. Отсутствие четких стандартов валидации алгоритмов ИИ для анализа поведенческих данных создает неопределенность в отношении надежности и воспроизводимости результатов [221–223].

Несмотря на существенные ограничения использования ИИ для определения и расшифровки сложного поведения лабораторных животных, остается нерешенной задача создания системы, которая сможет точно определять все поведенческие фенотипы, правильно их интерпретировать и выдавать прогнозы. Использование разработанных инструментов ИИ может способствовать созданию баз данных по классам соединений, а также поможет выявить сходство в поведенческих профилях как уже известных, так и новых соединений. Для уменьшения ограничений использования ИИ можно применять предобученные модели, обученные на других больших наборах данных, которые могут адаптироваться к новым данным с меньшим объемом [224]. Этот подход позволяет значительно сократить объем необходимых данных для обучения эффективных моделей классификации поведения, делая ИИ более доступным для небольших лабораторий с ограниченными ресурсами [225]. Помимо скрининга лекарств как таковых, другие области применения ИИ могут включать характеристику специфических поведенческих фенотипов у различных линий, полов, возрастных групп, моделей расстройств и других классов лекарств для ЦНС (например, антидепрессантов, галлюциногенов, нейролептиков или седативных средств), а также выявление стресс- и пол-специфических реакций, чтобы исследовать особенности влияния веществ в условиях стресса и с учетом пола, возраста и совместимости с другими препаратами. Важной перспективой является разработка систем ИИ для оптимизации дизайна экспериментов, что позволит максимизировать получаемую информацию [226]. Такие системы могут автоматически предлагать оптимальные экспериментальные параметры, выборку и статистическую мощьность на основе предыдущих данных и конкретных исследовательских вопросов.

Многообещающей перспективой является разработка мультимодальных систем ИИ, способных интегрировать и анализировать данные различных типов и уровней организации — от молекулярных и клеточных до поведенческих и системных [227]. Такие системы могут одновременно обрабатывать видеозаписи поведения, электрофизиологические сигналы, данные экспрессии генов и метаболомики, выявляя сложные взаимосвязи между молекулярными механизмами действия препаратов и их поведенческими эффектами [228, 229]. Показано, что мультимодальные модели могут повысить точность предсказания терапевтического потенциала соединений по сравнению с моделями, использующими только один тип данных [230–232]. Теперь анализы с высокой пропускной способностью позволяют использовать основанный на открытиях подход, который больше полагается на математическое моделирование и огромные объемы данных для выявления новых потенциальных лекарств. Последние достижения в области технологий автоматизированного

слежения и машинного зрения позволяют проводить непрерывный высокопроизводительный мониторинг поведения различных организмов [232].

Потенциальным развитием и интеграцией между поведенческими исследованиями и ИИ является интеграция нейроморфных исследований. Нейроморфный ИИ опирается на специализированные спайковые нейронные сети и аппаратные платформы, имитирующие головной мозг [233–235]. В контексте автоматизированного скрининга поведения такие системы способны обрабатывать сенсорные данные событийно-ориентированным, параллельным образом, обеспечивая анализ сложных паттернов активности в реальном времени [236]. Особенно перспективно развитие замкнутых (closed-loop) систем на основе нейроморфного ИИ, способных в реальном времени анализировать поведение животных и адаптивно модифицировать экспериментальные условия [237, 238]. Такие системы могут автоматически регистрировать определенные поведенческие паттерны и немедленно реагировать, например, применяя оптогенетическую стимуляцию или изменяя параметры среды [239]. Нейроморфные системы достигают масштабов, сопоставимых с мозгом небольших организмов (например, зебранию [240–242] или небольшого млекопитающего [243]), и могут быть встроены непосредственно в эксперименты в качестве носимого устройства для непрерывного мониторинга активности мозга и поведения животного [244, 245]. Однако внедрение нейроморфных технологий сталкивается с ограничениями: обучение СНС осложнено дискретной природой спайков [246–250], емкость современных чипов недостаточна для масштабируемости больших нейросетей [251–253], а отсутствие стандартизированных инструментов разработки затрудняет создание кроссплатформенных приложений [254–258].

ВЫВОДЫ

Таким образом, ИИ становится неотъемлемой частью научных исследований и клинической практики. Растущий спрос на автоматизацию с помощью ИИ в нейробиологии и нейрофармакологии означает необходимость ускорения описания работы мозга человека и возможных терапевтических стратегий для лечения нейродегенеративных и других болезней ЦНС, что может быть достигнуто при использовании такого подхода. Тем не менее остается целый ряд открытых вопросов, некоторые из которых приведены в табл. 3. Использование ИИ открывает новые перспективы в нейробиологии поведения, ускоряя доклинические исследования и разработку инновационных терапевтических подходов. При этом особенно важным становится обеспечение воспроизводимости и прозрачности методов анализа нейрофенотипов, а также стандартизации инструментов и транслируемости результатов от форматов данных до метрик оценки моделей.

СПИСОК ЛИТЕРАТУРЫ

1. Hamet P., Tremblay J. Artificial intelligence in medicine. *Metabolism: Clin. Exper.* 2017. Vol. 69s. Pp. S36–S40. <https://doi.org/10.1016/j.metabol.2017.01.011>
2. Jordan M.I., Mitchell T.M. Machine learning: trends, perspectives, and prospects. *Science.* 2015. Vol. 349. No. 6245. Pp. 255–260. <https://doi.org/10.1126/science.aaa8415>

3. Chance F.S. Interception from a dragonfly neural network model. В сб.: *Proceedings of International Conference on Neuromorphic Systems 2020*. New York: Association for Computing Machinery; 2020, 21.
4. Popuri K., Da Ma, Lei Wang et al. Using machine learning to quantify structural MRI neurodegeneration patterns of Alzheimer's disease into dementia score: independent validation on 8,834 images from ADNI, AIBL, OASIS, and MIRIAD databases. *Hum. Brain Map.* 2020. Vol. 41. No. 14. Pp. 4127–4147. <https://doi.org/10.1002/hbm.25115>
5. Jingtao Fan, Lu Fang, Jiamin Wu et al. From Brain Science to Artificial Intelligence. *Eng.* 2020. Vol. 6. No. 3. Pp. 248–252. <https://doi.org/10.1016/j.eng.2019.11.012>
6. Zou J., Huss M., Abid A. et al. A primer on deep learning in genomics. *Nat. Genet.* 2019. Vol. 51. No. 1. Pp. 12–18. <https://doi.org/10.1038/s41588-018-0295-5>
7. Uffelmann E., Qin Qin Huang, Munung N.S. et al. Genome-wide association studies. *Nat. Rev. Methods Primers.* 2021. Vol. 1. No. 1. 59. <https://doi.org/10.1038/s43586-021-00056-9>
8. Wenderott K., Krups J., Zaruchas F. et al. Effects of artificial intelligence implementation on efficiency in medical imaging – a systematic literature review and meta-analysis. *NPJ Dig. Med.* 2024. Vol. 7. No. 1. 265. <https://doi.org/10.1038/s41746-024-01248-9>
9. Khalifa M., Albadawy M. AI in diagnostic imaging: revolutionizing accuracy and efficiency. *Comput. Methods Program. Biomed. Updat.* 2024. Vol. 5. 100146. <https://doi.org/10.1016/j.cmpbup.2024.100146>
10. Potočník J., Foley S., Thomas E. Current and potential applications of artificial intelligence in medical imaging practice: a narrative review. *J. Med. Imag. Rad. Sci.* 2023. Vol. 54. No. 2. Pp. 376–385. <https://doi.org/10.1016/j.jmir.2023.03.033>
11. Sanchez-Roige S., Gray J.C., Mackillop J. et al. The genetics of human personality. *Genes Brain Behav.* 2018. Vol. 17. No. 3. e12439. <https://doi.org/10.1111/gbb.12439>
12. Brasil S., Pascoal C., Francisco R. et al. Artificial intelligence (AI) in rare diseases: is the future brighter? *Genes.* 2019. Vol. 10. No. 12. 978. <https://doi.org/10.3390/genes10120978>
13. Smeriglio P., Langard P., Querin G. et al. The identification of novel biomarkers is required to improve adult SMA patient stratification, diagnosis and treatment. *J. Pers. Med.* 2020. Vol. 10. No. 3. 75. <https://doi.org/10.3390/jpm10030075>
14. Mathis M.W., Mathis A. Deep learning tools for the measurement of animal behavior in neuroscience. *Curr. Opin. Neurobiol.* 2020. Vol. 60. Pp. 1–11. <https://doi.org/10.1016/j.conb.2019.10.008>
15. Valletta J.J., Torney C., Kings M. et al. Applications of machine learning in animal behavior studies. *Anim. Behav.* 2017. Vol. 124. Pp. 203–220. <https://doi.org/10.1016/j.anbehav.2016.12.005>
16. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature.* 2015. Vol. 521. No. 7553. Pp. 436–444. <https://doi.org/10.1038/nature14539>
17. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol. Rev.* 1958. Vol. 65. No. 6. Pp. 386–408. <https://doi.org/10.1037/h0042519>

18. Rumelhart D.E., Hinton G.E., Williams R.J. Learning representations by back-propagating errors. *Nature*. 1986. Vol. 323. No. 6088. Pp. 533–536. <https://doi.org/10.1038/323533a0>
19. LeCun Y., Bottou L., Bengio Y. et al. Gradient-based learning applied to document recognition. *Proc. IEEE*. 1998. Vol. 86. No. 11. Pp. 2278–2324. <https://doi.org/10.1109/5.726791>
20. Gu J., Wang Z., Kuen J. et al. Recent advances in convolutional neural networks. *Pattern Recognit.* 2018. Vol. 77. Pp. 354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>
21. Li Z., Liu F., Yang W. et al. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Trans. Neural Netw. Learn. Syst.* 2022. Vol. 33. No. 12. Pp. 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
22. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. *Adv. Neural Inf. Process. Syst.* 2012. Vol. 25. Pp. 1097–1105. <https://doi.org/10.1145/3065386>
23. Asiri A.A., Shaf A., Ali T. et al. Brain tumor detection and classification using fine-tuned CNN with ResNet50 and U-Net model: a study on TCGA-LGG and TCIA dataset for MRI applications. *Life*. 2023. Vol. 13. No. 7. 1449. <https://doi.org/10.3390/life13071449>
24. Huang Z.-J., Patel B., Lu W.-H. et al. Yeast cell detection using fuzzy automatic contrast enhancement (FACE) and you only look once (YOLO). *Sci. Rep.* 2023. Vol. 13. No. 1. 16222. <https://doi.org/10.1038/s41598-023-43452-9>
25. Quan T.M., Hildebrand D.G.C., Jeong W.-K. FusionNet: a deep fully residual convolutional neural network for image segmentation in connectomics. *Front. Comput. Sci.* 2021. Vol. 3. 613981. <https://doi.org/10.3389/fcomp.2021.613981>
26. Iqbal A., Sheikh A., Karayannis T. DeNeRD: high-throughput detection of neurons for brain-wide analysis with deep learning. *Sci. Rep.* 2019. Vol. 9. No. 1. 13828. <https://doi.org/10.1038/s41598-019-50137-9>
27. Schubert P.J., Dorkenwald S., Januszewski M., Jain V., Kornfeld J. Learning cellular morphology with neural networks. *Nat. Commun.* 2019. Vol. 10. No. 1. 2736. <https://doi.org/10.1038/s41467-019-10836-3>
28. Marks M., Jin Q., Sturman O. et al. Deep-learning-based identification, tracking, pose estimation and behavior classification of interacting primates and mice in complex environments. *Nat. Mach. Intell.* 2022. Vol. 4. No. 4. Pp. 331–340. <https://doi.org/10.1038/s42256-022-00477-5>
29. Barreiros M.O., Dantas D.O., Silva L.C.O. et al. Zebrafish tracking using YOLOv2 and Kalman filter. *Sci. Rep.* 2021. Vol. 11. No. 1. 3219. <https://doi.org/10.1038/s41598-021-81997-9>
30. Yu Y., Si X., Hu Ch. et al. A review of recurrent neural networks: LSTM cells and network architectures. *Neural Comput.* 2019. Vol. 31. No. 7. Pp. 1235–1270. https://doi.org/10.1162/neco_a_01199
31. Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D*. 2020. Vol. 404. 132306. <https://doi.org/10.1016/j.physd.2019.132306>

32. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Comput.* 1997. Vol. 9. No. 8. Pp. 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
33. Van Houdt G., Mosquera C., Nápoles G. A review on the long short-term memory model. *Artif. Intell. Rev.* 2020. Vol. 53. No. 8. Pp. 5929–5955. <https://doi.org/10.1007/s10462-020-09838-1>
34. Staudemeyer R.C., Morris E.R. Understanding LSTM – a tutorial into long short-term memory recurrent neural networks. *arXiv.* 1909.09586. <https://doi.org/10.48550/arXiv.1909.09586>
35. Lipton Z.C., Kale D.C., Elkan C. et al. Learning to diagnose with LSTM recurrent neural networks. *arXiv.* 1511.03677. <https://doi.org/10.48550/arXiv.1511.03677>
36. Goodfellow I.J., Pouget-Abadie J., Mirza M. et al. Generative adversarial nets. В сб.: *Advances in Neural Information Processing Systems 27: 28th Annual Conference on Neural Information Processing Systems 2014 (December 8–13, 2014, Montreal, Canada)*. Curran Associates; 2015. Pp. 2672–2680.
37. Wang Z., She Q., Ward T.E. Generative adversarial networks in computer vision: a survey and taxonomy. *ACM Comput. Surv.* 2021. Vol. 54. No. 2. 37. <https://doi.org/10.1145/3439723>
38. Gui J., Sun Zh., Wen Y. et al. A review on generative adversarial networks: algorithms, theory, and applications. *IEEE Trans. Knowl. Data Eng.* 2023. Vol. 35. No. 4. Pp. 3313–3332. <https://doi.org/10.1109/TKDE.2021.3130191>
39. Karras T., Laine S., Aila T. A style-based generator architecture for generative adversarial networks. *IEEE Trans. Pattern Anal. Mach. Intell.* 2020. Vol. 43. No. 12. Pp. 4217–4228. <https://doi.org/10.1109/TPAMI.2020.2970919>
40. Ledig C., Theis L., Huszar F. et al. Photo-realistic single image super-resolution using a generative adversarial network. В сб.: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017*. IEEE Computer Society; 2017. Pp. 4681–4690.
41. Yi X., Walia E., Babyn P. Generative adversarial network in medical imaging: a review. *Med. Image Analysis.* 2019. Vol. 58. 101552. <https://doi.org/10.1016/j.media.2019.101552>
42. Pradeepkumar J., Anandakumar M., Kugathasan V. et al. Toward interpretable sleep stage classification using cross-modal transformers. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2024. Vol. 32. Pp. 2874–2885. <https://doi.org/10.1109/TNSRE.2024.3438610>
43. Vaswani A., Shazeer N., Parmar N. et al. Attention is all you need. *Adv. Neural Inf. Process. Syst.* 2017. Vol. 30. Pp. 5999–6009.
44. Lin T., Wang Y., Liu X. et al. A survey of transformers. *AI Open.* 2022. Vol. 3. Pp. 111–113. <https://doi.org/10.1016/j.aiopen.2022.10.001>
45. Tay Y., Dehghani M., Rao J. et al. Scale efficiently: insights from pre-training and fine-tuning transformers. *arXiv.* 2109.10686. <https://doi.org/10.48550/arXiv.2109.10686>
46. Bahdanau D., Cho K., Bengio Y. Neural machine translation by jointly learning to align and translate. *Int. Conf. Learn. Represent. (ICLR)*. 2015. <https://doi.org/10.48550/arXiv.1409.0473>

47. Luong M.T., Pham H., Manning C. Effective approaches to attention-based neural machine translation. В сб.: *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*. Association for Computational Linguistics, 2015. Pp. 1412–1421. <https://doi.org/10.18653/v1/D15-1166>
48. Ji Y., Zhou Zh., Liu H. et al. DNABERT: pre-trained bidirectional encoder representations from transformers model for DNA-language in genome. *Bioinformatics*. 2021. Vol. 37. No. 15. Pp. 2112–2120. <https://doi.org/10.1093/bioinformatics/btab083>
49. Avsec Ž., Agarwal V., Visentin D. et al. Effective gene expression prediction from sequence by integrating long-range interactions. *Nat. Met.* 2021. Vol. 18. No. 10. Pp. 1196–1203. <https://doi.org/10.1038/s41592-021-01252-x>
50. Shamshad F., Khan S., Zamir S.W. et al. Transformers in medical imaging: a survey. *Med. Image Analysis*. 2023. Vol. 88. 102802. <https://doi.org/10.1016/j.media.2023.102802>
51. Lee J., Yoon W., Kim S. et al. BioBERT: a pre-trained biomedical language representation model for biomedical text mining. *Bioinformatics*. 2019. Vol. 36. No. 4. Pp. 1234–1240. <https://doi.org/10.1093/bioinformatics/btz682>
52. Alsentzer E., Murphy J., Boag W. et al. Publicly available clinical BERT embeddings. В сб.: *Proceedings of the 2nd Clinical Natural Language Processing Workshop*. Minneapolis: Association for Computational Linguistics, 2019. Pp. 72–78.
53. Dosovitskiy A., Beyer L., Kolesnikov A. et al. An image is worth 16×16 words: transformers for image recognition at scale. *Int. Conf. Learn. Represent. (ICLR)*. 2021. <https://doi.org/10.48550/arXiv.2010.11929>
54. Fox B., Jiang J., Wickramaratne S. et al. A foundational transformer leveraging full-night, multichannel sleep study data accurately classifies sleep stages. *Sleep*. 2025. Vol. 48. No. 8. zsaf061. <https://doi.org/10.1093/sleep/zsaf061>
55. Kellmeyer P. Artificial intelligence in basic and clinical neuroscience: opportunities and ethical challenges. *Neuroforum*. 2019. Vol. 25. No. 4. Pp. 241–250. <https://doi.org/10.1515/nf-2019-0018>
56. Litjens G., Sánchez C.I., Timofeeva N. et al. Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. *Sci. Rep.* 2016. Vol. 6. No. 1. 26286. <https://doi.org/10.1038/srep26286>
57. Pereira S., Pinto A., Alves V. et al. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Trans. Med. Imaging*. 2016. Vol. 35. No. 5. Pp. 1240–1251. <https://doi.org/10.1109/TMI.2016.2538465>
58. Akkus Z., Galimzianova A., Hoogi A. et al. Deep learning for brain MRI segmentation: state of the art and future directions. *J. Digit. Imag.* 2017. Vol. 30. Pp. 449–459. <https://doi.org/10.1007/s10278-017-9983-4>
59. Gawehn E., Hiss J.A., Schneider G. Deep learning in drug discovery. *Mol. Inf.* 2016. Vol. 35. No. 1. Pp. 3–14. <https://doi.org/10.1002/minf.201501008>
60. Hadar P.N., Zelmann R., Salami P. et al. The neurostimulationist will see you now: prescribing direct electrical stimulation therapies for the human brain in epilepsy and beyond. *Front. Hum. Neurosci.* 2024. Vol. 18. 1439541. <https://doi.org/10.3389/fnhum.2024.1439541>

61. Li Zh., Jilin H., Zhiping H. Screening and diagnosis of chronic pharyngitis based on deep learning. *Int. J. Environ. Res. Public Health*. 2019. Vol. 16. No. 10. 1688. <https://doi.org/10.3390/ijerph16101688>
62. Gupta N.S., Kumar P. Perspective of artificial intelligence in healthcare data management: a journey towards precision medicine. *Comput. Biol. Med.* 2023. Vol. 162. 107051. <https://doi.org/10.1016/j.combiomed.2023.107051>
63. Zhan A., Mohan S., Tarolli C. et al. Using smartphones and machine learning to quantify Parkinson disease severity: the mobile Parkinson disease score. *JAMA Neurol.* 2018. Vol. 75. No. 7. Pp. 876–880. <https://doi.org/10.1001/jamaneurol.2018.0809>
64. Dias R., Torkamani A. Artificial intelligence in clinical and genomic diagnostics. *Genome Med.* 2019. Vol. 11. No. 1. 70. <https://doi.org/10.1186/s13073-019-0689-8>
65. Marmar C.R., Brown A.D., Meng Qian et al. Speech-based markers for posttraumatic stress disorder in US veterans. *Depress. Anxiety*. 2019. Vol. 36. No. 7. Pp. 607–616. <https://doi.org/10.1002/da.22890>
66. Maor E., Sara J.D., Orbelo D.M. et al. Voice signal characteristics are independently associated with coronary artery disease. *Mayo Clin. Proc.* 2018. Vol. 93. No. 7. Pp. 840–847. <https://doi.org/10.1016/j.mayocp.2017.12.025>
67. Luz S., Haider F., de la Fuente García S. et al. Alzheimer's dementia recognition through spontaneous speech. *Front. Comput. Sci.* 2021. Vol. 3. 780169. <https://doi.org/10.3389/fcomp.2021.780169>
68. McWhirter L., Ritchie C., Stone J. et al. Functional cognitive disorders: a systematic review. *Lancet Psychiatry*. 2020. Vol. 7. No. 2. Pp. 191–207. [https://doi.org/10.1016/S2215-0366\(19\)30405-5](https://doi.org/10.1016/S2215-0366(19)30405-5)
69. Mirheidari B., Blackburn D., O'Malley R. et al. Computational cognitive assessment: investigating the use of an intelligent virtual agent for the detection of early signs of dementia. В сб.: *2019 IEEE International Conference on Acoustics, Speech, and Signal Processing: Proceedings*. The Institute of Electrical and Electronics Engineers, Inc., 2019. Pp. 2732–2736. <https://doi.org/10.1109/ICASSP.2019.8682423>
70. Ossadtchi A., Semenov I., Zhuravleva A. et al. Representational dissimilarity component analysis (ReDisCA). *NeuroImage*. 2024. Vol. 301. 120868. <https://doi.org/10.1016/j.neuroimage.2024.120868>
71. Kriegeskorte N., Wei X.-X. Neural tuning and representational geometry. *Nat. Rev. Neurosci.* 2021. Vol. 22. No. 11. Pp. 703–718. <https://doi.org/10.1038/s41583-021-00502-3>
72. Goldstein A., Grinstein-Dabush A., Schain M. et al. Alignment of brain embeddings and artificial contextual embeddings in natural language points to common geometric patterns. *Nat. Commun.* 2024. Vol. 15. No. 1. 2768. <https://doi.org/10.1038/s41467-024-46631-y>
73. Pchitskaya E., Vasiliev P., Smirnova D. et al. SpineTool is an open-source software for analysis of morphology of dendritic spines. *Sci. Rep.* 2023. Vol. 13. No. 1. 10561. <https://doi.org/10.1038/s41598-023-37406-4>
74. Segal M. Dendritic spines: morphological building blocks of memory. *Neurobiol. Learn. Mem.* 2017. Vol. 138. Pp. 3–9. <https://doi.org/10.1016/j.nlm.2016.06.007>

75. Chidambaram S.B., Rathipriya A., Bolla S.R. et al. Dendritic spines: revisiting the physiological role. *Prog. Neuropsychopharmacol. Biol. Psychiatry*. 2019. Vol. 92. Pp. 161–193. <https://doi.org/10.1016/j.pnpbp.2019.01.005>
76. Stein I.S., Zito K. Dendritic spine elimination: molecular mechanisms and implications. *Neuroscientist*. 2019. Vol. 25. No. 1. Pp. 27–47. <https://doi.org/10.1177/1073858418769644>
77. Hatsopoulos N.G., Donoghue J.P. The science of neural interface systems. *Annu. Rev. Neurosci.* 2009. Vol. 32. No. 1. Pp. 249–266. <https://doi.org/10.1146/annurev.neuro.051508.135241>
78. Mak J.N., Wolpaw J.R. Clinical applications of brain-computer interfaces: current state and future prospects. *IEEE Rev. Biomed. Eng.* 2009. Vol. 2. Pp. 187–199. <https://doi.org/10.1109/RBME.2009.2035356>
79. Al-Nafjan A., Hosny M., Al-Ohali Y. et al. Review and classification of emotion recognition based on EEG brain-computer interface system research: a systematic review. *Appl. Sci.* 2017. Vol. 7. No. 12. 1239. <https://doi.org/10.3390/app7121239>
80. Abiri R., Borhani S., Sellers E.W. et al. A comprehensive review of EEG-based brain-computer interface paradigms. *J. Neural Eng.* 2019. Vol. 16. No. 1. 011001. <https://doi.org/10.1088/1741-2552/aaf12e>
81. Angrick M., Ottenhoff M.C., Diener L. et al. Real-time synthesis of imagined speech processes from minimally invasive recordings of neural activity. *Commun. Biol.* 2021. Vol. 4. No. 1. 1055. <https://doi.org/10.1038/s42003-021-02578-0>
82. Petrosyan A., Voskoboynikov A., Slioussar N. et al. Compact and interpretable architecture for speech decoding from iEEG. *Int. J. Psychophysiol.* 2021. Vol. 168. S195. <https://doi.org/10.1109/CNN53494.2021.9580381>
83. Petrosyan A., Voskoboynikov A., Sukhinin D. et al. Speech decoding from a small set of spatially segregated minimally invasive intracranial EEG electrodes with a compact and interpretable neural network. *J. Neural Eng.* 2022. Vol. 19. No. 6. 066016. <https://doi.org/10.1088/1741-2552/aca1e1>
84. Willett F.R., Kunz E.M., Fan C. et al. A high-performance speech neuroprosthesis. *Nature*. 2023. Vol. 620. No. 7976. Pp. 1031–1036. <https://doi.org/10.1038/s41586-023-06377-x>
85. Silva A.B., Liu J.R., Metzger S.L. et al. A bilingual speech neuroprosthesis driven by cortical articulatory representations shared between languages. *Nat. Biomed. Eng.* 2024. Vol. 8. No. 8. Pp. 977–991. <https://doi.org/10.1038/s41551-024-01207-5>
86. Pereira T.D., Shaevitz J.W., Murthy M. Quantifying behavior to understand the brain. *Nat. Neurosci.* 2020. Vol. 23. No. 12. Pp. 1537–1549. <https://doi.org/10.1038/s41593-020-00734-z>
87. Shemesh Y., Chen A. A paradigm shift in translational psychiatry through rodent neuroethology. *Mol. Psychiatry*. 2023. Vol. 28. No. 3. Pp. 993–1003. <https://doi.org/10.1038/s41380-022-01913-z>
88. Krakauer J.W., Ghazanfar A.A., Gomez-Marín A. et al. Neuroscience needs behavior: correcting a reductionist bias. *Neuron*. 2017. Vol. 93. No. 3. Pp. 480–490. <https://doi.org/10.1016/j.neuron.2016.12.041>

89. Kuo J.Y., Denman A.J., Beacher N.J. et al. Using deep learning to study emotional behavior in rodent models. *Front. Behav. Neurosci.* 2022. Vol. 16. 1044492. <https://doi.org/10.3389/fnbeh.2022.1044492>
90. Mathis A., Mamidanna P., Cury K.M. et al. DeepLabCut: markerless pose estimation of user-defined body parts with deep learning. *Nat. Neurosci.* 2018. Vol. 21. No. 9. Pp. 1281–1289. <https://doi.org/10.1038/s41593-018-0209-y>
91. Gomez-Marin A., Paton J.J., Kampff A.R. et al. Big behavioral data: psychology, ethology and the foundations of neuroscience. *Nat. Neurosci.* 2014. Vol. 17. No. 11. Pp. 1455–1462. <https://doi.org/10.1038/nn.3812>
92. Lahoz-Monfort J.J., Magrath M.J. A comprehensive overview of technologies for species and habitat monitoring and conservation. *BioScience.* 2021. Vol. 71. No. 10. Pp. 1038–1062. <https://doi.org/10.1093/biosci/biab073>
93. Dell A.I., Bender J.A., Branson K. et al. Automated image-based tracking and its application in ecology. *Trends Ecol. Evol.* 2014. Vol. 29. No. 7. Pp. 417–428. <https://doi.org/10.1016/j.tree.2014.05.004>
94. Egnor S.R., Branson K. Computational analysis of behavior. *Annu. Rev. Neurosci.* 2016. Vol. 39. No. 1. Pp. 217–236. <https://doi.org/10.1146/annurev-neuro-070815-013845>
95. Camomilla V., Bergamini E., Fantozzi S. et al. Trends supporting the in-field use of wearable inertial sensors for sport performance evaluation: a systematic review. *Sensors.* 2018. Vol. 18. No. 3. 873. <https://doi.org/10.3390/s18030873>
96. Herath S., Harandi M., Porikli F. Going deeper into action recognition: a survey. *Image Vis. Comput.* 2017. Vol. 60. Pp. 4–21. <https://doi.org/10.1016/j.imavis.2017.01.010>
97. Zhou T., Porikli F., Crandall D.J. et al. A survey on deep learning technique for video segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.* 2022. Vol. 45. No. 6. Pp. 7099–7122. <https://doi.org/10.1109/TPAMI.2022.3225573>
98. Zhou L., Zhang L., Konz N. Computer vision techniques in manufacturing. *IEEE Trans. Syst. Man Cybern. Syst.* 2022. Vol. 53. No. 1. Pp. 105–117. <https://doi.org/10.1109/TSMC.2022.3166397>
99. Colyer S.L., Evans M., Cosker D.P. et al. A review of the evolution of vision-based motion analysis and the integration of advanced computer vision methods towards developing a markerless system. *Sports Med-Open.* 2018. Vol. 4. 24. <https://doi.org/10.1186/s40798-018-0139-y>
100. Litjens G., Kooi T., Bejnordi B.E. et al. A survey on deep learning in medical image analysis. *Med. Image Anal.* 2017. Vol. 42. Pp. 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
101. Serre T. Deep learning: the good, the bad, and the ugly. *Annu. Rev. Vis. Sci.* 2019. Vol. 5. No. 1. Pp. 399–426. <https://doi.org/10.1146/annurev-vision-091718-014951>
102. Zador A., Escola S., Richards B. et al. Catalyzing next-generation artificial intelligence through neuroAI. *Nat. Commun.* 2023. Vol. 14. No. 1. 1597. <https://doi.org/10.1038/s41467-023-37180-x>
103. Weinreb C., Pearl J.E., Lin S. et al. Keypoint-MoSeq: parsing behavior by linking point tracking to pose dynamics. *Nat. Methods.* 2024. Vol. 21. No. 7. Pp. 1329–1339. <https://doi.org/10.1038/s41592-024-02318-2>

104. Nath T., Mathis A., Chen A.C. et al. Using DeepLabCut for 3D markerless pose estimation across species and behaviors. *Nat. Protoc.* 2019. Vol. 14. No. 7. Pp. 2152–2176. <https://doi.org/10.1038/s41596-019-0176-0>
105. Goodwin N.L., Choong J.J., Hwang S. et al. Simple behavioral analysis (SimBA) as a platform for explainable machine learning in behavioral neuroscience. *Nat. Neurosci.* 2024. Vol. 27. No. 7. Pp. 1411–1424. <https://doi.org/10.1038/s41593-024-01649-9>
106. Geuther B.Q., Peer A., Hao He et al. Action detection using a neural network elucidates the genetics of mouse grooming behavior. *eLife.* 2021. Vol. 10. e63207. <https://doi.org/10.7554/eLife.63207>
107. Weber R.Z., Mulders G., Kaiser J. et al. Deep learning-based behavioral profiling of rodent stroke recovery. *BMC Biol.* 2022. Vol. 20. No. 1. 232. <https://doi.org/10.1186/s12915-022-01434-9>
108. Aljovic A., Zhao Sh., Chahin M. et al. A deep learning-based toolbox for automated limb motion analysis (ALMA) in murine models of neurological disorders. *Commun. Biol.* 2022. Vol. 5. No. 1. 131. <https://doi.org/10.1038/s42003-022-03077-6>
109. Wiltschko A.B., Johnson M.J., Iurilli G. et al. Mapping sub-second structure in mouse behavior. *Neuron.* 2015. Vol. 88. No. 6. Pp. 1121–1135. <https://doi.org/10.1016/j.neuron.2015.11.031>
110. Hsu A.I., Yttri E.A. B-SO₂D, an open-source unsupervised algorithm for identification and fast prediction of behaviors. *Nat. Commun.* 2021. Vol. 12. No. 1. 5188. <https://doi.org/10.1038/s41467-021-25420-x>
111. Muralidharan A., Swaminathan A., Poulouse A. Deep learning dives: predicting anxiety in zebrafish through novel tank assay analysis. *Physiol. Behav.* 2024. Vol. 287. 114696. <https://doi.org/10.1016/j.physbeh.2024.114696>
112. Pereira T.D., Tabris N., Matsliah A. et al. SLEAP: a deep learning system for multi-animal pose tracking. *Nat. Methods.* 2022. Vol. 19. No. 4. Pp. 486–495. <https://doi.org/10.1038/s41592-022-01426-1>
113. Cohen I.L., Gardner J.M., Karmel B.Z. et al. Rating scale measures are associated with Noldus EthoVision-XT video tracking of behaviors of children on the autism spectrum. *Mol. Autism.* 2014. Vol. 5. 15. <https://doi.org/10.1186/2040-2392-5-15>
114. Sabatos-DeVito M., Murias M., Dawson G. et al. Methodological considerations in the use of Noldus EthoVision XT video tracking of children with autism in multi-site studies. *Biol. Psychol.* 2019. Vol. 146. 107712. <https://doi.org/10.1016/j.biopsycho.2019.05.012>
115. Noldus L.P., Spink A.J., Tegelenbosch R.A. EthoVision: a versatile video tracking system for automation of behavioral experiments. *Behav. Res. Methods Instrum. Comput.* 2001. Vol. 33. Pp. 398–414. <https://doi.org/10.3758/BF03196102>
116. Bühler D., Power Guerra N., Müller L. et al. Leptin deficiency-caused behavioral change—a comparative analysis using EthoVision and DeepLabCut. *Front. Neurosci.* 2023. Vol. 17. 1052079. <https://doi.org/10.3389/fnins.2023.1052079>
117. Sturman O., von Ziegler L., Schläppi C. et al. Deep learning-based behavioral analysis reaches human accuracy and is capable of outperforming commercial solutions. *Neuropsychopharmacology.* 2020. Vol. 45. No. 11. Pp. 1942–1952. <https://doi.org/10.1038/s41386-020-0776-y>

118. Marek S., Tervo-Clemmens B., Calabro F.J. et al. Reproducible brain-wide association studies require thousands of individuals. *Nature*. 2022. Vol. 603. No. 7902. Pp. 654–660. <https://doi.org/10.1038/s41586-022-04492-9>
119. Gerasimov E., Karasev V., Umnov S. et al. AI-powered mice behavior tracking and its application for neuronal manifold analysis based on hippocampal ensemble activity in an Alzheimer's disease mice model. *Int. J. Mol. Sci.* 2025. Vol. 26. No. 15. 7180. <https://doi.org/10.3390/ijms26157180>
120. Kalueff A.V., Aldridge J.W., LaPorte J.L. et al. Analyzing grooming microstructure in neurobehavioral experiments. *Nat. Protoc.* 2007. Vol. 2. No. 10. Pp. 2538–2544. <https://doi.org/10.1038/nprot.2007.367>
121. Xinzhu Yu, Taylor A.M., Jun Nagai et al. Reducing astrocyte calcium signaling *in vivo* alters striatal microcircuits and causes repetitive behavior. *Neuron*. 2018. Vol. 99. No. 6. Pp. 1170–1187. <https://doi.org/10.1016/j.neuron.2018.08.015>
122. Daviu N., Bruchas M.R., Moghaddam B. et al. Neurobiological links between stress and anxiety. *Neurobiol. Stress*. 2019. Vol. 11. 100191. <https://doi.org/10.1016/j.ynstr.2019.100191>
123. Dhawale A.K., Wolff S.B., Ko R. et al. The basal ganglia control the detailed kinematics of learned motor skills. *Nat. Neurosci.* 2021. Vol. 24. No. 9. Pp. 1256–1269. <https://doi.org/10.1038/s41593-021-00889-3>
124. Lipton D.M., Gonzales B.J., Citri A. Dorsal striatal circuits for habits, compulsions and addictions. *Front. Syst. Neurosci.* 2019. Vol. 13. 28. <https://doi.org/10.3389/fnsys.2019.00028>
125. Hintiryan H., Foster N.N., Bowman I. et al. The mouse cortico-striatal projectome. *Nat. Neurosci.* 2016. Vol. 19. No. 8. Pp. 1100–1114. <https://doi.org/10.1038/nn.4332>
126. Schmeisser M.J., Ey E., Wegener S. et al. Autistic-like behaviours and hyperactivity in mice lacking ProSAP1/Shank2. *Nature*. 2012. Vol. 486. No. 7402. Pp. 256–260. <https://doi.org/10.1038/nature11015>
127. Hsu A.I., Yttri E.A. B-SOId, an open-source unsupervised algorithm for identification and fast prediction of behaviors. *Nat. Commun.* 2021. Vol. 12. No. 1. 5188. <https://doi.org/10.1038/s41467-021-25420-x>
128. Апухтин К.В., Шевляков А.Д., Котова М.М. и др. Анализ груминга грызунов и его поведенческой микроструктуры в современных нейробиологических исследованиях. *Российский физиологический журнал им. И.М. Сеченова*. 2024. Т. 110. № 6. С. 889–914. <https://doi.org/10.31857/S0869813924060022>
129. Kyzar E., Gaikwad S., Roth A. et al. Towards high-throughput phenotyping of complex patterned behaviors in rodents: focus on mouse self-grooming and its sequencing. *Behav. Brain Res.* 2011. Vol. 225. No. 2. Pp. 426–431. <https://doi.org/10.1016/j.bbr.2011.07.052>
130. Groman S.M., Keistler C., Keip A.J. et al. Orbitofrontal circuits control multiple reinforcement-learning processes. *Neuron*. 2019. Vol. 103. No. 4. Pp. 734–746. <https://doi.org/10.1016/j.neuron.2019.05.042>
131. Piantadosi S.C., Manning E.E., Chamberlain B.L. et al. Hyperactivity of indirect pathway-projecting spiny projection neurons promotes compulsive behavior. *Nat. Commun.* 2024. Vol. 15. No. 1. 4434. <https://doi.org/10.1038/s41467-024-48331-z>

132. Van den Boom B.J., Pavlidi P., Wolf C.J. et al. Automated classification of self-grooming in mice using open-source software. *J. Neurosci. Methods*. 2017. Vol. 289. Pp. 48–56. <https://doi.org/10.1016/j.jneumeth.2017.05.026>
133. Zhou F., Jiang Zh., Liu Zh. et al. Structured context enhancement network for mouse pose estimation. *IEEE Trans. Circuits Syst. Video Technol.* 2021. Vol. 32. No. 5. Pp. 2787–2801. <https://doi.org/10.1109/TCSVT.2021.3098497>
134. Salem G., Krynitsky J., Hayes M. et al. Three-dimensional pose estimation for laboratory mouse from monocular images. *IEEE Trans. Image Process.* 2019. Vol. 28. No. 9. Pp. 4273–4287. <https://doi.org/10.1109/TIP.2019.2908796>
135. Dunn T.W., Marshall J.D., Severson K.S. et al. Geometric deep learning enables 3D kinematic profiling across species and environments. *Nat. Methods*. 2021. Vol. 18. No. 5. Pp. 564–573. <https://doi.org/10.1038/s41592-021-01106-6>
136. Pereira T.D., Aldarondo D.E., Willmore L. et al. Fast animal pose estimation using deep neural networks. *Nat. Methods*. 2019. Vol. 16. No. 1. Pp. 117–125. <https://doi.org/10.1038/s41592-018-0234-5>
137. Graving J.M., Chae D., Naik H. et al. DeepPoseKit, a software toolkit for fast and robust animal pose estimation using deep learning. *eLife*. 2019. Vol. 8. e47994. <https://doi.org/10.7554/eLife.47994>
138. Wang Zh., Mirbozorgi S.A., Ghovanloo M. Towards a Kinect-based behavior recognition and analysis system for small animals. В сб.: *2015 IEEE BioCAS Proceedings: 2015 IEEE Biomedical Circuits and Systems Conference (BioCAS)*. IEEE, 2015. <https://doi.org/10.1109/BioCAS.2015.7348456>
139. Karashchuk P., Rupp K.L., Dickinson E.S. et al. Anipose: a toolkit for robust markerless 3D pose estimation. *Cell Rep.* 2021. Vol. 36. No. 13. 109730. <https://doi.org/10.1016/j.celrep.2021.109730>
140. Gerós A., Magalhães A., Aguiar P. Improved 3D tracking and automated classification of rodents' behavioral activity using depth-sensing cameras. *Behav. Res. Methods*. 2020. Vol. 52. No. 5. Pp. 2156–2167. <https://doi.org/10.3758/s13428-020-01381-9>
141. Fayat R., Sarraudy M., Léna C. et al. DISSECT: an unsupervised framework for high-resolution mapping of rodent behavior using inertial sensors. *PLoS Biol.* 2025. Vol. 23. No. 10. e3003431. <https://doi.org/10.1371/journal.pbio.3003431>
142. van den Boom B.J.G., Pavlidi P., Wolf C.J.H. et al. Automated classification of self-grooming in mice using open-source software. *J. Neurosci. Methods*. 2017. Vol. 289. Pp. 48–56. <https://doi.org/10.1016/j.jneumeth.2017.05.026>
143. Simon P., Dupuis R., Costentin J. Thigmotaxis as an index of anxiety in mice: influence of dopaminergic transmissions. *Behav. Brain Res.* 1994. Vol. 61. No. 1. Pp. 59–64. [https://doi.org/10.1016/0166-4328\(94\)90008-6](https://doi.org/10.1016/0166-4328(94)90008-6)
144. Hong W., Kennedy A., Burgos-Artizzu X.P. et al. Automated measurement of mouse social behaviors using depth sensing, video tracking, and machine learning. *Proc. Natl. Acad. Sci. U.S.A.* 2015. Vol. 112. No. 38. Pp. E5351–E5360. <https://doi.org/10.1073/pnas.1515982112>
145. Hardin A., Schlupp I. Using machine learning and DeepLabCut in animal behavior. *Acta Ethol.* 2022. Vol. 25. No. 3. Pp. 125–133. <https://doi.org/10.1007/s10211-022-00397-y>

146. Itskov P.M., Moreira J.M., Vinnik E. et al. Automated monitoring and quantitative analysis of feeding behavior in *Drosophila*. *Nat. Commun.* 2014. Vol. 5. No. 1. 4560. <https://doi.org/10.1038/ncomms5560>
147. Wang Ch., Shen J. Deep learning-driven behavioral analysis reveals adaptive responses in *Drosophila* offspring after long-term parental microplastic exposure. *J. Environ. Manage.* 2025. Vol. 376. 124502. <https://doi.org/10.1016/j.jenvman.2025.124502>
148. Branson K., Robie A.A., Bender J. et al. High-throughput ethomics in large groups of *Drosophila*. *Nat. Methods.* 2009. Vol. 6. No. 6. Pp. 451–457. <https://doi.org/10.1038/nmeth.1328>
149. Grieco F., Bernstein B.J., Biemans B. et al. Measuring behavior in the home cage: study design, applications, challenges, and perspectives. *Front. Behav. Neurosci.* 2021. Vol. 15. 735387. <https://doi.org/10.3389/fnbeh.2021.735387>
150. Salido A.G., de la Herrán R., Robles F. et al. Automatic counting and identification of two *Drosophila melanogaster* (Diptera: Drosophilidae) morphs with image-recognition artificial intelligence. *Can. Entomol.* 2024. Vol. 156. e40. <https://doi.org/10.4039/tce.2024.36>
151. Keleş M.F., Sapci A.O.B., Brody C. et al. FlyVISTA, an integrated machine learning platform for deep phenotyping of sleep in *Drosophila*. *Sci. Adv.* 2025. Vol. 11. No. 11. eadq8131. <https://doi.org/10.1126/sciadv.adq8131>
152. Lin J.-L., Kuo W.-L., Huang Y.-H. et al. Using convolutional neural networks to measure the physiological age of *Caenorhabditis elegans*. *IEEE/ACM Trans. Comput. Biol. Bioinform.* 2020. Vol. 18. No. 6. Pp. 2724–2732. <https://doi.org/10.1109/TCBB.2020.2971992>
153. Park C.F., Barzegar-Keshteli M., Korchagina K. et al. Automated neuron tracking inside moving and deforming *C. elegans* using deep learning and targeted augmentation. *Nat. Methods.* 2024. Vol. 21. No. 1. Pp. 142–149. <https://doi.org/10.1038/s41592-023-02096-3>
154. Swierczek N.A., Giles A.C., Rankin C.H. et al. High-throughput behavioral analysis in *C. elegans*. *Nat. Methods.* 2011. Vol. 8. No. 7. Pp. 592–598. <https://doi.org/10.1038/nmeth.1625>
155. DuPlissis A., Medewar A., Hegarty E. et al. Machine learning-based analysis of microfluidic device immobilized *C. elegans* for automated developmental toxicity testing. *Sci. Rep.* 2025. Vol. 15. No. 1. 15. <https://doi.org/10.1038/s41598-024-84842-x>
156. Pan P., Zhang P., Premachandran S. et al. High-resolution imaging and morphological phenotyping of *C. elegans* through stable robotic sample rotation and artificial intelligence-based 3-dimensional reconstruction. *Research.* 2024. Vol. 7. 0513. <https://doi.org/10.34133/research.0513>
157. Kalueff A.V., Stewart A.M., Gerlai R. Zebrafish as an emerging model for studying complex brain disorders. *Trends Pharmacol. Sci.* 2014. Vol. 35. No. 2. Pp. 63–75. <https://doi.org/10.1016/j.tips.2013.12.002>
158. Stewart A.M., Grieco F., Tegelenbosch R.A.J. et al. A novel 3D method of locomotor analysis in adult zebrafish: implications for automated detection of CNS drug-evoked phenotypes. *J. Neurosci. Methods.* 2015. Vol. 255. Pp. 66–74. <https://doi.org/10.1016/j.jneumeth.2015.07.023>

159. Li Y., Chen T., Miao X. et al. Zebrafish: a promising in vivo model for assessing the delivery of natural products, fluorescence dyes and drugs across the blood-brain barrier. *Pharmacol. Res.* 2017. Vol. 125. Pp. 246–257. <https://doi.org/10.1016/j.phrs.2017.08.017>
160. Kokel D., Peterson R.T. Chemobehavioural phenomics and behaviour-based psychiatric drug discovery in the zebrafish. *Brief. Funct. Genom. Proteom.* 2008. Vol. 7. No. 6. Pp. 483–490. <https://doi.org/10.1093/bfgp/eln040>
161. Bailey J.M., Oliveri A.N., Levin E.D. Pharmacological analyses of learning and memory in zebrafish (*Danio rerio*). *Pharmacol. Biochem. Behav.* 2015. Vol. 139. Pp. 103–111. <https://doi.org/10.1016/j.pbb.2015.03.006>
162. Stewart A.M., Kalueff A.V. The developing utility of zebrafish models for cognitive enhancers research. *Curr. Neuropharmacol.* 2012. Vol. 10. No. 3. Pp. 263–271. <https://doi.org/10.2174/157015912803217323>
163. Geng Y., Yates C., Peterson R.T. Social behavioral profiling by unsupervised deep learning reveals a stimulative effect of dopamine D3 agonists on zebrafish sociality. *Cell Rep. Methods.* 2023. Vol. 3. No. 1. 100381. <https://doi.org/10.1016/j.crmeth.2022.100381>
164. Gore S.V., Kakodkar R., Del Rosario Hernández T. et al. Zebrafish Larvae Position Tracker (Z-LaP Tracker): a high-throughput deep-learning behavioral approach for the identification of calcineurin pathway-modulating drugs using zebrafish larvae. *Sci. Rep.* 2023. Vol. 13. No. 1. 3174. <https://doi.org/10.1038/s41598-023-30303-w>
165. Kokel D., Bryan J., Laggner C. et al. Rapid behavior-based identification of neuroactive small molecules in the zebrafish. *Nat. Chem. Biol.* 2010. Vol. 6. No. 3. Pp. 231–237. <https://doi.org/10.1038/nchembio.307>
166. Brockerhoff S.E., Hurley J.B., Janssen-Bienhold U. et al. A behavioral screen for isolating zebrafish mutants with visual system defects. *Proc. Natl. Acad. Sci. U.S.A.* 1995. Vol. 92. No. 23. Pp. 10545–10549. <https://doi.org/10.1073/pnas.92.23.10545>
167. Neuhaus S.C., Biehlmaier O., Seeliger M.W. et al. Genetic disorders of vision revealed by a behavioral screen of 400 essential loci in zebrafish. *J. Neurosci.* 1999. Vol. 19. No. 19. Pp. 8603–8615. <https://doi.org/10.1523/jneurosci.19-19-08603.1999>
168. Burgess H.A., Granato M. Sensorimotor gating in larval zebrafish. *J. Neurosci.* 2007. Vol. 27. No. 18. Pp. 4984–4994. <https://doi.org/10.1523/jneurosci.0615-07.2007>
169. Prober D.A., Rihel J., Onah A.A. et al. Hypocretin/orexin overexpression induces an insomnia-like phenotype in zebrafish. *J. Neurosci.* 2006. Vol. 26. No. 51. Pp. 13400–13410. <https://doi.org/10.1523/jneurosci.4332-06.2006>
170. Zhdanova I.V., Wang S.Y., Leclair O.U. et al. Melatonin promotes sleep-like state in zebrafish. *Brain Res.* 2001. Vol. 903. Nos. 1–2. Pp. 263–268. [https://doi.org/10.1016/s0006-8993\(01\)02444-1](https://doi.org/10.1016/s0006-8993(01)02444-1)
171. Brockerhoff S.E. Measuring the optokinetic response of zebrafish larvae. *Nat. Protoc.* 2006. Vol. 1. No. 5. Pp. 2448–2451. <https://doi.org/10.1038/nprot.2006.255>
172. Muto A., Orger M.B., Wehman A.M. et al. Forward genetic analysis of visual behavior in zebrafish. *PLoS Genet.* 2005. Vol. 1. No. 5. e66. <https://doi.org/10.1371/journal.pgen.0010066>

173. Laggner C., Kokel D., Setola V. et al. Chemical informatics and target identification in a zebrafish phenotypic screen. *Nat. Chem. Biol.* 2011. Vol. 8. No. 2. Pp. 144–146. <https://doi.org/10.1038/nchembio.732>
174. McCarroll M.N., Gendelev L., Kinser R. et al. Zebrafish behavioural profiling identifies GABA and serotonin receptor ligands related to sedation and paradoxical excitation. *Nat. Commun.* 2019. Vol. 10. No. 1. 4078. <https://doi.org/10.1038/s41467-019-11936-w>
175. Braun D., Rosenberg A.M., Rabaniam E. et al. High-resolution tracking of unconfined zebrafish behavior reveals stimulatory and anxiolytic effects of psilocybin. *Mol. Psychiatry.* 2024. Vol. 29. No. 4. Pp. 1046–1062. <https://doi.org/10.1038/s41380-023-02391-7>
176. Soleymani A., Cachat J., Robinson K. et al. Integrating cross-scale analysis in the spatial and temporal domains for classification of behavioral movement. *J. Spat. Inf. Sci.* 2014. Vol. 8. Pp. 1–25. <https://doi.org/10.5311/josis.2014.8.162>
177. Lukovikov D.A., Kolesnikova T.O., Ikrin A.N. et al. A novel open-access artificial-intelligence-driven platform for CNS drug discovery utilizing adult zebrafish. *J. Neurosci. Methods.* 2024. Vol. 411. 110256. <https://doi.org/10.1016/j.jneumeth.2024.110256>
178. Bozhko D.V., Myrov V.O., Kolchanova S.M. et al. Artificial intelligence-driven phenotyping of zebrafish psychoactive drug responses. *Prog. Neuropsychopharmacol. Biol. Psychiatry.* 2022. Vol. 112. 110405. <https://doi.org/10.1016/j.pnpbp.2021.110405>
179. Demin K.A., Kupriyanova O.V., Shevyrin V.A. et al. Acute behavioral and neurochemical effects of novel N-benzyl-2-phenylethylamine derivatives in adult zebrafish. *ACS Chem. Neurosci.* 2022. Vol. 13. No. 13. Pp. 1902–1922. <https://doi.org/10.1021/acscemneuro.2c00123>
180. Myrov V.O., Polovian A.I., Kolchanova S. et al. Artificial neural network (ANN)-based pattern recognition approach illustrates a biphasic behavioral effect of ethanol in zebrafish: a high-throughput method for animal locomotor analysis. *Biomedicines.* 2023. Vol. 11. No. 12. 3215. <https://doi.org/10.3390/biomedicines11123215>
181. Marques J.C., Lackner S., Félix R. et al. Structure of the zebrafish locomotor repertoire revealed with unsupervised behavioral clustering. *Curr. Biol.* 2018. Vol. 28. No. 2. Pp. 181–195. <https://doi.org/10.1016/j.cub.2017.12.002>
182. Xing Q., Huynh V., Parolari T.G. et al. Zebrafish larvae heartbeat detection from body deformation in low resolution and low frequency video. *Med. Biol. Eng. Comput.* 2018. Vol. 56. No. 12. Pp. 2353–2365. <https://doi.org/10.1007/s11517-018-1863-7>
183. Liu Ch., Wang Y., Zeng Y. et al. Use of deep-learning assisted assessment of cardiac parameters in zebrafish to discover cyanidin chloride as a novel Keap1 inhibitor against doxorubicin-induced cardiotoxicity. *Adv. Sci.* 2023. Vol. 10. No. 30. 2301136. <https://doi.org/10.1002/advs.202301136>
184. Abangan A.S., Kopp D., Faillettaz R. Artificial intelligence for fish behavior recognition may unlock fishing gear selectivity. *Front. Mar. Sci.* 2023. Vol. 10. 1010761. <https://doi.org/10.3389/fmars.2023.1010761>

185. He S. Modeling oral dyskinesias in zebrafish, and its AI-powered models. *Sciences*. Hangzhou. Zhejiang. 2025. P1-033.
186. He S., Yang L., Bai Y. et al. Studying oral dyskinesias using AI in zebrafish. В сб.: *Proceedings of the Neuroscience Week-2025: 3rd Joint Meeting “Neuroscience Week-2025”*, Yerevan, Armenia, 16–19 May, 2025.
187. Challa A.P., Beam A.L., Shen M. et al. Machine learning on drug-specific data to predict small molecule teratogenicity. *Reprod. Toxicol.* 2020. Vol. 95. Pp. 148–158. <https://doi.org/10.1016/j.reprotox.2020.05.004>
188. Ahuja A.S. The impact of artificial intelligence in medicine on the future role of the physician. *PeerJ*. 2019. Vol. 7. e7702. <https://doi.org/10.7717/peerj.7702>
189. Sakamoto N., Haraguchi T., Kobayashi K. et al. Automated scratching detection system for black mouse using deep learning. *Front. Physiol.* 2022. Vol. 13. 939281. <https://doi.org/10.3389/fphys.2022.939281>
190. Ozdemir Y., Nakamoto K., Boivin B. et al. Quantification of stimulus-evoked tactile allodynia in free moving mice by the chainmail sensitivity test. *Front. Pharmacol.* 2024. Vol. 15. 1352464. <https://doi.org/10.3389/fphar.2024.1352464>
191. Manno F.A., Cheung P., Basnet V. et al. Subtle alterations of vestibulomotor functioning in conductive hearing loss. *Front. Neurosci.* 2023. Vol. 17. 1057551. <https://doi.org/10.3389/fnins.2023.1057551>
192. Geng W., Cosman P., Berry C.C. et al. Automatic tracking, feature extraction and classification of *C. elegans* phenotypes. *IEEE Trans. Biomed. Eng.* 2004. Vol. 51. No. 10. Pp. 1811–1820. <https://doi.org/10.1109/TBME.2004.831532>
193. Zhan W., Chen W., Pan Y. Automated recognition and analysis of escape response in *Caenorhabditis elegans*. *IEEE/ACM Trans. Comput. Biol. Bioinform.* 2025. Vol. 22. No. 3. Pp. 1201–1210. <https://doi.org/10.1109/TCBBIO.2025.3552631>
194. Hughes N.C., Roberts D.C., Tarchini B. et al. Instrumented swim test for quantifying motor impairment in rodents. *Sci. Rep.* 2024. Vol. 14. No. 1. 29270. <https://doi.org/10.1038/s41598-024-80344-y>
195. Dingemans A.J., Hinne M., Truijen K.M. et al. PhenoScore quantifies phenotypic variation for rare genetic diseases by combining facial analysis with other clinical features using a machine-learning framework. *Nat. Genet.* 2023. Vol. 55. No. 9. Pp. 1598–1607. <https://doi.org/10.1038/s41588-023-01469-w>
196. Hasin Y., Seldin M., Lusia A. Multi-omics approaches to disease. *Genome Biol.* 2017. Vol. 18. No. 1. 83. <https://doi.org/10.1186/s13059-017-1215-1>
197. Qiu S., Miller M.I., Joshi P.S. et al. Multimodal deep learning for Alzheimer’s disease dementia assessment. *Nat. Commun.* 2022. Vol. 13. No. 1. 3404. <https://doi.org/10.1038/s41467-022-31037-5>
198. Kline A., Wang H., Li Y. et al. Multimodal machine learning in precision health: a scoping review. *npj Digit. Med.* 2022. Vol. 5. No. 1. 171. <https://doi.org/10.1038/s41746-022-00712-8>
199. Jun Shi, Xiao Zheng, Yan Li et al. Multimodal neuroimaging feature learning with multimodal stacked deep polynomial networks for diagnosis of Alzheimer’s disease. *IEEE J. Biomed. Health Inform.* 2017. Vol. 22. No. 1. Pp. 173–183. <https://doi.org/10.1109/JBHI.2017.2655720>

200. Hinrichs C., Singh V., Guofan Xu et al. Predictive markers for AD in a multi-modality framework: an analysis of MCI progression in the ADNI population. *NeuroImage*. 2011. Vol. 55. No. 2. Pp. 574–589. <https://doi.org/10.1016/j.neuroimage.2010.10.081>
201. Zhang D., Wang Y., Zhou L. et al. Multimodal classification of Alzheimer's disease and mild cognitive impairment. *Neuroimage*. 2011. Vol. 55. No. 3. Pp. 856–867. <https://doi.org/10.1016/j.neuroimage.2011.01.008>
202. Gao X., Shi F., Shen D. et al. Multimodal transformer network for incomplete image generation and diagnosis of Alzheimer's disease. *Comput. Med. Imaging Graph.* 2023. Vol. 110. 102303. <https://doi.org/10.1016/j.compmedimag.2023.102303>
203. Wang E.Y., Fahey P.G., Zhuokun Ding et al. Foundation model of neural activity predicts response to new stimulus types. *Nature*. 2025. Vol. 640. No. 8058. Pp. 470–477. <https://doi.org/10.1038/s41586-025-08829-y>
204. Sinz F., Ecker A.S., Fahey P. et al. Stimulus domain transfer in recurrent models for large scale cortical population prediction on video. *Adv. Neural Inf. Process. Syst.* 2018. Vol. 31. Pp. 7632–7643. <https://doi.org/10.1101/452672>
205. Subramanian I., Verma S., Kumar S. et al. Multi-omics data integration, interpretation, and its application. *Bioinform. Biol. Insights*. 2020. Vol. 14. 1177932219899051. <https://doi.org/10.1177/1177932219899051>
206. Nam Y., Kim J., Jung S.-H. et al. Harnessing artificial intelligence in multimodal omics data integration: paving the path for the next frontier in precision medicine. *Annu. Rev. Biomed. Data Sci.* 2024. Vol. 7. Pp. 153–175. <https://doi.org/10.1146/annurev-biodatasci-102523-103801>
207. Rudroff T. Artificial intelligence as a replacement for animal experiments in neurology: potential, progress, and challenges. *Neurol. Int.* 2024. Vol. 16. No. 4. Pp. 805–820. <https://doi.org/10.3390/neurolint16040060>
208. Bailey J. Does the stress inherent to laboratory life and experimentation on animals adversely affect research data? *Altern. Lab. Anim.* 2017. Vol. 45. No. 6. Pp. 299–301. <https://doi.org/10.1177/026119291704500605>
209. Bruni G., Rennekamp A.J., Velenich A. et al. Zebrafish behavioral profiling identifies multitarget antipsychotic-like compounds. *Nat. Chem. Biol.* 2016. Vol. 12. No. 7. Pp. 559–566. <https://doi.org/10.1038/nchembio.2097>
210. Gendelev L., Taylor J., Myers-Turnbull D. et al. Deep phenotypic profiling of neuroactive drugs in larval zebrafish. *Nat. Commun.* 2024. Vol. 15. No. 1. 9955. <https://doi.org/10.1038/s41467-024-54375-y>
211. von Ziegler L., Sturman O., Bohacek J. Big behavior: challenges and opportunities in a new era of deep behavior profiling. *Neuropsychopharmacology*. 2021. Vol. 46. No. 1. Pp. 33–44. <https://doi.org/10.1038/s41386-020-0751-7>
212. Segalin C., Williams J., Karigo T. et al. The Mouse Action Recognition System (MARS) software pipeline for automated analysis of social behaviors in mice. *eLife*. 2021. Vol. 10. e63720. <https://doi.org/10.7554/eLife.63720>
213. Mavrogiorgos K., Kiourtis A., Mavrogiorgou A. et al. Bias in machine learning: a literature review. *Appl. Sci.* 2024. Vol. 14. No. 19. 8860. <https://doi.org/10.3390/app14198860>

214. Fontana B., Marion J., Rosemberg D. Swimming into the future: machine learning in zebrafish behavioral research. *Prog. Neuropsychopharmacol. Biol. Psychiatry*. 2025. Vol. 139. 111398. <https://doi.org/10.1016/j.pnpbp.2025.111398>
215. Guidotti R., Monreale A., Ruggieri S. et al. A survey of methods for explaining black box models. *ACM Comput. Surv.* 2018. Vol. 51. No. 5. 93. <https://doi.org/10.1145/3236009>
216. Lundberg S.M., Lee S.I. A unified approach to interpreting model predictions. В сб.: *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*. Curran Associates Inc., 2017. Pp. 4768–4777.
217. Yang G.R., Wang X.-J. Artificial neural networks for neuroscientists: a primer. *Neuron*. 2020. Vol. 107. No. 6. Pp. 1048–1070. <https://doi.org/10.48550/arXiv.2006.01001>
218. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nat. Mach. Intell.* 2019. Vol. 1. No. 5. Pp. 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
219. Gunning D., Stefik M., Choi J. et al. XAI – Explainable artificial intelligence. *Sci. Robot.* 2019. Vol. 4. No. 37. eaay7120. <https://doi.org/10.1126/scirobotics.aay7120>
220. Shah P., Kendall F., Khozin S. et al. Artificial intelligence and machine learning in clinical development: a translational perspective. *NPJ Digit. Med.* 2019. Vol. 2. No. 1. 69. <https://doi.org/10.1038/s41746-019-0148-3>
221. Gerke S., Minssen T., Cohen G. Ethical and legal challenges of artificial intelligence-driven healthcare. В кн.: A. Bohr, K. Memarzadeh K (eds.) *Artificial Intelligence in Healthcare*. Acad. Press, 2020. Pp. 295–336. <https://doi.org/10.1016/B978-0-12-818438-7.00012-5>
222. Vayena E., Blasimme A., Cohen I.G. Machine learning in medicine: addressing ethical challenges. *PLoS Med.* 2018. Vol. 15. No. 11. e1002689. <https://doi.org/10.1371/journal.pmed.1002689>
223. Price W.N., Cohen I.G. Privacy in the age of medical big data. *Nat. Med.* 2019. Vol. 25. No. 1. Pp. 37–43. <https://doi.org/10.1038/s41591-018-0272-7>
224. Dixit P. Transfer learning in image recognition: leveraging pre-trained models for improved performance. *Edu Journal of International Affairs and Research*. 2023. Vol. 2. No. 4. Pp. 31–37.
225. Gupta A., Eysenbach B., Finn C. et al. Unsupervised meta-learning for reinforcement learning. *arXiv*. 1806.04640. <https://doi.org/10.48550/arXiv.1806.04640>
226. Chaloner K., Verdinelli I. Bayesian experimental design: a review. *Stat. Sci.* 1995. Vol. 10. No. 3. Pp. 273–304. <https://doi.org/10.1214/ss/1177009939>
227. Baltrušaitis T., Ahuja C., Morency L.P. Multimodal machine learning: a survey and taxonomy. *IEEE Trans. Pattern Anal. Mach. Intell.* 2019. Vol. 41. No. 2. Pp. 423–443. <https://doi.org/10.1109/TPAMI.2018.2798607>
228. Chen R.J., Wang J.J., Williamson D.F.K. et al. Algorithmic fairness in artificial intelligence for medicine and healthcare. *Nat. Biomed. Eng.* 2023. Vol. 7. No. 6. Pp. 719–742. <https://doi.org/10.1038/s41551-023-01056-8>

229. Vamathevan J., Clark D., Czodrowski P. et al. Applications of machine learning in drug discovery and development. *Nat. Rev. Drug Discov.* 2019. Vol. 18. No. 6. Pp. 463–477. <https://doi.org/10.1038/s41573-019-0024-5>
230. Huang Sh., Yang J., Fong S. et al. Artificial intelligence in cancer diagnosis and prognosis: opportunities and challenges. *Cancer Lett.* 2020. Vol. 471. Pp. 61–71. <https://doi.org/10.1016/j.canlet.2019.12.007>
231. Bruni G., Lakhani P., Kokel D. Discovering novel neuroactive drugs through high-throughput behavior-based chemical screening in the zebrafish. *Front. Pharmacol.* 2014. Vol. 5. 153. <https://doi.org/10.3389/fphar.2014.00153>
232. Kokel D., Rennekamp A.J., Shah A.H. et al. Behavioral barcoding in the cloud: embracing data-intensive digital phenotyping in neuropharmacology. *Trends Biotechnol.* 2012. Vol. 30. No. 8. Pp. 421–425. <https://doi.org/10.1016/j.tibtech.2012.05.001>
233. Davies M., Srinivasa N., Lin T.H. et al. Loihi: a neuromorphic manycore processor with on-chip learning. *IEEE Micro.* 2018. Vol. 38. No. 1. Pp. 82–99. <https://doi.org/10.1109/MM.2018.112130359>
234. Merolla P.A., Arthur J.V., Alvarez-Icaza R. et al. A million spiking-neuron integrated circuit with a scalable communication network and interface. *Science.* 2014. Vol. 345. No. 6197. Pp. 668–673. <https://doi.org/10.1126/science.1254642>
235. Леуненко А.О. Нейроморфный искусственный интеллект: принципы, технологии и перспективы развития. В сб.: *ТОГУ-Старт: фундаментальные и прикладные исследования молодых: Материалы VI региональной научно-практической конференции* (Хабаровск, 7–12 апреля, 2025). Хабаровск: Изд-во ТОГУ. С. 148–157.
236. Tang J., Yuan F., Shen X. et al. Bridging biological and artificial neural networks with emerging neuromorphic devices: fundamentals, progress, and challenges. *Adv. Mater.* 2019. Vol. 31. No. 49. 1902761. <https://doi.org/10.1002/adma.201902761>
237. Potter S.M., El Hady A., Fetz E.E. Closed-loop neuroscience and neuroengineering. *Front. Neural Circuits.* 2014. Vol. 8. 115. <https://doi.org/10.3389/fncir.2014.00115>
238. Kim T.H., Zhang Y., Lecoq J. et al. Long-term optical access to an estimated one million neurons in the live mouse cortex. *Cell Rep.* 2016. Vol. 17. No. 12. Pp. 3385–3394. <https://doi.org/10.1016/j.celrep.2016.12.004>
239. Ahrens M.B., Orger M.B., Robson D.N. et al. Whole-brain functional imaging at cellular resolution using light-sheet microscopy. *Nat. Methods.* 2013. Vol. 10. No. 5. Pp. 413–420. <https://doi.org/10.1038/nmeth.2434>
240. Korkos A. Intel’s Pohoiki Beach, a 64-chip neuromorphic system, delivers breakthrough results in research tests. URL: <https://www.intc.com/news-events/press-releases/detail/61/intels-pohoiki-beach-a-64-chip-neuromorphic-system> (дата обращения: 15.07.2019)
241. Salter J. Brains scale better than CPUs. So Intel is building brains. URL: <https://arstechnica.com/science/2019/07/brains-scale-better-than-cpus-so-intel-is-building-brains/> (дата обращения: 15.07.2019)
242. Korkos A. Intel scales neuromorphic research system to 100 million neurons. URL: <https://www.intc.com/news-events/press-releases/detail/12/intel-scales-neuromorphic-research-system-to-100-million> (дата обращения: 17.04.2025)

243. Ward-Foxton S. Intel scales neuromorphic computer to 100 million neurons. URL: <https://www.eetimes.com/intel-scales-neuromorphic-computer-to-100-million-neurons/> (дата обращения: 17.04.2025)
244. Naveros F., Garrido J.A., Carrillo R.R. et al. Event- and time-driven techniques using parallel CPU-GPU co-processing for spiking neural networks. *Frontiers in Neuroinformatics*. 2017. Vol. 11. 7. <https://doi.org/10.3389/fninf.2017.00007>
245. Angotzi G.N., Boi F., Zordan S. et al. A programmable closed-loop recording and stimulating wireless system for behaving small laboratory animals. *Scientific Reports*. 2014. Vol. 4. No. 1. 5963. <https://doi.org/10.1038/srep05963>
246. Pfeiffer M., Pfeiffer T. Deep learning with spiking neurons: opportunities and challenges. *Frontiers in Neuroscience*. 2018. Vol. 12. 774. <https://doi.org/10.3389/fnins.2018.00774>
247. Tavanaei A., Maida A. BP-STDP: approximating backpropagation using spike timing-dependent plasticity. *Neurocomputing*. 2019. Vol. 330. Pp. 39–47. <https://doi.org/10.1016/j.neucom.2018.11.014>
248. Lee C., Panda P., Srinivasan G. et al. Training deep spiking convolutional neural networks with STDP-based unsupervised pre-training followed by supervised fine-tuning. *Frontiers in Neuroscience*. 2018. Vol. 12. 435. <https://doi.org/10.3389/fnins.2018.00435>
249. Bellec G., Scherr F., Subramoney A. et al. A solution to the learning dilemma for recurrent networks of spiking neurons. *Nature Communications*. 2020. Vol. 11. No. 1. 3625. <https://doi.org/10.1038/s41467-020-17236-y>
250. Kaiser J., Mostafa H., Neftci E. Synaptic plasticity dynamics for deep continuous local learning (DECOLLE). *Frontiers in Neuroscience*. 2020. Vol. 14. 424. <https://doi.org/10.3389/fnins.2020.00424>
251. Sze V., Yu-Hsin Chen, Tien-Ju Yang et al. Efficient processing of deep neural networks: a tutorial and survey. *Proceedings of the IEEE*. 2017. Vol. 105. No. 12. Pp. 2295–2329. <https://doi.org/10.1109/JPROC.2017.2761740>
252. Lin Ch.-K., Wild A., China G.N. et al. Programming spiking neural networks on Intel's Loihi. *Computer*. 2018. Vol. 51. No. 3. Pp. 52–61. <https://doi.org/10.1109/MC.2018.157113521>
253. Kudithipudi D., Schuman C., Vineyard C.M. et al. Neuromorphic computing at scale. *Nature*. 2025. Vol. 637. No. 8047. Pp. 801–812. <https://doi.org/10.1038/s41586-024-08253-8>
254. Davies M., Wild A., Orchard G. et al. Advancing neuromorphic computing with Loihi: a survey of results and outlook. *Proceedings of the IEEE*. 2021. Vol. 109. No. 5. Pp. 911–934. <https://doi.org/10.1109/JPROC.2021.3067593>
255. Schuman C.D., Kulkarni S.R., Parsa M. et al. Opportunities for neuromorphic computing algorithms and applications. *Nature Computational Science*. 2022. Vol. 2. No. 1. Pp. 10–19. <https://doi.org/10.1038/s43588-021-00184-y>
256. Vogginger B., Rostami A.H., Jain V. et al. Neuromorphic hardware for sustainable AI data centers. *arXiv*. 2402.02521. <https://doi.org/10.48550/arXiv.2402.02521>
257. Kulkarni S.R., Rajendran B. Spiking neural networks for handwritten digit recognition – supervised learning and network optimization. *Neural Networks*. 2018. Vol. 103. Pp. 118–127. <https://doi.org/10.1016/j.neunet.2018.03.019>

258. Hazan H., Saunders D.J., Khan H. et al. BindsNET: a machine learning-oriented spiking neural networks library in Python. *Frontiers in Neuroinformatics*. 2018. Vol. 12. 89. <https://doi.org/10.3389/fninf.2018.00089>
259. Baratta A.M., Brandner A.J., Plasil S.L. et al. Advancements in genomic and behavioral neuroscience analysis for the study of normal and pathological brain function. *Frontiers in Molecular Neuroscience*. 2022. Vol. 15. 905328. <https://doi.org/10.3389/fnmol.2022.905328>

REFERENCES

1. Hamet P., Tremblay J. Artificial intelligence in medicine. *Metabolism*. 2017;**69**(Suppl):S36–S40. <https://doi.org/10.1016/j.metabol.2017.01.011>
2. Jordan M.I., Mitchell T.M. Machine learning: trends, perspectives, and prospects. *Science*. 2015;**349**(6245):255–260. <https://doi.org/10.1126/science.aaa8415>
3. Chance F.S. Interception from a dragonfly neural network model. In: *Proceedings of International Conference on Neuromorphic Systems 2020*. New York: Association for Computing Machinery; 2020:p.21.
4. Popuri K., Ma D., Wang L. et al. Using machine learning to quantify structural MRI neurodegeneration patterns of Alzheimer’s disease into dementia score: independent validation on 8,834 images from ADNI, AIBL, OASIS, and MIRIAD databases. *Hum. Brain Mapp*. 2020;**41**(14):4127–4147. <https://doi.org/10.1002/hbm.25115>
5. Fan J., Fang L., Wu J. et al. From brain science to artificial intelligence. *Eng*. 2020;**6**(3):248–252. <https://doi.org/10.1016/j.eng.2019.11.012>
6. Zou J., Huss M., Abid A. et al. A primer on deep learning in genomics. *Nat. Genet*. 2019;**51**(1):12–18. <https://doi.org/10.1038/s41588-018-0295-5>
7. Uffelmann E., Huang Q.Q., Munung N.S. et al. Genome-wide association studies. *Nat. Rev. Methods Primers*. 2021;**1**(1):59. <https://doi.org/10.1038/s43586-021-00056-9>
8. Wenderott K., Krups J., Zaruchas F. et al. Effects of artificial intelligence implementation on efficiency in medical imaging – a systematic literature review and meta-analysis. *NPJ Digit. Med*. 2024;**7**(1):265. <https://doi.org/10.1038/s41746-024-01248-9>
9. Khalifa M., Albadawy M. AI in diagnostic imaging: revolutionizing accuracy and efficiency. *Comput. Methods Programs Biomed. Update*. 2024;**5**:100146. <https://doi.org/10.1016/j.cmpbup.2024.100146>
10. Potočník J., Foley S., Thomas E. Current and potential applications of artificial intelligence in medical imaging practice: a narrative review. *J. Med. Imaging Radiat. Sci*. 2023;**54**(2):376–385. <https://doi.org/10.1016/j.jmir.2023.03.033>
11. Sanchez-Roige S., Gray J.C., MacKillop J. et al. The genetics of human personality. *Genes Brain Behav*. 2018;**17**(3):e12439. <https://doi.org/10.1111/gbb.12439>
12. Brasil S., Pascoal C., Francisco R. et al. Artificial intelligence (AI) in rare diseases: is the future brighter? *Genes*. 2019;**10**(12):978. <https://doi.org/10.3390/genes10120978>

13. Smeriglio P., Langard P., Querin G. et al. The identification of novel biomarkers is required to improve adult SMA patient stratification, diagnosis and treatment. *J. Pers. Med.* 2020;**10**(3):75. <https://doi.org/10.3390/jpm10030075>
14. Mathis M.W., Mathis A. Deep learning tools for the measurement of animal behavior in neuroscience. *Curr. Opin. Neurobiol.* 2020;**60**:1–11. <https://doi.org/10.1016/j.conb.2019.10.008>
15. Valletta J.J., Torney C., Kings M. et al. Applications of machine learning in animal behavior studies. *Anim. Behav.* 2017;**124**:203–220. <https://doi.org/10.1016/j.anbehav.2016.12.005>
16. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature.* 2015;**521**(7553):436–444. <https://doi.org/10.1038/nature14539>
17. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol. Rev.* 1958;**65**(6):386–408. <https://doi.org/10.1037/h0042519>
18. Rumelhart D.E., Hinton G.E., Williams R.J. Learning representations by back-propagating errors. *Nature.* 1986;**323**(6088):533–536. <https://doi.org/10.1038/323533a0>
19. LeCun Y., Bottou L., Bengio Y. et al. Gradient-based learning applied to document recognition. *Proc. IEEE.* 1998;**86**(11):2278–2324. <https://doi.org/10.1109/5.726791>
20. Gu J., Wang Z., Kuen J. et al. Recent advances in convolutional neural networks. *Pattern. Recognit.* 2018;**77**:354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>
21. Li Z., Liu F., Yang W. et al. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Trans. Neural Netw. Learn. Syst.* 2022;**33**(12):6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
22. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. *Adv. Neural Inf. Process. Syst.* 2012;**25**:1097–1105. <https://doi.org/10.1145/3065386>
23. Asiri A.A., Shaf A., Ali T. et al. Brain tumor detection and classification using fine-tuned CNN with ResNet50 and U-Net model: a study on TCGA-LGG and TCIA dataset for MRI applications. *Life.* 2023;**13**(7):1449. <https://doi.org/10.3390/life13071449>
24. Huang Z.-J., Patel B., Lu W.-H. et al. Yeast cell detection using fuzzy automatic contrast enhancement (FACE) and you only look once (YOLO). *Sci. Rep.* 2023;**13**(1):16222. <https://doi.org/10.1038/s41598-023-43452-9>
25. Quan T.M., Hildebrand D.G.C., Jeong W.-K. FusionNet: a deep fully residual convolutional neural network for image segmentation in connectomics. *Front. Comput. Sci.* 2021;**3**:613981. <https://doi.org/10.3389/fcomp.2021.613981>
26. Iqbal A., Sheikh A., Karayannis T. DeNeRD: high-throughput detection of neurons for brain-wide analysis with deep learning. *Sci. Rep.* 2019;**9**(1):13828. <https://doi.org/10.1038/s41598-019-50137-9>
27. Schubert P.J., Dorkenwald S., Januszewski M. et al. Learning cellular morphology with neural networks. *Nat. Commun.* 2019;**10**(1):2736. <https://doi.org/10.1038/s41467-019-10836-3>

28. Marks M., Jin Q., Sturman O. et al. Deep-learning-based identification, tracking, pose estimation and behavior classification of interacting primates and mice in complex environments. *Nat. Mach. Intell.* 2022;**4**(4):331–340. <https://doi.org/10.1038/s42256-022-00477-5>
29. Barreiros M.O., Dantas D.O., Silva L.C.O. et al. Zebrafish tracking using YOLOv2 and Kalman filter. *Sci. Rep.* 2021;**11**(1):3219. <https://doi.org/10.1038/s41598-021-81997-9>
30. Yu Y., Si X., Hu C. et al. A review of recurrent neural networks: LSTM cells and network architectures. *Neural Comput.* 2019;**31**(7):1235–1270. https://doi.org/10.1162/neco_a_01199
31. Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D.* 2020;**404**:132306. <https://doi.org/10.1016/j.physd.2019.132306>
32. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Comput.* 1997;**9**(8):1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
33. Van Houdt G., Mosquera C., Nápoles G. A review on the long short-term memory model. *Artif. Intell. Rev.* 2020;**53**(8):5929–5955. <https://doi.org/10.1007/s10462-020-09838-1>
34. Staudemeyer R.C., Morris E.R. Understanding LSTM – a tutorial into long short-term memory recurrent neural networks. *arXiv.* 2019:1909.09586. <https://doi.org/10.48550/arXiv.1909.09586>
35. Lipton Z.C., Kale D.C., Elkan C. et al. Learning to diagnose with LSTM recurrent neural networks. *arXiv.* 2015:1511.03677. <https://doi.org/10.48550/arXiv.1511.03677>
36. Goodfellow I.J., Pouget-Abadie J., Mirza M. et al. Generative adversarial nets. In: *Advances in Neural Information Processing Systems 27: 28th Annual Conference on Neural Information Processing Systems 2014 (December 8–13, 2014, Montreal, Canada)*. Curran Associates; 2015, Pp. 2672–2680.
37. Wang Z., She Q., Ward T.E. Generative adversarial networks in computer vision: a survey and taxonomy. *ACM Comput. Surv.* 2021;**54**(2):37. <https://doi.org/10.1145/3439723>
38. Gui J., Sun Z., Wen Y. et al. A review on generative adversarial networks: algorithms, theory, and applications. *IEEE Trans. Knowl. Data Eng.* 2023;**35**(4):3313–3332. <https://doi.org/10.1109/TKDE.2021.3130191>
39. Karras T., Laine S., Aila T. A style-based generator architecture for generative adversarial networks. *IEEE Trans. Pattern Anal. Mach. Intell.* 2020;**43**(12):4217–4228. <https://doi.org/10.1109/TPAMI.2020.2970919>
40. Ledig C., Theis L., Huszar F. et al. Photo-realistic single image super-resolution using a generative adversarial network. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017*. IEEE Computer Society; 2017, Pp. 4681–4690.
41. Yi X., Walia E., Babyn P. Generative adversarial network in medical imaging: a review. *Med. Image Anal.* 2019;**58**:101552. <https://doi.org/10.1016/j.media.2019.101552>

42. Pradeepkumar J., Anandakumar M., Kugathasan V. et al. Toward interpretable sleep stage classification using cross-modal transformers. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2024;**32**:2874–2885. <https://doi.org/10.1109/TNSRE.2024.3438610>
43. Vaswani A., Shazeer N., Parmar N. et al. Attention is all you need. *Adv. Neural Inf. Process. Syst.* 2017;**30**:5999–6009.
44. Lin T., Wang Y., Liu X. et al. A survey of transformers. *AI Open.* 2022;**3**:111–113. <https://doi.org/10.1016/j.aiopen.2022.10.001>
45. Tay Y., Dehghani M., Rao J. et al. Scale efficiently: insights from pre-training and fine-tuning transformers. *arXiv.* 2021:2109.10686. <https://doi.org/10.48550/arXiv.2109.10686>
46. Bahdanau D., Cho K., Bengio Y. Neural machine translation by jointly learning to align and translate. *Int. Conf. Learn. Represent. (ICLR).* 2015. <https://doi.org/10.48550/arXiv.1409.0473>
47. Luong M.T., Pham H., Manning C. Effective approaches to attention-based neural machine translation. In: *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing.* Association for Computational Linguistics; 2015, Pp. 1412–1421. <https://doi.org/10.18653/v1/D15-1166>
48. Ji Y., Zhou Z., Liu H. et al. DNABERT: pre-trained bidirectional encoder representations from transformers model for DNA-language in genome. *Bioinformatics.* 2021;**37**(15):2112–2120. <https://doi.org/10.1093/bioinformatics/btab083>
49. Avsec Ž., Agarwal V., Visentin D. et al. Effective gene expression prediction from sequence by integrating long-range interactions. *Nat. Methods.* 2021;**18**(10):1196–1203. <https://doi.org/10.1038/s41592-021-01252-x>
50. Shamshad F., Khan S., Zamir S.W. et al. Transformers in medical imaging: a survey. *Med. Image Anal.* 2023;**88**:102802. <https://doi.org/10.1016/j.media.2023.102802>
51. Lee J., Yoon W., Kim S. et al. BioBERT: a pre-trained biomedical language representation model for biomedical text mining. *Bioinformatics.* 2019;**36**(4):1234–1240. <https://doi.org/10.1093/bioinformatics/btz682>
52. Alsentzer E., Murphy J., Boag W. et al. Publicly available clinical BERT embeddings. In: *Proceedings of the 2nd Clinical Natural Language Processing Workshop.* Minneapolis: Association for Computational Linguistics; 2019, Pp. 72–78.
53. Dosovitskiy A., Beyer L., Kolesnikov A. et al. An image is worth 16×16 words: transformers for image recognition at scale. *Int. Conf. Learn. Represent. (ICLR).* 2021. <https://doi.org/10.48550/arXiv.2010.11929>
54. Fox B., Jiang J.J., Wickramaratne S. et al. A foundational transformer leveraging full-night, multichannel sleep study data accurately classifies sleep stages. *Sleep.* 2025;**48**(8):zsaf061. <https://doi.org/10.1093/sleep/zsaf061>
55. Kellmeyer P. Artificial intelligence in basic and clinical neuroscience: opportunities and ethical challenges. *Neuroforum.* 2019;**25**(4):241–250. <https://doi.org/10.1515/nf-2019-0018>
56. Litjens G., Sánchez C.I., Timofeeva N. et al. Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. *Sci. Rep.* 2016;**6**(1):26286. <https://doi.org/10.1038/srep26286>

57. Pereira S., Pinto A., Alves V. et al. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Trans. Med. Imaging*. 2016;**35**(5):1240–1251. <https://doi.org/10.1109/TMI.2016.2538465>
58. Akkus Z., Galimzianova A., Hoogi A. et al. Deep learning for brain MRI segmentation: state of the art and future directions. *J. Digit. Imaging*. 2017;**30**:449–459. <https://doi.org/10.1007/s10278-017-9983-4>
59. Gawehn E., Hiss J.A., Schneider G. Deep learning in drug discovery. *Mol. Inf.* 2016;**35**(1):3–14. <https://doi.org/10.1002/minf.201501008>
60. Hadar P.N., Zelmann R., Salami P. et al. The neurostimulationist will see you now: prescribing direct electrical stimulation therapies for the human brain in epilepsy and beyond. *Front. Hum. Neurosci.* 2024;**18**:1439541. <https://doi.org/10.3389/fnhum.2024.1439541>
61. Li Z., Huang J., Hu Z. Screening and diagnosis of chronic pharyngitis based on deep learning. *Int. J. Environ. Res. Public Health*. 2019;**16**(10):1688. <https://doi.org/10.3390/ijerph16101688>
62. Gupta N.S., Kumar P. Perspective of artificial intelligence in healthcare data management: a journey towards precision medicine. *Comput. Biol. Med.* 2023;**162**:107051. <https://doi.org/10.1016/j.combiomed.2023.107051>
63. Zhan A., Mohan S., Tarolli C. et al. Using smartphones and machine learning to quantify Parkinson disease severity: the mobile Parkinson disease score. *JAMA Neurol.* 2018;**75**(7):876–880. <https://doi.org/10.1001/jamaneurol.2018.0809>
64. Dias R., Torkamani A. Artificial intelligence in clinical and genomic diagnostics. *Genome Med.* 2019;**11**(1):70. <https://doi.org/10.1186/s13073-019-0689-8>
65. Marmar C.R., Brown A.D., Meng Q. et al. Speech-based markers for posttraumatic stress disorder in US veterans. *Depress. Anxiety*. 2019;**36**(7):607–616. <https://doi.org/10.1002/da.22890>
66. Maor E., Sara J.D., Orbelo D.M. et al. Voice signal characteristics are independently associated with coronary artery disease. *Mayo. Clin. Proc.* 2018;**93**(7):840–847. <https://doi.org/10.1016/j.mayocp.2017.12.025>
67. Luz S., Haider F., de la Fuente García S. et al. Alzheimer's dementia recognition through spontaneous speech. *Front. Comput. Neurosci.* 2021;**3**:780169. <https://doi.org/10.3389/fcomp.2021.780169>
68. McWhirter L., Ritchie C., Stone J. et al. Functional cognitive disorders: a systematic review. *Lancet Psychiatry*. 2020;**7**(2):191–207. [https://doi.org/10.1016/S2215-0366\(19\)30405-5](https://doi.org/10.1016/S2215-0366(19)30405-5)
69. Mirheidari B., Blackburn D., O'Malley R. et al. Computational cognitive assessment: investigating the use of an intelligent virtual agent for the detection of early signs of dementia. In: *2019 IEEE International Conference on Acoustics, Speech, and Signal Processing: Proceedings*. The Institute of Electrical and Electronics Engineers, Inc.; 2019, Pp. 2732–2736. <https://doi.org/10.1109/ICASSP.2019.8682423>
70. Ossadtchi A., Semenkov I., Zhuravleva A. et al. Representational dissimilarity component analysis (ReDisCA). *Neuroimage*. 2024;**301**:120868. <https://doi.org/10.1016/j.neuroimage.2024.120868>

71. Kriegeskorte N., Wei X.-X. Neural tuning and representational geometry. *Nat. Rev. Neurosci.* 2021;**22**(11):703–718. <https://doi.org/10.1038/s41583-021-00502-3>
72. Goldstein A., Grinstein-Dabush A., Schain M. et al. Alignment of brain embeddings and artificial contextual embeddings in natural language points to common geometric patterns. *Nat. Commun.* 2024;**15**(1):2768. <https://doi.org/10.1038/s41467-024-46631-y>
73. Pchitskaya E., Vasiliev P., Smirnova D. et al. SpineTool is an open-source software for analysis of morphology of dendritic spines. *Sci. Rep.* 2023;**13**(1):10561. <https://doi.org/10.1038/s41598-023-37406-4>
74. Segal M. Dendritic spines: morphological building blocks of memory. *Neurobiol. Learn. Mem.* 2017;**138**:3–9. <https://doi.org/10.1016/j.nlm.2016.06.007>
75. Chidambaram S.B., Rathipriya A., Bolla S.R. et al. Dendritic spines: revisiting the physiological role. *Prog. Neuropsychopharmacol. Biol. Psychiatry.* 2019;**92**:161–193. <https://doi.org/10.1016/j.pnpbp.2019.01.005>
76. Stein I.S., Zito K. Dendritic spine elimination: molecular mechanisms and implications. *Neuroscientist.* 2019;**25**(1):27–47. <https://doi.org/10.1177/1073858418769644>
77. Hatsopoulos N.G., Donoghue J.P. The science of neural interface systems. *Annu. Rev. Neurosci.* 2009;**32**(1):249–266. <https://doi.org/10.1146/annurev.neuro.051508.135241>
78. Mak J.N., Wolpaw J.R. Clinical applications of brain-computer interfaces: current state and future prospects. *IEEE Rev. Biomed. Eng.* 2009;**2**:187–199. <https://doi.org/10.1109/RBME.2009.2035356>
79. Al-Nafjan A., Hosny M., Al-Ohali Y. et al. Review and classification of emotion recognition based on EEG brain-computer interface system research: a systematic review. *Appl. Sci.* 2017;**7**(12):1239. <https://doi.org/10.3390/app7121239>
80. Abiri R., Borhani S., Sellers E.W. et al. A comprehensive review of EEG-based brain-computer interface paradigms. *J. Neural Eng.* 2019;**16**(1):011001. <https://doi.org/10.1088/1741-2552/aaf12e>
81. Angrick M., Ottenhoff M.C., Diener L. et al. Real-time synthesis of imagined speech processes from minimally invasive recordings of neural activity. *Commun. Biol.* 2021;**4**(1):1055. <https://doi.org/10.1038/s42003-021-02578-0>
82. Petrosyan A., Voskoboinikov A., Slioussar N. et al. Compact and interpretable architecture for speech decoding from iEEG. *Int. J. Psychophysiol.* 2021;**168**:S195. <https://doi.org/10.1109/CNN53494.2021.9580381>
83. Petrosyan A., Voskoboinikov A., Sukhinin D. et al. Speech decoding from a small set of spatially segregated minimally invasive intracranial EEG electrodes with a compact and interpretable neural network. *J. Neural Eng.* 2022;**19**(6):066016. <https://doi.org/10.1088/1741-2552/aca1e1>
84. Willett F.R., Kunz E.M., Fan C. et al. A high-performance speech neuroprosthesis. *Nature.* 2023;**620**(7976):1031–1036. <https://doi.org/10.1038/s41586-023-06377-x>
85. Silva A.B., Liu J.R., Metzger S.L. et al. A bilingual speech neuroprosthesis driven by cortical articulatory representations shared between languages. *Nat. Biomed. Eng.* 2024;**8**(8):977–991. <https://doi.org/10.1038/s41551-024-01207-5>

86. Pereira T.D., Shaevez J.W., Murthy M. Quantifying behavior to understand the brain. *Nat. Neurosci.* 2020;**23**(12):1537–1549.
<https://doi.org/10.1038/s41593-020-00734-z>
87. Shemesh Y., Chen A. A paradigm shift in translational psychiatry through rodent neuroethology. *Mol. Psychiatry.* 2023;**28**(3):993–1003.
<https://doi.org/10.1038/s41380-022-01913-z>
88. Krakauer J.W., Ghazanfar A.A., Gomez-Marín A. et al. Neuroscience needs behavior: correcting a reductionist bias. *Neuron.* 2017;**93**(3):480–490.
<https://doi.org/10.1016/j.neuron.2016.12.041>
89. Kuo J.Y., Denman A.J., Beacher N.J. et al. Using deep learning to study emotional behavior in rodent models. *Front. Behav. Neurosci.* 2022;**16**:1044492.
<https://doi.org/10.3389/fnbeh.2022.1044492>
90. Mathis A., Mamidanna P., Cury K.M. et al. DeepLabCut: markerless pose estimation of user-defined body parts with deep learning. *Nat. Neurosci.* 2018;**21**(9):1281–1289.
<https://doi.org/10.1038/s41593-018-0209-y>
91. Gomez-Marín A., Paton J.J., Kampff A.R. et al. Big behavioral data: psychology, ethology and the foundations of neuroscience. *Nat. Neurosci.* 2014;**17**(11):1455–1462.
<https://doi.org/10.1038/nn.3812>
92. Lahoz-Monfort J.J., Magrath M.J. A comprehensive overview of technologies for species and habitat monitoring and conservation. *BioScience.* 2021;**71**(10):1038–1062.
<https://doi.org/10.1093/biosci/biab073>
93. Dell A.I., Bender J.A., Branson K. et al. Automated image-based tracking and its application in ecology. *Trends. Ecol. Evol.* 2014;**29**(7):417–428.
<https://doi.org/10.1016/j.tree.2014.05.004>
94. Egnor S.R., Branson K. Computational analysis of behavior. *Annu. Rev. Neurosci.* 2016;**39**(1):217–236. <https://doi.org/10.1146/annurev-neuro-070815-013845>
95. Camomilla V., Bergamini E., Fantozzi S. et al. Trends supporting the in-field use of wearable inertial sensors for sport performance evaluation: a systematic review. *Sensors.* 2018;**18**(3):873. <https://doi.org/10.3390/s18030873>
96. Herath S., Harandi M., Porikli F. Going deeper into action recognition: a survey. *Image. Vis. Comput.* 2017;**60**:4–21. <https://doi.org/10.1016/j.imavis.2017.01.010>
97. Zhou T., Porikli F., Crandall D.J. et al. A survey on deep learning technique for video segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.* 2022;**45**(6):7099–7122.
<https://doi.org/10.1109/TPAMI.2022.3225573>
98. Zhou L., Zhang L., Konz N. Computer vision techniques in manufacturing. *IEEE Trans. Syst. Man Cybern. Syst.* 2022;**53**(1):105–117.
<https://doi.org/10.1109/TSMC.2022.3166397>
99. Colyer S.L., Evans M., Cosker D.P. et al. A review of the evolution of vision-based motion analysis and the integration of advanced computer vision methods towards developing a markerless system. *Sports Med. Open.* 2018;**4**:24.
<https://doi.org/10.1186/s40798-018-0139-y>

100. Litjens G., Kooi T., Bejnordi B.E. et al. A survey on deep learning in medical image analysis. *Med. Image Anal.* 2017;**42**:60–88. <https://doi.org/10.1016/j.media.2017.07.005>
101. Serre T. Deep learning: the good, the bad, and the ugly. *Annu. Rev. Vis. Sci.* 2019;**5**(1):399–426. <https://doi.org/10.1146/annurev-vision-091718-014951>
102. Zador A., Escola S., Richards B. et al. Catalyzing next-generation artificial intelligence through neuroAI. *Nat. Commun.* 2023;**14**(1):1597. <https://doi.org/10.1038/s41467-023-37180-x>
103. Weinreb C., Pearl J.E., Lin S. et al. Keypoint-MoSeq: parsing behavior by linking point tracking to pose dynamics. *Nat. Methods.* 2024;**21**(7):1329–1339. <https://doi.org/10.1038/s41592-024-02318-2>
104. Nath T., Mathis A., Chen A.C. et al. Using DeepLabCut for 3D markerless pose estimation across species and behaviors. *Nat. Protoc.* 2019;**14**(7):2152–2176. <https://doi.org/10.1038/s41596-019-0176-0>
105. Goodwin N.L., Choong J.J., Hwang S. et al. Simple behavioral analysis (SimBA) as a platform for explainable machine learning in behavioral neuroscience. *Nat. Neurosci.* 2024;**27**(7):1411–1424. <https://doi.org/10.1038/s41593-024-01649-9>
106. Geuther B.Q., Peer A., He H. et al. Action detection using a neural network elucidates the genetics of mouse grooming behavior. *eLife.* 2021;**10**:e63207. <https://doi.org/10.7554/eLife.63207>
107. Weber R.Z., Mulders G., Kaiser J. et al. Deep learning-based behavioral profiling of rodent stroke recovery. *BMC Biol.* 2022;**20**(1):232. <https://doi.org/10.1186/s12915-022-01434-9>
108. Aljovic A., Zhao S., Chahin M. et al. A deep learning-based toolbox for automated limb motion analysis (ALMA) in murine models of neurological disorders. *Commun. Biol.* 2022;**5**(1):131. <https://doi.org/10.1038/s42003-022-03077-6>
109. Wiltschko A.B., Johnson M.J., Iurilli G. et al. Mapping sub-second structure in mouse behavior. *Neuron.* 2015;**88**(6):1121–1135. <https://doi.org/10.1016/j.neuron.2015.11.031>
110. Hsu A.I., Yttri E.A. B-SoiD, an open-source unsupervised algorithm for identification and fast prediction of behaviors. *Nat. Commun.* 2021;**12**(1):5188. <https://doi.org/10.1038/s41467-021-25420-x>
111. Muralidharan A., Swaminathan A., Poulouse A. Deep learning dives: predicting anxiety in zebrafish through novel tank assay analysis. *Physiol. Behav.* 2024;**287**:114696. <https://doi.org/10.1016/j.physbeh.2024.114696>
112. Pereira T.D., Tabris N., Matsliah A. et al. SLEAP: a deep learning system for multi-animal pose tracking. *Nat. Methods.* 2022;**19**(4):486–495. <https://doi.org/10.1038/s41592-022-01426-1>
113. Cohen I.L., Gardner J.M., Karmel B.Z. et al. Rating scale measures are associated with Noldus EthoVision-XT video tracking of behaviors of children on the autism spectrum. *Mol. Autism.* 2014;**5**:15. <https://doi.org/10.1186/2040-2392-5-15>

114. Sabatos-DeVito M., Murias M., Dawson G. et al. Methodological considerations in the use of Noldus EthoVision XT video tracking of children with autism in multi-site studies. *Biol. Psychol.* 2019;**146**:107712.
<https://doi.org/10.1016/j.biopsycho.2019.05.012>
115. Noldus L.P., Spink A.J., Tegelenbosch R.A. EthoVision: a versatile video tracking system for automation of behavioral experiments. *Behav. Res. Methods Instrum. Comput.* 2001;**33**:398–414. <https://doi.org/10.3758/BF03196102>
116. Bühler D., Guerra N.P., Müller L. et al. Leptin deficiency-caused behavioral change – a comparative analysis using EthoVision and DeepLabCut. *Front. Neurosci.* 2023;**17**:1052079. <https://doi.org/10.3389/fnins.2023.1052079>
117. Sturman O., von Ziegler L., Schläppi C. et al. Deep learning-based behavioral analysis reaches human accuracy and is capable of outperforming commercial solutions. *Neuropsychopharmacology.* 2020;**45**(11):1942–1952.
<https://doi.org/10.1038/s41386-020-0776-y>
118. Marek S., Tervo-Clemmens B., Calabro F.J. et al. Reproducible brain-wide association studies require thousands of individuals. *Nature.* 2022;**603**(7902):654–660.
<https://doi.org/10.1038/s41586-022-04492-9>
119. Gerasimov E., Karasev V., Umnov S. et al. AI-powered mice behavior tracking and its application for neuronal manifold analysis based on hippocampal ensemble activity in an Alzheimer’s disease mice model. *Int. J. Mol. Sci.* 2025;**26**(15):7180.
<https://doi.org/10.3390/ijms26157180>
120. Kalueff A.V., Aldridge J.W., LaPorte J.L. et al. Analyzing grooming microstructure in neurobehavioral experiments. *Nat. Protoc.* 2007;**2**(10):2538–2544.
<https://doi.org/10.1038/nprot.2007.367>
121. Yu X., Taylor A.M., Nagai J. et al. Reducing astrocyte calcium signaling in vivo alters striatal microcircuits and causes repetitive behavior. *Neuron.* 2018;**99**(6):1170–1187.
<https://doi.org/10.1016/j.neuron.2018.08.015>
122. Daviu N., Bruchas M.R., Moghaddam B. et al. Neurobiological links between stress and anxiety. *Neurobiol. Stress.* 2019;**11**:100191.
<https://doi.org/10.1016/j.ynstr.2019.100191>
123. Dhawale A.K., Wolff S.B., Ko R. et al. The basal ganglia control the detailed kinematics of learned motor skills. *Nat. Neurosci.* 2021;**24**(9):1256–1269.
<https://doi.org/10.1038/s41593-021-00889-3>
124. Lipton D.M., Gonzales B.J., Citri A. Dorsal striatal circuits for habits, compulsions and addictions. *Front. Syst. Neurosci.* 2019;**13**:28.
<https://doi.org/10.3389/fnsys.2019.00028>
125. Hintiryan H., Foster N.N., Bowman I. et al. The mouse cortico-striatal projectome. *Nat. Neurosci.* 2016;**19**(8):1100–1114. <https://doi.org/10.1038/nn.4332>
126. Schmeisser M.J., Ey E., Wegener S. et al. Autistic-like behaviours and hyperactivity in mice lacking ProSAP1/Shank2. *Nature.* 2012;**486**(7402):256–260.
<https://doi.org/10.1038/nature11015>

127. Hsu A.I., Yttri E.A. B-SoiD, an open-source unsupervised algorithm for identification and fast prediction of behaviors. *Nat. Commun.* 2021;**12**(1):5188. <https://doi.org/10.1038/s41467-021-25420-x>
128. Apukhtin K.V., Shevlyakov A.D., Kotova M.M. Analiz gruminga gryzunov i ego povedencheskoy mikrostruktury v sovremennykh neyrobiologicheskikh issledovaniyakh [Analyses of Rodent Grooming and its Behavioral Microstructure in Modern Neurobiological Studies]. *Rossiyskiy fiziologicheskij zhurnal im. I.M. Sechenova = Russian Journal of Physiology.* 2024;**110**(6):889–914 (In Russ.). <https://doi.org/10.31857/S0869813924060022>
129. Kyzar E., Gaikwad S., Roth A. et al. Towards high-throughput phenotyping of complex patterned behaviors in rodents: focus on mouse self-grooming and its sequencing. *Behav. Brain Res.* 2011;**225**(2):426–431. <https://doi.org/10.1016/j.bbr.2011.07.052>
130. Groman S.M., Keistler C., Keip A.J. et al. Orbitofrontal circuits control multiple reinforcement-learning processes. *Neuron.* 2019;**103**(4):734–746. <https://doi.org/10.1016/j.neuron.2019.05.042>
131. Piantadosi S.C., Manning E.E., Chamberlain B.L. et al. Hyperactivity of indirect pathway-projecting spiny projection neurons promotes compulsive behavior. *Nat. Commun.* 2024;**15**(1):4434. <https://doi.org/10.1038/s41467-024-48331-z>
132. Van den Boom B.J., Pavlidi P., Wolf C.J. et al. Automated classification of self-grooming in mice using open-source software. *J. Neurosci. Methods.* 2017;**289**:48–56. <https://doi.org/10.1016/j.jneumeth.2017.05.026>
133. Zhou F., Jiang Z., Liu Z. et al. Structured context enhancement network for mouse pose estimation. *IEEE Trans. Circuits. Syst. Video. Technol.* 2021;**32**(5): 2787–2801. <https://doi.org/10.1109/TCSVT.2021.3098497>
134. Salem G., Krynitsky J., Hayes M. et al. Three-dimensional pose estimation for laboratory mouse from monocular images. *IEEE Trans. Image. Process.* 2019;**28**(9): 4273–4287. <https://doi.org/10.1109/TIP.2019.2908796>
135. Dunn T.W., Marshall J.D., Severson K.S. et al. Geometric deep learning enables 3D kinematic profiling across species and environments. *Nat. Methods.* 2021;**18**(5):564–573. <https://doi.org/10.1038/s41592-021-01106-6>
136. Pereira T.D., Aldarondo D.E., Willmore L. et al. Fast animal pose estimation using deep neural networks. *Nat. Methods.* 2019;**16**(1):117–125. <https://doi.org/10.1038/s41592-018-0234-5>
137. Graving J.M., Chae D., Naik H. et al. DeepPoseKit, a software toolkit for fast and robust animal pose estimation using deep learning. *eLife.* 2019;**8**:e47994. <https://doi.org/10.7554/eLife.47994>
138. Wang Z., Mirbozorgi S.A., Ghovanloo M. Towards a Kinect-based behavior recognition and analysis system for small animals. In: *2015 IEEE Biomedical Circuits and Systems Conference (BioCAS).* IEEE; 2015. <https://doi.org/10.1109/BioCAS.2015.7348456>

139. Karashchuk P., Rupp K.L., Dickinson E.S. et al. Anipose: a toolkit for robust markerless 3D pose estimation. *Cell Rep.* 2021;**36**(13):109730. <https://doi.org/10.1016/j.celrep.2021.109730>
140. Gerós A., Magalhães A., Aguiar P. Improved 3D tracking and automated classification of rodents' behavioral activity using depth-sensing cameras. *Behav. Res. Methods.* 2020;**52**(5):2156–2167. <https://doi.org/10.3758/s13428-020-01381-9>
141. Fayat R., Sarraudy M., Léna C. et al. DISSeCT: an unsupervised framework for high-resolution mapping of rodent behavior using inertial sensors. *PLoS Biol.* 2025;**23**(10):e3003431. <https://doi.org/10.1371/journal.pbio.3003431>
142. Van den Boom B.J.G., Pavlidi P., Wolf C.J.H. et al. Automated classification of self-grooming in mice using open-source software. *J. Neurosci. Methods.* 2017;**289**:48–56. <https://doi.org/10.1016/j.jneumeth.2017.05.026>
143. Simon P., Dupuis R., Costentin J. Thigmotaxis as an index of anxiety in mice: influence of dopaminergic transmissions. *Behav. Brain Res.* 1994;**61**(1):59–64. [https://doi.org/10.1016/0166-4328\(94\)90008-6](https://doi.org/10.1016/0166-4328(94)90008-6)
144. Hong W., Kennedy A., Burgos-Artizzu X.P. et al. Automated measurement of mouse social behaviors using depth sensing, video tracking, and machine learning. *Proc. Natl. Acad. Sci. U. S. A.* 2015;**112**(38):E5351–E5360. <https://doi.org/10.1073/pnas.1515982112>
145. Hardin A., Schlupp I. Using machine learning and DeepLabCut in animal behavior. *Acta Ethol.* 2022;**25**(3):125–133. <https://doi.org/10.1007/s10211-022-00397-y>
146. Itskov P.M., Moreira J.M., Vinnik E. et al. Automated monitoring and quantitative analysis of feeding behavior in *Drosophila*. *Nat. Commun.* 2014;**5**(1):4560. <https://doi.org/10.1038/ncomms5560>
147. Wang C., Shen J. Deep learning-driven behavioral analysis reveals adaptive responses in *Drosophila* offspring after long-term parental microplastic exposure. *J. Environ. Manage.* 2025;**376**:124502. <https://doi.org/10.1016/j.jenvman.2025.124502>
148. Branson K., Robie A.A., Bender J. et al. High-throughput ethomics in large groups of *Drosophila*. *Nat. Methods.* 2009;**6**(6):451–457. <https://doi.org/10.1038/nmeth.1328>
149. Grieco F., Bernstein B.J., Biemans B. et al. Measuring behavior in the home cage: study design, applications, challenges, and perspectives. *Front. Behav. Neurosci.* 2021;**15**:735387. <https://doi.org/10.3389/fnbeh.2021.735387>
150. Salido A.G., de la Herrán R., Robles F. et al. Automatic counting and identification of two *Drosophila melanogaster* (Diptera: Drosophilidae) morphs with image-recognition artificial intelligence. *Can. Entomol.* 2024;**156**:e40. <https://doi.org/10.4039/tce.2024.36>
151. Keleş M.F., Sapci A.O.B., Brody C. et al. FlyVISTA, an integrated machine learning platform for deep phenotyping of sleep in *Drosophila*. *Sci. Adv.* 2025;**11**(11):eadq8131. <https://doi.org/10.1126/sciadv.adq8131>
152. Lin J.-L., Kuo W.-L., Huang Y.-H. et al. Using convolutional neural networks to measure the physiological age of *Caenorhabditis elegans*. *IEEE/ACM Trans. Comput. Biol. Bioinform.* 2020;**18**(6):2724–2732. <https://doi.org/10.1109/TCBB.2020.2971992>

153. Park C.F., Barzegar-Keshteli M., Korchagina K. et al. Automated neuron tracking inside moving and deforming *C. elegans* using deep learning and targeted augmentation. *Nat. Methods*. 2024;**21**(1):142–149. <https://doi.org/10.1038/s41592-023-02096-3>
154. Swierczek N.A., Giles A.C., Rankin C.H. et al. High-throughput behavioral analysis in *C. elegans*. *Nat. Methods*. 2011;**8**(7):592–598. <https://doi.org/10.1038/nmeth.1625>
155. DuPlissis A., Medewar A., Hegarty E. et al. Machine learning-based analysis of microfluidic device immobilized *C. elegans* for automated developmental toxicity testing. *Sci. Rep.* 2025;**15**(1):15. <https://doi.org/10.1038/s41598-024-84842-x>
156. Pan P., Zhang P., Premachandran S. et al. High-resolution imaging and morphological phenotyping of *C. elegans* through stable robotic sample rotation and artificial intelligence-based 3-dimensional reconstruction. *Research*. 2024;**7**:0513. <https://doi.org/10.34133/research.0513>
157. Kalueff A.V., Stewart A.M., Gerlai R. Zebrafish as an emerging model for studying complex brain disorders. *Trends Pharmacol. Sci.* 2014;**35**(2):63–75. <https://doi.org/10.1016/j.tips.2013.12.002>
158. Stewart A.M., Grieco F., Tegelenbosch R.A.J. et al. A novel 3D method of locomotor analysis in adult zebrafish: implications for automated detection of CNS drug-evoked phenotypes. *J. Neurosci. Methods*. 2015;**255**:66–74. <https://doi.org/10.1016/j.jneumeth.2015.07.023>
159. Li Y., Chen T., Miao X. et al. Zebrafish: a promising in vivo model for assessing the delivery of natural products, fluorescence dyes and drugs across the blood-brain barrier. *Pharmacol. Res.* 2017;**125**:246–257. <https://doi.org/10.1016/j.phrs.2017.08.017>
160. Kokel D., Peterson R.T. Chemobehavioural phenomics and behaviour-based psychiatric drug discovery in the zebrafish. *Brief. Funct. Genom. Proteom.* 2008;**7**(6):483–490. <https://doi.org/10.1093/bfgp/eln040>
161. Bailey J.M., Oliveri A.N., Levin E.D. Pharmacological analyses of learning and memory in zebrafish (*Danio rerio*). *Pharmacol. Biochem. Behav.* 2015;**139**:103–111. <https://doi.org/10.1016/j.pbb.2015.03.006>
162. Stewart A.M., Kalueff A.V. The developing utility of zebrafish models for cognitive enhancers research. *Curr. Neuropharmacol.* 2012;**10**(3):263–271. <https://doi.org/10.2174/157015912803217323>
163. Geng Y., Yates C., Peterson R.T. Social behavioral profiling by unsupervised deep learning reveals a stimulative effect of dopamine D3 agonists on zebrafish sociality. *Cell Rep. Methods*. 2023;**3**(1):100381. <https://doi.org/10.1016/j.crmeth.2022.100381>
164. Gore S.V., Kakodkar R., Del Rosario Hernández T. et al. Zebrafish Larvae Position Tracker (Z-LaP Tracker): a high-throughput deep-learning behavioral approach for the identification of calcineurin pathway-modulating drugs using zebrafish larvae. *Sci. Rep.* 2023;**13**(1):3174. <https://doi.org/10.1038/s41598-023-30303-w>
165. Kokel D., Bryan J., Laggner C. et al. Rapid behavior-based identification of neuroactive small molecules in the zebrafish. *Nat. Chem. Biol.* 2010;**6**(3):231–237. <https://doi.org/10.1038/nchembio.307>

166. Brockerhoff S.E., Hurley J.B., Janssen-Bienhold U. et al. A behavioral screen for isolating zebrafish mutants with visual system defects. *Proc. Natl. Acad. Sci. U. S. A.* 1995;**92**(23):10545–10549. <https://doi.org/10.1073/pnas.92.23.10545>
167. Neuhauss S.C., Biehmaier O., Seeliger M.W. et al. Genetic disorders of vision revealed by a behavioral screen of 400 essential loci in zebrafish. *J. Neurosci.* 1999;**19**(19):8603–8615. <https://doi.org/10.1523/jneurosci.19-19-08603.1999>
168. Burgess H.A., Granato M. Sensorimotor gating in larval zebrafish. *J. Neurosci.* 2007;**27**(18):4984–4994. <https://doi.org/10.1523/jneurosci.0615-07.2007>
169. Prober D.A., Rihel J., Onah A.A. et al. Hypocretin/orexin overexpression induces an insomnia-like phenotype in zebrafish. *J. Neurosci.* 2006;**26**(51):13400–13410. <https://doi.org/10.1523/jneurosci.4332-06.2006>
170. Zhdanova I.V., Wang S.Y., LeClair O.U. et al. Melatonin promotes sleep-like state in zebrafish. *Brain Res.* 2001;**903**(1–2):263–268. [https://doi.org/10.1016/s0006-8993\(01\)02444-1](https://doi.org/10.1016/s0006-8993(01)02444-1)
171. Brockerhoff S.E. Measuring the optokinetic response of zebrafish larvae. *Nat. Protoc.* 2006;**1**(5):2448–2451. <https://doi.org/10.1038/nprot.2006.255>
172. Muto A., Orger M.B., Wehman A.M. et al. Forward genetic analysis of visual behavior in zebrafish. *PLoS Genet.* 2005;**1**(5):e66. <https://doi.org/10.1371/journal.pgen.0010066>
173. Laggner C., Kokel D., Setola V. et al. Chemical informatics and target identification in a zebrafish phenotypic screen. *Nat. Chem. Biol.* 2011;**8**(2):144–146. <https://doi.org/10.1038/nchembio.732>
174. McCarroll M.N., Gendele L., Kinser R. et al. Zebrafish behavioural profiling identifies GABA and serotonin receptor ligands related to sedation and paradoxical excitation. *Nat. Commun.* 2019;**10**(1):4078. <https://doi.org/10.1038/s41467-019-11936-w>
175. Braun D., Rosenberg A.M., Rabaniam E. et al. High-resolution tracking of unconfined zebrafish behavior reveals stimulatory and anxiolytic effects of psilocybin. *Mol. Psychiatry.* 2024;**29**(4):1046–1062. <https://doi.org/10.1038/s41380-023-02391-7>
176. Soleymani A., Cachat J., Robinson K. et al. Integrating cross-scale analysis in the spatial and temporal domains for classification of behavioral movement. *J. Spat. Inf. Sci.* 2014;**8**:1–25. <https://doi.org/10.5311/josis.2014.8.162>
177. Lukovikov D.A., Kolesnikova T.O., Ikrin A.N. et al. A novel open-access artificial-intelligence-driven platform for CNS drug discovery utilizing adult zebrafish. *J. Neurosci. Methods.* 2024;**411**:110256. <https://doi.org/10.1016/j.jneumeth.2024.110256>
178. Bozhko D.V., Myrov V.O., Kolchanova S.M. et al. Artificial intelligence-driven phenotyping of zebrafish psychoactive drug responses. *Prog. Neuropsychopharmacol. Biol. Psychiatry.* 2022;**112**:110405. <https://doi.org/10.1016/j.pnpbp.2021.110405>
179. Demin K.A., Kupriyanova O.V., Shevyrin V.A. et al. Acute behavioral and neurochemical effects of novel N-benzyl-2-phenylethylamine derivatives in adult zebrafish. *ACS Chem. Neurosci.* 2022;**13**(13):1902–1922. <https://doi.org/10.1021/acscchemneuro.2c00123>

180. Myrov V.O., Polovian A.I., Kolchanova S. et al. Artificial neural network (ANN)-based pattern recognition approach illustrates a biphasic behavioral effect of ethanol in zebrafish: a high-throughput method for animal locomotor analysis. *Bio-medicines*. 2023;**11**(12):3215. <https://doi.org/10.3390/biomedicines11123215>
181. Marques J.C., Lackner S., Félix R. et al. Structure of the zebrafish locomotor repertoire revealed with unsupervised behavioral clustering. *Curr. Biol.* 2018;**28**(2):181–195. <https://doi.org/10.1016/j.cub.2017.12.002>
182. Qi X., Huynh V., Parolari T.G. et al. Zebrafish larvae heartbeat detection from body deformation in low resolution and low frequency video. *Med. Biol. Eng. Comput.* 2018;**56**(12):2353–2365. <https://doi.org/10.1007/s11517-018-1863-7>
183. Liu C., Wang Y., Zeng Y. et al. Use of deep-learning assisted assessment of cardiac parameters in zebrafish to discover cyanidin chloride as a novel Keap1 inhibitor against doxorubicin-induced cardiotoxicity. *Adv. Sci.* 2023;**10**(30):2301136. <https://doi.org/10.1002/advs.202301136>
184. Abangan A.S., Kopp D., Faillettaz R. Artificial intelligence for fish behavior recognition may unlock fishing gear selectivity. *Front. Mar. Sci.* 2023;**10**:1010761. <https://doi.org/10.3389/fmars.2023.1010761>
185. He S. Modeling oral dyskinesias in zebrafish, and its AI-powered models. *Sci. Hangzhou*. 2025;P1-033.
186. He S., Yang L., Bai Y. et al. Studying oral dyskinesias using AI in zebrafish. In: *Proceedings of the Neuroscience Week-2025: 3rd Joint Meeting “Neuroscience Week-2025”, Yerevan, Armenia, 16–19 May, 2025*.
187. Challa A.P., Beam A.L., Shen M. et al. Machine learning on drug-specific data to predict small molecule teratogenicity. *Reprod. Toxicol.* 2020;**95**:148–158. <https://doi.org/10.1016/j.reprotox.2020.05.004>
188. Ahuja A.S. The impact of artificial intelligence in medicine on the future role of the physician. *PeerJ*. 2019;**7**:e7702. <https://doi.org/10.7717/peerj.7702>
189. Sakamoto N., Haraguchi T., Kobayashi K. et al. Automated scratching detection system for black mouse using deep learning. *Front. Physiol.* 2022;**13**:939281. <https://doi.org/10.3389/fphys.2022.939281>
190. Ozdemir Y., Nakamoto K., Boivin B. et al. Quantification of stimulus-evoked tactile allodynia in free moving mice by the chainmail sensitivity test. *Front. Pharmacol.* 2024;**15**:1352464. <https://doi.org/10.3389/fphar.2024.1352464>
191. Manno F.A., Cheung P., Basnet V. et al. Subtle alterations of vestibulomotor functioning in conductive hearing loss. *Front. Neurosci.* 2023;**17**:1057551. <https://doi.org/10.3389/fnins.2023.1057551>
192. Geng W., Cosman P., Berry C.C. et al. Automatic tracking, feature extraction and classification of *C. elegans* phenotypes. *IEEE Trans. Biomed. Eng.* 2004;**51**(10):1811–1820. <https://doi.org/10.1109/TBME.2004.831532>
193. Zhan W., Chen W., Pan Y. Automated recognition and analysis of escape response in *Caenorhabditis elegans*. *IEEE/ACM Trans. Comput. Biol. Bioinform.* 2025;**22**(3):1201–1210. <https://doi.org/10.1109/TCBBIO.2025.3552631>
194. Hughes N.C., Roberts D.C., Tarchini B. et al. Instrumented swim test for quantifying motor impairment in rodents. *Sci. Rep.* 2024;**14**(1):29270. <https://doi.org/10.1038/s41598-024-80344-y>

195. Dingemans A.J., Hinne M., Truijen K.M. et al. PhenoScore quantifies phenotypic variation for rare genetic diseases by combining facial analysis with other clinical features using a machine-learning framework. *Nat. Genet.* 2023;**55**(9):1598–1607. <https://doi.org/10.1038/s41588-023-01469-w>
196. Hasin Y., Seldin M., Lusic A. Multi-omics approaches to disease. *Genome Biol.* 2017;**18**(1):83. <https://doi.org/10.1186/s13059-017-1215-1>
197. Qiu S., Miller M.I., Joshi P.S. et al. Multimodal deep learning for Alzheimer's disease dementia assessment. *Nat. Commun.* 2022;**13**(1):3404. <https://doi.org/10.1038/s41467-022-31037-5>
198. Kline A., Wang H., Li Y. et al. Multimodal machine learning in precision health: a scoping review. *NPJ Digit. Med.* 2022;**5**(1):171. <https://doi.org/10.1038/s41746-022-00712-8>
199. Shi J., Zheng X., Li Y. et al. Multimodal neuroimaging feature learning with multimodal stacked deep polynomial networks for diagnosis of Alzheimer's disease. *IEEE J. Biomed. Health Inform.* 2017;**22**(1):173–183. <https://doi.org/10.1109/JBHI.2017.2655720>
200. Hinrichs C., Singh V., Xu G. et al. Predictive markers for AD in a multi-modality framework: an analysis of MCI progression in the ADNI population. *Neuroimage.* 2011;**55**(2):574–589. <https://doi.org/10.1016/j.neuroimage.2010.10.081>
201. Zhang D., Wang Y., Zhou L. et al. Multimodal classification of Alzheimer's disease and mild cognitive impairment. *Neuroimage.* 2011;**55**(3):856–867. <https://doi.org/10.1016/j.neuroimage.2011.01.008>
202. Gao X., Shi F., Shen D. et al. Multimodal transformer network for incomplete image generation and diagnosis of Alzheimer's disease. *Comput. Med. Imaging Graph.* 2023;**110**:102303. <https://doi.org/10.1016/j.compmedimag.2023.102303>
203. Wang E.Y., Fahey P.G., Ding Z. et al. Foundation model of neural activity predicts response to new stimulus types. *Nature.* 2025;**640**(8058):470–477. <https://doi.org/10.1038/s41586-025-08829-y>
204. Sinz F., Ecker A.S., Fahey P. et al. Stimulus domain transfer in recurrent models for large scale cortical population prediction on video. *Adv. Neural Inf. Process. Syst.* 2018;**31**:7632–7643. <https://doi.org/10.1101/452672>
205. Subramanian I., Verma S., Kumar S. et al. Multi-omics data integration, interpretation, and its application. *Bioinform. Biol. Insights.* 2020;**14**:1177932219899051. <https://doi.org/10.1177/1177932219899051>
206. Nam Y., Kim J., Jung S.-H. et al. Harnessing artificial intelligence in multimodal omics data integration: paving the path for the next frontier in precision medicine. *Annu. Rev. Biomed. Data Sci.* 2024;**7**:153–175. <https://doi.org/10.1146/annurev-biodatasci-102523-103801>
207. Rudroff T. Artificial intelligence as a replacement for animal experiments in neurology: potential, progress, and challenges. *Neurol. Int.* 2024;**16**(4):805–820. <https://doi.org/10.3390/neurolint16040060>

208. Bailey J. Does the stress inherent to laboratory life and experimentation on animals adversely affect research data? *Altern. Lab. Anim.* 2017;**45**(6):299–301. <https://doi.org/10.1177/026119291704500605>
209. Bruni G., Rennekamp A.J., Velenich A. et al. Zebrafish behavioral profiling identifies multitarget antipsychotic-like compounds. *Nat. Chem. Biol.* 2016;**12**(7):559–566. <https://doi.org/10.1038/nchembio.2097>
210. Gendelev L., Taylor J., Myers-Turnbull D. et al. Deep phenotypic profiling of neuroactive drugs in larval zebrafish. *Nat. Commun.* 2024;**15**(1):9955. <https://doi.org/10.1038/s41467-024-54375-y>
211. von Ziegler L., Sturman O., Bohacek J. Big behavior: challenges and opportunities in a new era of deep behavior profiling. *Neuropsychopharmacology.* 2021;**46**(1):33–44. <https://doi.org/10.1038/s41386-020-0751-7>
212. Segalin C., Williams J., Karigo T. et al. The Mouse Action Recognition System (MARS) software pipeline for automated analysis of social behaviors in mice. *eLife.* 2021;**10**:e63720. <https://doi.org/10.7554/eLife.63720>
213. Mavrogiorgos K., Kiourtis A., Mavrogiorgou A. et al. Bias in machine learning: a literature review. *Appl. Sci.* 2024;**14**(19):8860. <https://doi.org/10.3390/app14198860>
214. Fontana B., Marion J., Rosemberg D. Swimming into the future: machine learning in zebrafish behavioral research. *Prog. Neuropsychopharmacol. Biol. Psychiatry.* 2025;**139**:111398. <https://doi.org/10.1016/j.pnpbp.2025.111398>
215. Guidotti R., Monreale A., Ruggieri S. et al. A survey of methods for explaining black box models. *ACM Comput. Surv.* 2018;**51**(5):93. <https://doi.org/10.1145/3236009>
216. Lundberg S.M., Lee S.I. A unified approach to interpreting model predictions. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*. Curran Associates Inc.; 2017, Pp. 4768–4777. <https://doi.org/10.48550/arXiv.1705.07874>
217. Yang G.R., Wang X.-J. Artificial neural networks for neuroscientists: a primer. *Neuron.* 2020;**107**(6):1048–1070. <https://doi.org/10.48550/arXiv.2006.01001>
218. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nat. Mach. Intell.* 2019;**1**(5):206–215. <https://doi.org/10.1038/s42256-019-0048-x>
219. Gunning D., Stefik M., Choi J. et al. XAI – Explainable artificial intelligence. *Sci. Robot.* 2019;**4**(37):eaay7120. <https://doi.org/10.1126/scirobotics.aay7120>
220. Shah P., Kendall F., Khozin S. et al. Artificial intelligence and machine learning in clinical development: a translational perspective. *NPJ Digit. Med.* 2019;**2**(1):69. <https://doi.org/10.1038/s41746-019-0148-3>
221. Gerke S., Minssen T., Cohen G. Ethical and legal challenges of artificial intelligence-driven healthcare. In: A. Bohr, K. Memarzadeh (eds.) *Artificial Intelligence in Healthcare*. Academic Press; 2020, Pp. 295–336. <https://doi.org/10.1016/B978-0-12-818438-7.00012-5>
222. Vayena E., Blasimme A., Cohen I.G. Machine learning in medicine: addressing ethical challenges. *PLoS Med.* 2018;**15**(11):e1002689. <https://doi.org/10.1371/journal.pmed.1002689>

223. Price W.N., Cohen I.G. Privacy in the age of medical big data. *Nat. Med.* 2019;**25**(1):37–43. <https://doi.org/10.1038/s41591-018-0272-7>
224. Dixit P. Transfer learning in image recognition: leveraging pre-trained models for improved performance. *Edu. J. Int. Aff. Res.* 2023;**2**(4):31–37.
225. Gupta A., Eysenbach B., Finn C. et al. Unsupervised meta-learning for reinforcement learning. *arXiv.* 2018:1806.04640. <https://doi.org/10.48550/arXiv.1806.04640>
226. Chaloner K., Verdinelli I. Bayesian experimental design: a review. *Stat. Sci.* 1995;**10**(3):273–304. <https://doi.org/10.1214/ss/1177009939>
227. Baltrušaitis T., Ahuja C., Morency L.P. Multimodal machine learning: a survey and taxonomy. *IEEE Trans. Pattern Anal. Mach. Intell.* 2019;**41**(2):423–443. <https://doi.org/10.1109/TPAMI.2018.2798607>
228. Chen R.J., Wang J.J., Williamson D.F.K. et al. Algorithmic fairness in artificial intelligence for medicine and healthcare. *Nat. Biomed. Eng.* 2023;**7**(6):719–742. <https://doi.org/10.1038/s41551-023-01056-8>
229. Vamathevan J., Clark D., Czodrowski P. et al. Applications of machine learning in drug discovery and development. *Nat. Rev. Drug Discov.* 2019;**18**(6):463–477. <https://doi.org/10.1038/s41573-019-0024-5>
230. Huang S., Yang J., Fong S. et al. Artificial intelligence in cancer diagnosis and prognosis: opportunities and challenges. *Cancer Lett.* 2020;**471**:61–71. <https://doi.org/10.1016/j.canlet.2019.12.007>
231. Bruni G., Lakhani P., Kokel D. Discovering novel neuroactive drugs through high-throughput behavior-based chemical screening in the zebrafish. *Front. Pharmacol.* 2014;**5**:153. <https://doi.org/10.3389/fphar.2014.00153>
232. Kokel D., Rennekamp A.J., Shah A.H. et al. Behavioral barcoding in the cloud: embracing data-intensive digital phenotyping in neuropharmacology. *Trends Biotechnol.* 2012;**30**(8):421–425. <https://doi.org/10.1016/j.tibtech.2012.05.001>
233. Davies M., Srinivasa N., Lin T.H. et al. Loihi: a neuromorphic manycore processor with on-chip learning. *IEEE Micro.* 2018;**38**(1):82–99. <https://doi.org/10.1109/MM.2018.112130359>
234. Merolla P.A., Arthur J.V., Alvarez-Icaza R. et al. A million spiking-neuron integrated circuit with a scalable communication network and interface. *Science.* 2014;**345**(6197):668–673. <https://doi.org/10.1126/science.1254642>
235. Leunenکو A.O. Neyromorfnyy iskusstvennyy intellekt: printsipy, tekhnologii i perspektivy razvitiya [Neuromorphic artificial intelligence: principles, technologies, and development prospects]. *TOGU-Start: Fundamental and Applied Research of Young People. Materials of the 6th Regional Scientific and Practical Conference.* Khabarovsk, April 7–12, 2025. Pacific State University; 2025, Pp. 148–157 (In Russ.).
236. Tang J., Yuan F., Shen X. et al. Bridging biological and artificial neural networks with emerging neuromorphic devices: fundamentals, progress, and challenges. *Adv. Mater.* 2019;**31**(49):1902761. <https://doi.org/10.1002/adma.201902761>
237. Potter S.M., El Hady A., Fetz E.E. Closed-loop neuroscience and neuroengineering. *Front. Neural Circuits.* 2014;**8**:115. <https://doi.org/10.3389/fncir.2014.00115>

238. Kim T.H., Zhang Y., Lecoq J. et al. Long-term optical access to an estimated one million neurons in the live mouse cortex. *Cell Rep.* 2016;**17**(12):3385–3394. <https://doi.org/10.1016/j.celrep.2016.12.004>
239. Ahrens M.B., Orger M.B., Robson D.N. et al. Whole-brain functional imaging at cellular resolution using light-sheet microscopy. *Nat. Methods.* 2013;**10**(5):413–420. <https://doi.org/10.1038/nmeth.2434>
240. Korkos A. Intel’s Pohoiki Beach, a 64-chip neuromorphic system, delivers breakthrough results in research tests. Available at: <https://www.intc.com/news-events/press-releases/detail/61/intels-pohoiki-beach-a-64-chip-neuromorphic-system> [Accessed: 15.07.2019]
241. Salter J. Brains scale better than CPUs. So Intel is building brains. Available at: <https://arstechnica.com/science/2019/07/brains-scale-better-than-cpus-so-intel-is-building-brains/> [Accessed: 15.07.2019]
242. Korkos A. Intel scales neuromorphic research system to 100 million neurons. Available from: <https://www.intc.com/news-events/press-releases/detail/12/intel-scales-neuromorphic-research-system-to-100-million> [Accessed: 17.04.2025]
243. Ward-Foxton S. Intel scales neuromorphic computer to 100 million neurons. Available from: <https://www.eetimes.com/intel-scales-neuromorphic-computer-to-100-million-neurons/> [Accessed: 17.04.2025]
244. Naveros F., Garrido J.A., Carrillo R.R. et al. Event-and time-driven techniques using parallel CPU-GPU co-processing for spiking neural networks. *Front. Neuroinform.* 2017;**11**:7. <https://doi.org/10.3389/fninf.2017.00007>
245. Angotzi G.N., Boi F., Zordan S., Bonfanti A., Vato A. A programmable closed-loop recording and stimulating wireless system for behaving small laboratory animals. *Sci. Rep.* 2014;**4**(1):5963.
246. Pfeiffer M., Pfeil T. Deep learning with spiking neurons: opportunities and challenges. *Front. Neurosci.* 2018;**12**:774. <https://doi.org/10.3389/fnins.2018.00774>
247. Tavanaei A., Maida A. BP-STDP: approximating backpropagation using spike timing-dependent plasticity. *Neurocomputing.* 2019;**330**:39–47. <https://doi.org/10.1016/j.neucom.2018.11.014>
248. Lee C., Panda P., Srinivasan G. et al. Training deep spiking convolutional neural networks with STDP-based unsupervised pre-training followed by supervised fine-tuning. *Front. Neurosci.* 2018;**12**:435. <https://doi.org/10.3389/fnins.2018.00435>
249. Bellec G., Scherr F., Subramoney A. et al. A solution to the learning dilemma for recurrent networks of spiking neurons. *Nat. Commun.* 2020;**11**(1):3625. <https://doi.org/10.1038/s41467-020-17236-y>
250. Kaiser J., Mostafa H., Neftci E. Synaptic plasticity dynamics for deep continuous local learning (DECOLLE). *Front. Neurosci.* 2020;**14**:424. <https://doi.org/10.3389/fnins.2020.00424>
251. Sze V., Chen Y.-H., Yang T.-J. et al. Efficient processing of deep neural networks: a tutorial and survey. *Proc. IEEE.* 2017;**105**(12):2295–2329. <https://doi.org/10.1109/JPROC.2017.2761740>
252. Lin C.-K., Wild A., Chinya G.N. et al. Programming spiking neural networks on Intel’s Loihi. *Computer.* 2018;**51**(3):52–61. <https://doi.org/10.1109/MC.2018.157113521>

253. Kudithipudi D., Schuman C., Vineyard C.M. et al. Neuromorphic computing at scale. *Nature*. 2025;**637**(8047):801–812.
<https://doi.org/10.1038/s41586-024-08253-8>
254. Davies M., Wild A., Orchard G. et al. Advancing neuromorphic computing with Loihi: a survey of results and outlook. *Proc. IEEE*. 2021;**109**(5):911–934.
<https://doi.org/10.1109/JPROC.2021.3067593>
255. Schuman C.D., Kulkarni S.R., Parsa M. et al. Opportunities for neuromorphic computing algorithms and applications. *Nat. Comput. Sci*. 2022;**2**(1):10–19.
<https://doi.org/10.1038/s43588-021-00184-y>
256. Vogginger B., Rostami A.H., Jain V. et al. Neuromorphic hardware for sustainable AI data centers. *arXiv*. 2024:2402.02521. <https://doi.org/10.48550/arXiv.2402.02521>
257. Kulkarni S.R., Rajendran B. Spiking neural networks for handwritten digit recognition – supervised learning and network optimization. *Neural Netw*. 2018;**103**:118–127.
<https://doi.org/10.1016/j.neunet.2018.03.019>
258. Hazan H., Saunders D.J., Khan H. et al. BindsNET: a machine learning-oriented spiking neural networks library in Python. *Front. Neuroinform*. 2018;**12**:89.
<https://doi.org/10.3389/fninf.2018.00089>
259. Baratta A.M., Brandner A.J., Plasil S.L. et al. Advancements in genomic and behavioral neuroscience analysis for the study of normal and pathological brain function. *Frontiers in Molecular Neuroscience*. 2022;**15**:905328.
<https://doi.org/10.3389/fnmol.2022.905328>

СВЕДЕНИЯ ОБ АВТОРАХ

Апухтин Кирилл Владимирович – мл. науч. сотр. направления «Нейробиология»,
НТУ «Сириус», Федеральная территория Сириус, Российская Федерация
E-mail: kirillapuhtin@mail.ru
<https://orcid.org/0009-0008-3796-9794>

Золотова Анастасия Эдуардовна – студентка бакалавриата,
Институт биомедицинских систем и технологий, СПбПУ,
Санкт-Петербург, Российская Федерация
E-mail: anastaiaythere@gmail.com

Леуенко Артем Олегович – студент магистратуры,
Научный центр информационных технологий и искусственного интеллекта,
НТУ «Сириус», Федеральная территория Сириус, Российская Федерация
E-mail: al.university.edu@yandex.ru
<https://orcid.org/0009-0001-7784-6245>

Перфилова Валентина Николаевна – д-р биол. наук;
проф., Волгоградский государственный медицинский университет,
Волгоград, Российская Федерация
E-mail: vnperfilova@mail.ru
<https://orcid.org/0000-0002-2457-8486>

Калуев Алан Валерьевич – д-р биол. наук;
проф. РАН; руководитель группы НМИЦ им. В.А. Алмазова МЗ РФ,
Санкт-Петербург, Российская Федерация
E-mail: avkalueff@gmail.com
<https://orcid.org/0000-0002-7525-1950>

Поступила в редакцию 25.06.2025

После доработки 14.10.2025

Принята к публикации 15.10.2025

ABOUT THE AUTHORS

Apukhtin, Kirill V. – Research Assistant, Neurobiology Division, Sirius University of Science and Technology, Federal Territory Sirius, Russian Federation
E-mail: kirillapukhtin@mail.ru
<https://orcid.org/0009-0008-3796-9794>

Zolotova, Anastasia E. – Undergraduate Student, Institute of Biomedical Systems and Technologies, Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russian Federation
E-mail: anastaiaythere@gmail.com

Leunenکو, Artem O. – Master's Degree Student, Scientific Center for Information Technologies and Artificial Intelligence, Sirius University of Science and Technology, Federal Territory Sirius, Russian Federation
E-mail: al.university.edu@yandex.ru
<https://orcid.org/0009-0001-7784-6245>

Perfilova, Valentina N. – Ph.D. (Biology); Full Professor, Volgograd State Medical University, Volgograd, Russian Federation
E-mail: vnperfilova@mail.ru
<https://orcid.org/0000-0002-2457-8486>

Kaluev, Allan V. – Ph.D. (Biology);
Professor of the Russian Academy of Sciences; Group leader, Almazov National Medical Center, St. Petersburg, Russian Federation
E-mail: avkalueff@gmail.com
<https://orcid.org/0000-0002-7525-1950>

Received June 25, 2025

Revised October 14, 2025

Accepted October 15, 2025