

УДК 004.8:612.821

Методы автоматизированного анализа поведенческих тестов с использованием машинного обучения и искусственного интеллекта

Шибаета В.В., Ильина И.А., Балбек К.Д., Мелерзанов А.В.

Федеральное государственное автономное образовательное учреждение высшего образования «Московский физико-технический институт (национальный исследовательский университет)»
141701, Московская обл., Долгопрудный, Институтский пер., д. 9

Поведенческие тесты лабораторных животных являются важным инструментом для изучения неврологических реакций и психоэмоциональных состояний у животных. Традиционные подходы к обработке данных требуют значительного объема ручной работы, характеризуются высокой степенью субъективизма и низкой воспроизводимостью результатов. В данном обзоре рассматриваются современные методы автоматизированного анализа поведенческих тестов лабораторных животных с применением технологий машинного обучения и искусственного интеллекта, преимущества и ограничения различных подходов, включая отслеживание животного, классификацию поведения с учителем и без учителя. Подчеркивается важность разработки удобных и стандартизированных решений, которые смогут сделать автоматизированный анализ доступным для широкого круга исследователей.

Ключевые слова: поведенческие тесты; машинное обучение; автоматизированный анализ; классификация поведения.

Для цитирования: Шибаета В.В., Ильина И.А., Балбек К.Д., Мелерзанов А.В. Методы автоматизированного анализа поведенческих тестов с использованием машинного обучения и искусственного интеллекта. *Патогенез*. 2025; 23(2): 72–80

DOI: 10.48612/path/2310-0435.2025.02.72-80

Для корреспонденции: Шибаета Владлена Владимировна, e-mail: shibaeva.vv@phystech.edu

Финансирование: Исследование не имеет спонсорской поддержки

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов

Поступила: 27.05.2025.

Methods of automated analysis of behavioral tests using machine learning and artificial intelligence

Shibaeva V.V., Ilyina I.A., Balbek K.D., Melerzanov A.V.

The Moscow Institute of Physics and Technology
Institutskiy Pereulok 9, Dolgoprudny of Moscow Region 141701, Russian Federation

Behavioral tests in laboratory animals are a vital tool for investigating neurological responses and psychoemotional states. Traditional methods of data processing often involve extensive manual effort, are prone to subjectivity, and exhibit low reproducibility. This review explores contemporary approaches to the automated analysis of behavioral tests in laboratory animals, focusing on the application of machine learning and artificial intelligence. It discusses the benefits and limitations of various techniques, including animal tracking, as well as supervised and unsupervised behavior classification. The review highlights the need for user-friendly, standardized solutions to make automated analysis more accessible to a broader scientific community.

Keywords: behavioral tests; machine learning; automated analysis; behavior classification.

For citation: Shibaeva V.V., Ilyina I.A., Balbek K.D., Melerzanov A.V. [Methods of automated analysis of behavioral tests using machine learning and artificial intelligence]. *Patogeneis [Pathogenesis]*. 2025; 72–80 (in Russian)

DOI: 10.48612/path/2310-0435.2025.02.72-80

For correspondence: Shibaeva Vladlena Vladimirovna, e-mail: shibaeva.vv@phystech.edu

Funding. The study had no sponsorship.

Conflict of interest. The authors declare no conflict of interest.

Received: 27.05.2025.

Введение

Поведенческие тесты – важнейший инструмент для изучения психофизиологических реакций у различных животных, включая грызунов [1], насекомых [2], а также крупных млекопитающих, таких как свиньи [3] и собаки [4]. Это распространённый способ оценки когнитивно-поведенческого состояния исследуемого животного. Поведенческие тесты были специально разработаны для возможности оценки по-

ведения в контролируемых условиях вручную, по простым параметрам – количеству входов в определенные зоны, времени нахождения в этих зонах, времени неподвижности, и другим параметрам, которые дают представление об особенностях поведения подопытных животных.

Исторически поведенческие тесты опирались на мануальный анализ результатов. Несмотря на сохраняющуюся применимость такого подхода, у него есть несколько существенных ограничений. К основным недостаткам ма-

нуального анализа относятся: высокая трудоёмкость процесса, требующая просмотра всех записей эксперимента с необходимостью неоднократного пересмотра спорных моментов; субъективность оценки, приводящая к расхождению в интерпретации данных разными исследователями и снижающая воспроизводимость результатов [5]; а также техническая невозможность точного измерения ряда количественных параметров, таких как скорость, пройденное расстояние, угол поворота и другие [6]. Кроме того, ручной анализ не позволяет эффективно учитывать тонкие и нестандартные поведенческие паттерны, такие как сложные последовательности движений, микродвижения или контекстно-зависимые реакции, которые могут быть ключевыми для понимания изучаемых поведенческих эффектов.

Для данного обзора был проведен поиск в базах данных PubMed и Google Scholar за период с 2018 по 2025 год с использованием ключевых слов «поведенческие тесты», «машинное обучение», «нейронные сети», «оценка позы», «классификация поведения». Из найденных статей после исключения дубликатов и скрининга аннотаций были отобраны работы, соответствующих критериям: (1) применение ИИ для анализа поведения лабораторных животных; (2) доступность модели для скачивания и установки; (3) решение задачи отслеживания/классификации поведения.

Основные поведенческие тесты

В **табл. 1** предоставлены основные поведенческие тесты, предусматривающие возможность видеорегистрации эксперимента. Эти тесты помогают оценивать мо-

торную функцию животного (что используется при изучении болезни Паркинсона [7]), когнитивные функции (что используется при изучении болезни Альцгеймера [8]), а также уровень тревожности и проявления эмоциональности, имеющих значение при изучении депрессии и посттравматического стрессового расстройства (ПТСР) [9, 10].

Поведение можно анализировать в различных аспектах: временных показателях (например, время неподвижности, продолжительность пребывания в интересующих зонах); качественных и количественных параметрах (частота посещений зон интереса, число взаимодействий); а также в строго количественном выражении (скорость передвижения, длина пути).

Помимо параметров, специфичных для каждого отдельного теста (таких как время в закрытых/открытых рукавах для приподнятого крестообразного лабиринта, задержка до нахождения скрытой платформы в водном лабиринте Морриса), исследователи анализируют общие поведенческие паттерны, характерные для мышей и крыс. Основные модели поведения описаны в **табл. 2**.

Методы анализа поведения грызунов претерпели значительные изменения, пройдя путь от непосредственного наблюдения и ручной фиксации результатов до автоматизированных систем. Изначально исследователи наблюдали за животными в реальном времени и записывали поведение на основе заранее определенных критериев. Один из первых задокументированных экспериментов принадлежит Сэмюэлю Моссу, который вручную регистрировал взаимодействие крысы-альбиноса с собакой-крысоловом [11].

Таблица 1.

Основные (наиболее распространённые) поведенческие тесты

Название теста	Оцениваемые формы поведения	Устройство	Отслеживаемые параметры	Интерпретация
Открытое поле	Локомоторная активность, исследовательское поведение, тревожность	Открытая арена со стенками	Пройденная дистанция; количество времени, проведенное в центре / на периферии	Сниженная локомоторная активность и превалирование времени, проведенного на периферии, указывают на наличие тревожности
Приподнятый крестообразный лабиринт	Тревожность	Крестообразный лабиринт с двумя открытыми и двумя закрытыми рукавами, приподнятый над полом	Количество времени в открытых / закрытых рукавах, количество входов в открытые рукава, время до первого входа в открытый рукав	Снижение времени нахождения в открытых рукавах указывают на развитие тревожности
Водный лабиринт Морриса	Обучение и память	Круглый бассейн с непрозрачной жидкостью, содержащий скрытую под поверхностью платформу	Пройденная дистанция, количество времени в целевом квадранте (на платформе), латентность нахождения скрытой платформы	Большее время в целевом квадранте и короткие задержки указывают на лучшую пространственную память
Принудительное плавание	Депрессивное поведение	Цилиндр, заполненный водой	Время неподвижности	Увеличенное время неподвижности интерпретируется как отчаяние (признак депрессивного состояния)
Подвешивание за хвост	Депрессивное поведение	Животное подвешивается за хвост	Время неподвижности	Увеличенное время неподвижности интерпретируется как отчаяние
Тест социального взаимодействия	Социальное поведение (агрессия, аффилиация, социальное узнавание)	Два и более животных помещаются вместе	Количество взаимодействий разного типа (обнюхивание, драка)	Варьирует

Таблица 2.

Основные поведенческие паттерны, учитываемые при анализе поведенческих тестов

Название паттерна	Описание	Ассоциированное эмоциональное состояние
Груминг	Самоочищение, включающее лизание или покусывание шерсти и кожи	Избыточный груминг может указывать на стресс или тревогу
Стойка	Вставание на задние лапы для исследования окружающей среды	Исследование, любопытство; часто связано с более низким уровнем тревоги в поведенческих тестах
Застывание	Грызун остается совершенно неподвижным в напряжённой позе в течении нескольких секунд	Страх, тревога
Растяжка (stretch-attend posture, SAP)	Грызун вытягивает тело вперед, голова поднята и направлена вперед	Оценка риска, осторожность и тревога

Таблица 3.

Сравнение моделей автоматизированного анализа поведения для отслеживания и оценки позы животных

Модель	Архитектура	Результат	Отслеживание нескольких животных
AlphaTracker [15]	Обнаружение животных с YOLOv3, оценка ключевых точек с SENt	Adjusted Rand Index: Большой набор данных (3034 клипа): ARI = 0.201, Малый набор данных (1345 клипа): ARI = 0.187	Да
DeepLabCut [16-18]	ResNet	RMSE модели <5 пикс. (при обучении на 100 кадрах), близко к человеческой вариабельности (~2.69 пикс.). Сопоставимо с размером носа мыши	Нет в оригинальной статье, да – после доработки [19]
DeepPoseKit [20]	Stacked DenseNet (FC-DenseNet и Stacked Hourglass)	Работает в 3 раза быстрее DeepLabCut, достигая той же точности	Нет
MARS [21]	Inception-ResNet-v2 + Hourglass	Для съёмки сверху в пределах 5 мм от исходного значения находятся 92% предсказанных точек (67% для съёмки сбоку)	Да
SIPEC (PoseNet) [22]	Encoder-decoder	Среднеквадратичная ошибка (RMSE) - 2.9 пикселей	Да
SLEAP [23]	UNet	Работает в 11 раз быстрее DeepLabCut, достигая той же точности	Да

Введение видеокамер позволило фиксировать ход эксперимента, что дало возможность анализировать его позже, пересматривая спорные моменты. Однако обработка данных оставалась ручной. Разработка программ, таких как EthoVision [12] и ANY-maze, позволила автоматизировать отслеживание движения животных. Следует отметить, что каждое программное обеспечение основано на собственных алгоритмах, характерных для каждого производителя, что может также влиять на воспроизводимость. Например, исследования показывают, что EthoVision XT чаще завышает показатели расстояния по сравнению с ANY-Maze, особенно при слабом освещении [13].

Дальнейшее развитие компьютерного зрения и нейросетевых алгоритмов, а также появление открытых наборов данных открыли новые перспективы в автоматизированном анализе поведения. Модели, такие как JAABA, классифицировали поведение на основе данных о траекториях движения животного [14]. В последующие годы инструменты глубокого анализа продолжали развиваться, что привело к формированию широкого спектра специализированных подходов – от систем трекинга отдельных точек тела до комплексных платформ для анализа поведенческих последовательностей.

Этот технологический прогресс сопровождался стремительным ростом методологического разнообразия: современные решения различаются по типам используемых нейросетевых архитектур (CNN – Convolutional Neural

Network, RNN – Recurrent Neural Network, трансформеры), способам обработки видеоданных (2D/3D реконструкция, мультикамерные системы), а также подходам к интерпретации поведенческих паттернов (обучение с учителем или без учителя). Именно сравнительный анализ этих быстро развивающихся методов, их валидности и областей применения составляет основную **цель** данного обзора.

Основные используемые алгоритмы анализа поведения животных

Трекинг и оценка позы

Основой автоматизированного анализа поведенческих тестов является этап отслеживания животных. Этот этап состоит из двух ключевых компонентов – идентификация животного (имеющая особое значение, когда эксперимент проводится с несколькими мышами/крысами одновременно) и отслеживание траектории/положений частей тела. Хотя последние два компонента представляют разные уровни одной аналитической задачи – описания движения – в современных обзорах они традиционно разделяются, так как большинство существующих решений специализируется либо на трекинге целого тела, либо на позо-ориентированном анализе [9, 10]. В **табл. 3** приведено сравнение основных используемых моделей.

Пионером в области автоматизированного трекинга позы стала модель DeepLabCut (DLC) [16-18], которая остаётся одной из самых популярных платформ для маркировки и анализа движений животных. DLC, основанный на архитектуре ResNet, позволяет исследователям обучать модели на собственных данных, обеспечивая высокую точность даже при ограниченном размере выборки. Развитие методов машинного обучения привело к появлению новых решений, оптимизирующих скорость обработки и вычислительные ресурсы. Например, DeepPoseKit [20] и SLEAP [23] демонстрируют точность, сопоставимую с DLC, но достигают этого за счёт более эффективных архитектур, сокращающих количество параметров модели.

Несмотря на значительные успехи в этой области, ключевым ограничением остаётся трудоёмкость аннотирования данных. Даже разметка 100 кадров требует значительных временных затрат. Также следует отметить, что обучение сложных моделей (таких как ResNet или Unet) зачастую требует высокопроизводительных графических процессоров, что делает метод недоступным для небольших исследовательских групп. В этом контексте особую ценность представляют модели, предобученные на больших наборах данных, такие как SuperAnimal [24], которые способны работать без дообучения.

Важным направлением развития методов трекинга является трёхмерная реконструкция позы животных, позволяющая проводить более детальный анализ моторных функций. 3d-реконструкция может быть достигнута с использованием многокамерных систем [25-27] и/или с помощью камер с датчиком глубины (RGB-D) [28-30]. Новые перспективы открывает метод монокулярной 3d-реконструкции в таких моделях как LiftPose3D [31], которые с помощью глубокого обучения восстанавливают трёхмерную позу животного по данным с одной камеры. Эти методы значительно снижают требования к оборудованию, сохраняя при этом высокую точность реконструкции, что делает 3D-анализ доступным для широкого круга исследователей.

Для решения задачи автоматизированного анализа поведенческих тестов используют три метода обучения нейросетей: с учителем, без учителя, с подкреплением. Суть метода машинного обучения с учителем состоит в том, что для обучения нейросеть получает специальный набор данных, в котором заранее отмечено, что эти данные означают. Машинное обучение нейросети без учителя заключается в том, что нейросеть получает на входе неразмеченные данные и старается сама найти в них общие признаки и связи. Иногда нейросеть нужно натренировать выполнять определённую задачу с четкими результатами, и в таком случае хорошие результаты показывает обучение с подкреплением.

Решение задачи классификации поведения методом обучения с учителем

Задача классификации поведения животных представляет собой сложную проблему, поскольку поведенческие акты разнообразны, изменчивы и зависят от множества внутренних и внешних факторов. Классические методы,

не использующие технологии машинного обучения, позволяют выявлять поведение лишь с помощью эвристик – эмпирически разработанных правил и методов упрощённого анализа [32-34]. Поэтому круг распознаваемых ими моделей крайне узок и ограничивается преимущественно состояниями покоя животного. Современные методы машинного обучения значительно расширяют возможности автоматизированного анализа, что позволяет повысить точность, воспроизводимость и масштабируемость исследований (табл. 4). Это было труднодостижимо при использовании ручных методов аннотации и оценки.

Свёрточные нейронные сети (CNN) эффективно обрабатывают пространственные паттерны, автоматически выделяя иерархические признаки из видеоданных. Например, DeepEthogram [35] применяет 3D-CNN для анализа временных последовательностей и достигает 94% точности в распознавании редких поведенческих актов. Рекуррентные нейронные сети (LSTM, GRU) учитывают временную динамику, что особенно важно для различения стереотипных движений. Комбинированные архитектуры CNN и RNN, как в системе MARS [21], позволяют с точностью 89-95% отслеживать социальные взаимодействия мышей.

Важно отметить, что обучение с учителем требует наличия тщательно размеченных наборов данных, что является существенным ограничением. Инструменты типа JAABA [14] решают эту задачу через интерактивный интерфейс, где эксперты вручную маркируют ключевые кадры. Большинство современных платформ, таких как SimBA [36], опираются на предварительно размеченные открытые датасеты, например, DeepLabCut, что облегчает обучение моделей и повышает качество классификации.

Критическим преимуществом DeepEthogram стала его способность игнорировать абсолютное пространственное положение животных благодаря архитектуре CNN, что обеспечивает устойчивость к изменениям ориентации и позиции в арене [35]. MARS демонстрирует человеческий уровень производительности в классификации социального поведения, достигая precision-recall AUC 0.96 для агрессивных взаимодействий [21].

Основная проблема современных моделей – ограниченная способность к обобщению. DeepEthogram, обученный на мышках линии C57BL/6, при тестировании на линии BALB/c демонстрирует снижение точности примерно на 15% [35]. В связи с этим перспективным направлением становится применение методов самообучения с последующим дообучением на целевых данных, что позволяет повысить адаптивность моделей к новым условиям и видам. Кроме того, интеграция мультимодальных данных, таких как ЭЭГ и ЭМГ, в системы анализа поведения открывает новые возможности для изучения взаимосвязи между поведением и нейрофизиологическими процессами [36].

Кроме того, для повышения эффективности обучения и сокращения объёма ручной разметки всё шире применяются методы «semi-supervised learning», при которых первоначально размечается небольшой объём данных, а затем с помощью специализированных алгоритмов размеченный набор автоматически расширяется. Обучение модели про-

Таблица 4.

Сравнение моделей машинного обучения для классификации поведения с учителем

Модель	Архитектура	Результат
DeepEthogram [35]	3D-CNN + Optical Flow	F1: 0.93-0.95 (среднее по классам)
JAABA [14]	SVM + Handcrafted Features	Balanced accuracy $\approx$ 89% на мухах
SimBA [36]	Random Forest + CNN/DeepLabCut	F1 $\sim$ 0.85-0.92, зависит от поведения
MARS [21]	YOLOv4 + XGBoost	AUC-PR = 0.96 для агрессии
ResNet-50V2 [37]	ResNet50V2 (CNN)	Accuracy $\sim$ 96-98.7% (в зависимости от задачи)
ViT [38]	Transformer + Self-Attention	Accuracy $\approx$ 83%, F1 $\approx$ 82.7%

водится уже на увеличенной выборке, что значительно снижает необходимость в ручной аннотации и улучшает качество обучения, особенно при ограниченном количестве размеченных данных. Такой подход успешно применяется, например, в OpenLabCluster, демонстрируя эффективность в автоматизации анализа поведения животных [39].

Помимо CNN и RNN, в современных исследованиях используются архитектуры ResNet-50 и Vision Transformer (ViT) для классификации и распознавания поведенческих событий. ResNet-50, известная своей глубокой архитектурой с остаточными связями, демонстрирует высокую эффективность в извлечении визуальных признаков из видео и изображений животных, обеспечивая точность классификации свыше 95% при использовании предобученных моделей и дообучении на специализированных данных [40].

Vision Transformer (ViT) использует механизм внимания и многоголовую структуру для обработки изображений как последовательностей патчей, что позволяет лучше улавливать контекстуальные и пространственные взаимосвязи. В недавних исследованиях ViT показал высокую точность (около 83%) и F1-score (82.7%) при автоматическом обнаружении социальных взаимодействий у свиней, превосходя по адаптивности традиционные CNN-модели за счёт способности учитывать сложные контексты и вариации поведения [38].

Таким образом, интеграция ResNet-50 и ViT в процессы анализа поведения животных расширяет возможности автоматизации, улучшая качество распознавания и устойчивость моделей к вариациям данных.

Решение задачи классификации поведения методом обучения без учителя

Как было сказано выше, человеческий анализ поведенческих тестов субъективен, что влияет на аннотирование данных и, как следствие, на качество прогнозирования моделей, основанных на классификации с учителем. Кроме того, разметка поведения часто опирается на устоявшиеся этограммы, что может приводить к игнорированию слабо выраженных, но статистически значимых паттернов. Таких ограничений лишены методы классификации без учителя, которые автоматически выявляют структуру данных без предварительных меток.

Классификация без учителя направлена на обнаружение скрытых закономерностей путем кластеризации дан-

ных в пространстве признаков (табл. 5). В контексте поведенческого анализа кластеры соответствуют различным типам поведения. Перед кластеризацией, как правило, модели уменьшают размерность пространства с помощью нелинейных методов понижения размерности (UMAP, t-SNE). Так B-SOiD [42] обрабатывает данные трекинга позы, понижает размерность получившегося признакового пространства до 11, а затем выделяет кластеры. Похожим принципом пользуются Behavior Atlas [25] и Motion Mapper [43]. Другого подхода придерживается VAME [44] – с помощью вариационных автоэнкодеров преобразует видео в латентное пространство, после чего выполняется кластеризация.

Выбор оптимального метода зависит от целей исследователя и ресурсов. Лаборатории, оснащенные системами трёхмерной регистрации движений, могут применять AR-HMM и Behavior Atlas [25], тогда как для высокопроизводительного скрининга предпочтительным решением является B-SOiD [42]. В случаях, когда требуется точная идентификация поведенческих мотивов, рекомендуется использование VAME [43].

Лаборатории с 3D-системами могут использовать AR-HMM и Behavior Atlas, B-SOiD подходит для высокопроизводительных задач, а VAME – для точной идентификации мотивов. Будущие исследования могут интегрировать эти методы, например, комбинируя доступность B-SOiD с глубиной VAME, или разрабатывать более простые инструменты для AR-HMM. Следует отметить, что методы классификации поведения без учителя, не основанные на обучении нейросетей, могут показывать меньшее качество предсказания, однако значительным потенциалом для внедрения в лабораториях с ограниченными вычислительными ресурсами.

Перспективы использования автоматизированных алгоритмов анализа

поведения животных

Область поведенческой нейробиологии переживает значительный прогресс благодаря развитию автоматизированных методов анализа поведенческих тестов – от специализированных, решающих задачу отслеживания или классификации поведения, до более универсальных платформ, охватывающих весь процесс анализа (как, например, SIPEC [22], MARS [21] или LabGym [46]).

Таблица 5.

Сравнение моделей машинного обучения для классификации поведения без учителя

Модель	Архитектура	Результат
AR-HMM [41]	AR-HMM	Выявлено 60 поведенческих модулей с $R^2 > 0.9$
B-SoiD [42]	UMAP+HDBSCAN	Классификатор случайного леса достигает >90% точности, выявлено 11 классов поведения
Behavior Atlas [25]	DTAK, UMAP, HDBSCAN	Выявлен 41 фенотип поведения, сгруппировано в 11 кластеров
Motion Mapper [43]	PCA, t-SNE	122 мотивов поведения
VAME [44]	VAE с biRNN, HMM	50 поведенческих мотивов, Purity=80.6%, NMI =28.6%, Homogeneity =54.9%
Keypoint-MoSeq [45]	SLDS, AR-HMM	25-39 мотивов поведения

Тем не менее, несмотря на эти достижения, сохраняется ряд проблем, препятствующих полной интеграции автоматизированного анализа в стандартные исследовательские практики. Одним из ключевых барьеров является необходимость владения навыками программирования для эффективной реализации и настройки многих из этих инструментов. Например, хотя DeepLabCut предоставляет мощную платформу для оценки поз, получение более высокоуровневых поведенческих метрик, таких как количество входов в зоны или время, проведенное в определенных областях, часто требует дополнительной обработки данных или использования дополнительного программного обеспечения. Вычисление сложных поведенческих метрик иллюстрирует необходимость интеграции разнообразных параметров. Так, например, для вычисления индекса хрупкости необходимо знать общую пройденную дистанцию, максимальную из дистанций, пройденных между периодами покоя, среднюю скорость, меандр, общее время мобильности и количество стоек [47].

Перечисленные выше проблемы подчеркивают отсутствие единой, всеобъемлющей системы, способной удовлетворить полный спектр аналитических потребностей в поведенческой нейробиологии. Исследователи часто вынуждены комбинировать несколько инструментов или разрабатывать собственные решения для достижения всестороннего анализа, что может быть трудоемким и требовать междисциплинарных навыков.

В перспективе, разработка более интегрированных и удобных для пользователя систем имеет решающее значение для дальнейшего развития данной области. Усилия должны быть направлены на создание стандартизированных аналитических фреймворков, которые облегчают интеграцию различных инструментов, тем самым снижая потребность в обширных знаниях программирования. Кроме того, улучшение переносимости моделей машинного обучения с помощью трансферного обучения или использование больших, разнообразных наборов данных для обучения могут повысить точность моделей при применении их к новым данным.

В заключение отметим, что хотя автоматизированные методы значительно улучшили анализ поведения, дальнейшие инновации и междисциплинарное сотрудничество необходимы для преодоления существующих препятствий и полного раскрытия потенциала этих технологий в продвижении нашего понимания поведения.

Список литературы

- Каде А.Х., Кравченко С.В., Трофименко А.И., Поляков П.П., Липатова А.С., Ананьева Е.И., Чаплыгина К.Ю., Уварова Е.А., Терещенко О.А. Современные методы оценки уровня тревожности грызунов в поведенческих тестах, основанных на моделях без предварительного обусловливания. *Кубанский научный медицинский вестник*. 2018; 25(6): 171-176. DOI: 10.25207/1608-6228-2018-25-6-171-176
- Dhar G., Mukherjee S., Nayak N., Sahu S., Bag J., Rout R., Mishra M. *Various behavioural assays to detect the neuronal abnormality in flies*. In: Fundamental approaches to screen abnormalities in Drosophila / Ed. M. Mishra. Springer, 2020: 223-251. DOI: 10.1007/978-1-4939-9756-5_18
- Murphy E., Nordquist R.E., van der Staay F.J. A review of behavioural methods to study emotion and mood in pigs, Sus scrofa. *Appl. Anim. Behav. Sci.* 2014; 159: 9-28. DOI: 10.1016/j.applanim.2014.08.002
- Moser A.Y., Welch M., Brown W.Y., McGreevy P., Bennett P.C. Methods of behavioral testing in dogs: a scoping review and analysis of test stimuli. *Front. Vet. Sci.* 2024; 11: 1455574. DOI: 10.3389/fvets.2024.1455574
- Kafkafi N., Agassi J., Chesler E.J., Crabbe J.C., Crusio W.E., Eilam D., Gerlai R., Golani I., Gomez-Marin A., Heller R., Iraqi F., Jaljuli I., Karp N.A., Morgan H., Nicholson G., Pfaff D.W., Richter S.H., Stark P.B., Stiedl O., Stodden V., Tarantino L.M., Tucci V., Valdar W., Williams R.W., Würbel H., Benjamini Y. Reproducibility and replicability of rodent phenotyping in preclinical studies. *Neurosci. Biobehav. Rev.* 2018; 87: 218-232. DOI: 10.1016/j.neubiorev.2018.01.003
- KSV A.B.G., Dissanayake D., Gunatilake M., Velu V.K., Paranthaman M. A short review on behavioural assessment methods in rodents. *Bioinform.* 2023; 19(8): 866-870. DOI: 10.6026/97320630019866
- Prasad E.M., Hung S.Y. Behavioral tests in neurotoxin-induced animal models of Parkinson's disease. *Antioxidants*. 2020; 9(10): 1007. DOI: 10.3390/antiox9101007
- Pentkowski N.S., Rogge-Obando K.K., Donaldson T.N., Bouquin S.J., Clark B.J. Anxiety and Alzheimer's disease: Behavioral analysis and neural basis in rodent models of Alzheimer's-related neuropathology. *Neurosci. Biobehav. Rev.* 2021; 127: 647-658. DOI: 10.1016/j.neubiorev.2021.05.005
- Huang L., Xiao D., Sun H., Qu Y., Su X. Behavioral tests for evaluating the characteristics of brain diseases in rodent models: Optimal choices for improved outcomes. *Mol. Med. Rep.* 2022; 25(5): 183. DOI: 10.3892/mmr.2022.12699
- Verbitsky A., Dopfel D., Zhang N. Rodent models of post-traumatic stress disorder: behavioral assessment. *Transl. Psychiatry*. 2020; 10(1): 132. DOI: 10.1038/s41398-020-0806-x
- d'Isa R. The first rodent behavioral study (1822) and the diffusion of human-bred albino rats and mice in the 19th century. *Front. Psychol.* 2025; 15: 1532975. DOI: 10.3389/fpsyg.2024.1532975
- 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(3): 398-414. DOI: 10.3758/BF03195394
- Lim C.J.M., Platt B., Janhunen S.K., Riedel G. Comparison of automated video tracking systems in the open field test: ANY-Maze versus EthoVision XT. *J. Neurosci. Methods*. 2023; 397: 109940. DOI: 10.1016/j.jneumeth.2023.109940
- Kabra M., Robie A.A., Rivera-Alba M., Branson S., Branson K. JAABA: interactive machine learning for automatic annotation of animal behavior. *Nat. Methods*. 2013; 10(1): 64-67. DOI: 10.1038/nmeth.2281

15. Chen Z., Zhang R., Fang H. S., Zhang Y. E., Bal A., Zhou H., Rock R.R., Padilla-Coreano N., Keyes L.R., Zhu H., Li Y.L., Komiyama T., Tye K.M., Lu C. AlphaTracker: a multi-animal tracking and behavioral analysis tool. *Front. Behav. Neurosci.* 2023; 17: 1111908. DOI:10.3389/fnbeh.2023.1111908
16. Mathis A., Mamidanna P., Cury K.M., Abe T., Murthy V.N., Mathis M.W., Bethge M. DeepLabCut: markerless pose estimation of user-defined body parts with deep learning. *Nat. Neurosci.* 2018; 21(9): 1281-1289. DOI: 10.1038/s41593-018-0209-y
17. Nath T., Mathis A., Chen A.C., Patel A., Bethge M., Mathis M.W. Using DeepLabCut for 3D markerless pose estimation across species and behaviors. *Nat. Protoc.* 2019; 14(7): 2152-2176. DOI: 10.1038/s41596-019-0176-0
18. Mathis A., Biasi T., Schneider S., Yuksekogonul M., Rogers B., Bethge M., Mathis M.W. *Pretraining boosts out-of-domain robustness for pose estimation.* In: Proceedings of the IEEE/CVF winter conference on applications of computer vision. 2021: 1859-1868. DOI: 10.48550/arXiv.1909.11229
19. Lauer J., Zhou M., Ye S., Menegas W., Schneider S., Nath T., Rahman M.M., Di Santo V., Soberanes D., Feng G., Murthy V.N., Lauder G., Dulac C., Mathis M.W., Mathis A. Multi-animal pose estimation, identification and tracking with DeepLabCut. *Nat. Methods.* 2022; 19(4): 496-504. DOI: 10.1038/s41592-022-01443-0
20. Graving J.M., Chae D., Naik H., Li L., Koger B., Costelloe B.R., Couzin I.D. DeepPoseKit, a software toolkit for fast and robust animal pose estimation using deep learning. *Elife.* 2019; 8: e47994. DOI:10.7554/eLife.47994
21. Segalin C., Williams J., Karigo T., Hui M., Zelikowsky M., Sun J.J., Perona P., Anderson D.J., Kennedy A. The Mouse Action Recognition System (MARS) software pipeline for automated analysis of social behaviors in mice. *Elife.* 2021; 10: e63720. DOI:10.7554/eLife.63720
22. Marks M., Qiuhan J., Sturman O., von Ziegler L., Kollmorgen S., von der Behrens W., Mante V., Bohacek J., Yanik M.F. 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. DOI: 10.1038/s42256-022-00477-5
23. Pereira T.D., Tabris N., Matsliah A., Turner D.M., Li J., Ravindranath S., Papadoyannis E.S., Normand E., Deutsch D.S., Wang Z.Y., McKenzie-Smith G.C., Mitelut C.C., Castro M.D., D'Uva J., Kislin M., Sanes D.H., Kocher S.D., Wang S.S., Falkner A.L., Shaevez J.W., Murthy M. SLEAP: A deep learning system for multi-animal pose tracking. *Nat. Methods.* 2022; 19(4): 486-495. DOI: 10.1038/s41592-022-01426-1
24. Ye S., Filippova A., Lauer J., Schneider S., Vidal M., Qiu T., Mathis A., Mathis M.W. SuperAnimal pretrained pose estimation models for behavioral analysis. *Nat. Commun.* 2024; 15(1): 5165. DOI: 10.1038/s41467-024-48792-2
25. Huang K., Han Y., Chen K., Pan H., Zhao G., Yi W., Li X., Liu S., Wei P., Wang L. A hierarchical 3D-motion learning framework for animal spontaneous behavior mapping. *Nat. Commun.* 2021; 12(1): 2784. DOI: 10.1038/s41467-021-22970-y
26. Zimmermann C., Schneider A., Alyahyay M., Brox T., Diester I. FreiPose: a deep learning framework for precise animal motion capture in 3D spaces. *BioRxiv.* 2020. DOI: 10.1101/2020.02.27.967620
27. Karashchuk P., Rupp K.L., Dickinson E.S., Walling-Bell S., Sanders E., Azim E., Brunton B.W., Tuthill J. C. Anipose: A toolkit for robust markerless 3D pose estimation. *Cell Rep.* 2021; 36(13): 109730. DOI: 10.1016/j.celrep.2021.109730
28. Tsuruda Y., Akita S., Yamanaka K., Matsumoto Y., Yamamoto M., Sano Y., Furuichi T., Takemura H. *3D Body Parts Tracking of Mouse Based on RGB-D Video from Under an Open Field.* In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2021: 7252-7255. DOI:10.1109/EMBC46164.2021.9630565
29. Ebbesen C.L., Froemke R.C. Automatic mapping of multiplexed social receptive fields by deep learning and GPU-accelerated 3D videography. *Nat. Commun.* 2022; 13(1): 593. DOI: 10.1038/s41467-022-28153-7
30. 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. DOI: 10.3758/s13428-020-01381-9
31. Gosztolai A., Günel S., Lobato-Ríos V., Pietro Abrate M., Morales D., Rhodin H., Fua P., Ramdya P. LiftPose3D, a deep learning-based approach for transforming two-dimensional to three-dimensional poses in laboratory animals. *Nat. Methods.* 2021; 18(8): 975-981. DOI: 10.1038/s41592-021-01226-z
32. Gabriel C.J., Zeidler Z., Jin B., Guo C., Goodpaster C.M., Kashay A.Q., Wu A., Delaney M., Cheung J., DiFazio L.E., Sharpe M.J., Aharoni D., Wilke S.A., DeNardo L.A. BehaviorDEPOT is a simple, flexible tool for automated behavioral detection based on markerless pose tracking. *Elife.* 2022; 11: e74314. DOI:10.7554/eLife.74314
33. Pennington Z.T., Dong Z., Feng Y., Vetere L.M., Page-Harley L., Shuman T., Cai D.J. ezTrack: An open-source video analysis pipeline for the investigation of animal behavior. *Sci. Rep.* 2019; 9(1): 19979. DOI: 10.1038/s41598-019-56408-9
34. Nandi A., Virmani G., Barve A., Marathe S. DBScorer: An Open-Source Software for Automated Accurate Analysis of Rodent Behavior in Forced Swim Test and Tail Suspension Test. *eNeuro.* 2021; 8(6): ENEURO.0305-21.2021. DOI:10.1523/ENEURO.0305-21.2021
35. Bohoslav J.P., Wimalasena N.K., Clausen K.J., Dai Y.Y., Yarmolinsky D.A., Cruz T., Kashlan A.D., Chiappe M.E., Orefice L.L., Woolf C.J., Harvey C.D. DeepEthogram, a machine learning pipeline for supervised behavior classification from raw pixels. *Elife.* 2021; 10: e63377. DOI: 10.7554/eLife.63377
36. Nilsson S.R., Goodwin N.L., Choong J.J., Hwang S., Wright H.R., Norville Z.C., Tong X., Lin D., Bentzley B.S., Eshel N., McLaughlin R.J., Golden S.A. Simple Behavioral Analysis (SimBA) – an open-source toolkit for computer classification of complex social behaviors in experimental animals. *BioRxiv.* 2020; 2020.04.19.049452. DOI: 10.1101/2020.04.19.049452
37. Hindarto D. Use ResNet50V2 Deep Learning Model to Classify Five Animal Species. *J. JTik J. Teknol. Inf. Dan. Komun.* 2023; 7(4): 758-768. DOI: 10.35870/jtik.v7i4.1845
38. Taiwo G., Vadera S., Alameer A. Vision transformers for automated detection of pig interactions in groups. *Smart Agricultural Technology.* 2025; 10: 100774. DOI: 10.1016/j.atech.2025.100774
39. Li J., Keselman M., Shlizerman E. OpenLabCluster: Active Learning Based Clustering and Classification of Animal Behaviors in Videos Based on Automatically Extracted Kinematic Body Keypoints. *BioRxiv.* 2022. DOI: 10.1101/2022.10.10.511660
40. Barulina M., Andreev A., Kovalenko I., Barmin I., Titov E., Kirillov D. Method for Preprocessing Video Data for Training Deep-Learning Models for Identifying Behavioral Events in Bio-Objects. *Mathematics.* 2024; 12(24): 3978. DOI: 10.3390/math12243978
41. Wiltshko A.B., Johnson M.J., Iurilli G., Peterson R.E., Katon J.M., Pashkovski S.L., Abaira V.E., Adams R.P., Datta S.R. Mapping Sub-Second Structure in Mouse Behavior. *Neuron.* 2015; 88(6): 1121-1135. DOI: 10.1016/j.neuron.2015.11.031
42. 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. DOI:10.1038/s41467-021-25420-x
43. Berman G.J., Choi D.M., Bialek W., Shaevez J.W. Mapping the stereotyped behaviour of freely moving fruit flies. *J. R. Soc. Interface.* 2014; 11(99): 20140672. DOI: 10.1098/rsif.2014.0672
44. Luxem K., Mocellin P., Fuhrmann F., Kürsch J., Miller S.R., Palop J.J., Remy S., Bauer P. Identifying behavioral structure from deep variational embeddings of animal motion. *Commun. Biol.* 2022; 5(1): 1267. DOI: 10.1038/s42003-022-04080-7
45. Weinreb C., Pearl J., Lin S., Osman M.A.M., Zhang L., Annapragada S., Conlin E., Hoffman R., Makowska S., Gillis W.F., Jay M., Ye S., Mathis A., Mathis M.W., Pereira T., Linderman S.W., Datta S.R. Keypoint-MoSeq: parsing behavior by linking point tracking to pose dynamics. *Nat. Methods.* 2024; 21(7): 1329-1339. DOI: 10.1038/s41592-024-02318-2
46. Hu Y., Ferrario C.R., Maitland A.D., Ionides R.B., Ghimire A., Watson B., Iwasaki K., White H., Xi Y., Zhou J., Ye B. LabGym: Quantification of user-defined animal behaviors using learning-based holistic assessment. *Cell. Rep. Methods.* 2023; 3(3): 100415. DOI: 10.1016/j.crmeth.2023.100415
47. Parks R.J., Fares E., Macdonald J.K., Ernst M.C., Sinal C.J., Rockwood K., Howlett S.E. A procedure for creating a frailty index based on deficit accumulation in aging mice. *J. Gerontol. A. Biol. Sci. Med. Sci.* 2012; 67(3): 217-227. DOI: 10.1093/gerona/glr193

References

1. Kade A.Kh., Kravchenko S.V., Trofimenko A.I., Poliakov P.P., Lipatova A.S., Ananeva E.L., Chaplygina K.Iu., Uvarova E.A., Tereshchenko O.A. [Modern methods of anxiety assessment of rodents by tests based on unconditional behavior models]. *Kubanskii nauchnyi medicinskii vestnik. [Kuban Scientific Medical Bulletin]* 2018; 25(6): 171-176. DOI: 10.25207/1608-6228-2018-25-6-171-176 (in Russian)

2. Dhar G., Mukherjee S., Nayak N., Sahu S., Bag J., Rout R., Mishra M. *Various behavioural assays to detect the neuronal abnormality in flies*. In: Fundamental approaches to screen abnormalities in Drosophila / Ed. M. Mishra. Springer, 2020: 223-251. DOI: 10.1007/978-1-4939-9756-5_18
3. Murphy E., Nordquist R.E., van der Staay F.J. A review of behavioural methods to study emotion and mood in pigs, *Sus scrofa*. *Appl. Anim. Behav. Sci.* 2014; 159: 9-28. DOI: 10.1016/j.applanim.2014.08.002
4. Moser A.Y., Welch M., Brown W.Y., McGreevy P., Bennett P.C. Methods of behavioral testing in dogs: a scoping review and analysis of test stimuli. *Front. Vet. Sci.* 2024; 11: 1455574. DOI: 10.3389/fvets.2024.1455574
5. Kafkafi N., Agassi J., Chesler E.J., Crabbe J.C., Crusio W.E., Eilam D., Gerlai R., Golani I., Gomez-Marín A., Heller R., Iraqi F., Jaljuli I., Karp N.A., Morgan H., Nicholson G., Pfaff D.W., Richter S.H., Stark P.B., Stiedl O., Stodden V., Tarantino L.M., Tucci V., Valdar W., Williams R.W., Würbel H., Benjamini Y. Reproducibility and replicability of rodent phenotyping in preclinical studies. *Neurosci. Biobehav. Rev.* 2018; 87: 218-232. DOI: 10.1016/j.neubiorev.2018.01.003
6. KSV A.B.G., Dissanayake D., Gunatilake M., Velu V.K., Paranthaman M. A short review on behavioural assessment methods in rodents. *Bioinformation.* 2023; 19(8): 866-870. DOI: 10.6026/97320630019866
7. Prasad E.M., Hung S.Y. Behavioral tests in neurotoxin-induced animal models of Parkinson's disease. *Antioxidants.* 2020; 9(10): 1007. DOI: 10.3390/antiox9101007
8. Pentkowski N.S., Rogge-Obando K.K., Donaldson T.N., Bouquin S.J., Clark B.J. Anxiety and Alzheimer's disease: Behavioral analysis and neural basis in rodent models of Alzheimer's-related neuropathology. *Neurosci. Biobehav. Rev.* 2021; 127: 647-658. DOI: 10.1016/j.neubiorev.2021.05.005
9. Huang L., Xiao D., Sun H., Qu Y., Su X. Behavioral tests for evaluating the characteristics of brain diseases in rodent models: Optimal choices for improved outcomes. *Mol. Med. Rep.* 2022; 25(5): 183. DOI: 10.3892/mmr.2022.12699
10. Verbitsky A., Dopfel D., Zhang N. Rodent models of post-traumatic stress disorder: behavioral assessment. *Transl. Psychiatry.* 2020; 10(1): 132. DOI: 10.1038/s41398-020-0806-x
11. d'Isa R. The first rodent behavioral study (1822) and the diffusion of human-bred albino rats and mice in the 19th century. *Front. Psychol.* 2025; 15: 1532975. DOI: 10.3389/fpsyg.2024.1532975
12. 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(3): 398-414. DOI: 10.3758/BF03195394
13. Lim C.J.M., Platt B., Janhun S.K., Riedel G. Comparison of automated video tracking systems in the open field test: ANY-Maze versus EthoVision XT. *J. Neurosci. Methods.* 2023; 397: 109940. DOI: 10.1016/j.jneumeth.2023.109940
14. Kabra M., Robie A.A., Rivera-Alba M., Branson S., Branson K. JAABA: interactive machine learning for automatic annotation of animal behavior. *Nat. Methods.* 2013; 10(1): 64-67. DOI: 10.1038/nmeth.2281
15. Chen Z., Zhang R., Fang H. S., Zhang Y. E., Bal A., Zhou H., Rock R.R., Padilla-Coreano N., Keyes L.R., Zhu H., Li Y.L., Komiyama T., Tye K.M., Lu C. AlphaTracker: a multi-animal tracking and behavioral analysis tool. *Front. Behav. Neurosci.* 2023; 17: 1111908. DOI: 10.3389/fnbeh.2023.1111908
16. Mathis A., Mamidanna P., Cury K.M., Abe T., Murthy V.N., Mathis M.W., Bethge M. DeepLabCut: markerless pose estimation of user-defined body parts with deep learning. *Nat. Neurosci.* 2018; 21(9): 1281-1289. DOI: 10.1038/s41593-018-0209-y
17. Nath T., Mathis A., Chen A.C., Patel A., Bethge M., Mathis M.W. Using DeepLabCut for 3D markerless pose estimation across species and behaviors. *Nat. Protoc.* 2019; 14(7): 2152-2176. DOI: 10.1038/s41596-019-0176-0
18. Mathis A., Biasi T., Schneider S., Yuksekgonul M., Rogers B., Bethge M., Mathis M.W. *Pretraining boosts out-of-domain robustness for pose estimation*. In: Proceedings of the IEEE/CVF winter conference on applications of computer vision. 2021: 1859-1868. DOI: 10.48550/arXiv.1909.11229
19. Lauer J., Zhou M., Ye S., Menegas W., Schneider S., Nath T., Rahman M.M., Di Santo V., Soberanes D., Feng G., Murthy V.N., Lauder G., Dulac C., Mathis M.W., Mathis A. Multi-animal pose estimation, identification and tracking with DeepLabCut. *Nat. Methods.* 2022; 19(4): 496-504. DOI: 10.1038/s41592-022-01443-0
20. Graving J.M., Chae D., Naik H., Li L., Koger B., Costelloe B.R., Couzin I.D. DeepPoseKit, a software toolkit for fast and robust animal pose estimation using deep learning. *Elife.* 2019; 8: e47994. DOI: 10.7554/eLife.47994
21. Segalin C., Williams J., Karigo T., Hui M., Zelikowsky M., Sun J.J., Perona P., Anderson D.J., Kennedy A. The Mouse Action Recognition System (MARS) software pipeline for automated analysis of social behaviors in mice. *Elife.* 2021; 10: e63720. DOI: 10.7554/eLife.63720
22. Marks M., Qiuhan J., Sturman O., von Ziegler L., Kollmorgen S., von der Behrens W., Mante V., Bohacek J., Yanik M.F. 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. DOI: 10.1038/s42256-022-00477-5
23. Pereira T.D., Tabris N., Matsliah A., Turner D.M., Li J., Ravindranath S., Papadoyannis E.S., Normand E., Deutsch D.S., Wang Z.Y., McKenzie-Smith G.C., Mitelut C.C., Castro M.D., D'Uva J., Kislin M., Sanes D.H., Kocher S.D., Wang S.S., Falkner A.L., Shaevitz J.W., Murthy M. SLEAP: A deep learning system for multi-animal pose tracking. *Nat. Methods.* 2022; 19(4): 486-495. DOI: 10.1038/s41592-022-01426-1
24. Ye S., Filippova A., Lauer J., Schneider S., Vidal M., Qiu T., Mathis A., Mathis M.W. SuperAnimal pretrained pose estimation models for behavioral analysis. *Nat. Commun.* 2024; 15(1): 5165. DOI: 10.1038/s41467-024-48792-2
25. Huang K., Han Y., Chen K., Pan H., Zhao G., Yi W., Li X., Liu S., Wei P., Wang L. A hierarchical 3D-motion learning framework for animal spontaneous behavior mapping. *Nat. Commun.* 2021; 12(1): 2784. DOI: 10.1038/s41467-021-22970-y
26. Zimmermann C., Schneider A., Alyahyay M., Brox T., Diester I. FreiPose: a deep learning framework for precise animal motion capture in 3D spaces. *BioRxiv.* 2020. DOI: 10.1101/2020.02.27.967620
27. Karashchuk P., Rupp K.L., Dickinson E.S., Walling-Bell S., Sanders E., Azim E., Brunton B.W., Tuthill J. C. Anipose: A toolkit for robust markerless 3D pose estimation. *Cell Rep.* 2021; 36(13): 109730. DOI: 10.1016/j.celrep.2021.109730
28. Tsuruda Y., Akita S., Yamanaka K., Matsumoto Y., Yamamoto M., Sano Y., Furuichi T., Takemura H. *3D Body Parts Tracking of Mouse Based on RGB-D Video from Under an Open Field*. In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2021: 7252-7255. DOI: 10.1109/EMBC46164.2021.9630565
29. Ebbesen C.L., Froemke R.C. Automatic mapping of multiplexed social receptive fields by deep learning and GPU-accelerated 3D videography. *Nat. Commun.* 2022; 13(1): 593. DOI: 10.1038/s41467-022-28153-7
30. 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. DOI: 10.3758/s13428-020-01381-9
31. Gosztolai A., Günel S., Lobato-Ríos V., Pietro Abrate M., Morales D., Rhodin H., Fua P., Ramdya P. LiftPose3D, a deep learning-based approach for transforming two-dimensional to three-dimensional poses in laboratory animals. *Nat. Methods.* 2021; 18(8): 975-981. DOI: 10.1038/s41592-021-01226-z
32. Gabriel C.J., Zeidler Z., Jin B., Guo C., Goodpaster C.M., Kashay A.Q., Wu A., Delaney M., Cheung J., DiFazio L.E., Sharpe M.J., Aharoni D., Wilke S.A., DeNardo L.A. BehaviorDEPOT is a simple, flexible tool for automated behavioral detection based on markerless pose tracking. *Elife.* 2022; 11: e74314. DOI: 10.7554/eLife.74314
33. Pennington Z.T., Dong Z., Feng Y., Vetere L.M., Page-Harley L., Shuman T., Cai D.J. ezTrack: An open-source video analysis pipeline for the investigation of animal behavior. *Sci. Rep.* 2019; 9(1): 19979. DOI: 10.1038/s41598-019-56408-9
34. Nandi A., Virmani G., Barve A., Marathe S. DBscorer: An Open-Source Software for Automated Accurate Analysis of Rodent Behavior in Forced Swim Test and Tail Suspension Test. *eNeuro.* 2021; 8(6): ENEURO.0305-21.2021. DOI: 10.1523/ENEURO.0305-21.2021
35. Bohoslav J.P., Wimalasena N.K., Clausen K.J., Dai Y.Y., Yarmolinsky D.A., Cruz T., Kashlan A.D., Chiappe M.E., Orefice L.L., Woolf C.J., Harvey C.D. DeepEthogram, a machine learning pipeline for supervised behavior classification from raw pixels. *Elife.* 2021; 10: e63377. DOI: 10.7554/eLife.63377
36. Nilsson S.R., Goodwin N.L., Choong J.J., Hwang S., Wright H.R., Norville Z.C., Tong X., Lin D., Bentzley B.S., Eshel N., McLaughlin R.J., Golden S.A. Simple Behavioral Analysis (SimBA) – an open-source toolkit for computer classification of complex social behaviors in experimental animals. *BioRxiv.* 2020; 2020.04.19.049452. DOI: 10.1101/2020.04.19.049452

37. Hindarto D. Use ResNet50V2 Deep Learning Model to Classify Five Animal Species. *J. JTIK J. Teknol. Inf. Dan. Komun.* 2023; 7(4): 758-768. DOI: 10.35870/jtik.v7i4.1845
38. Taiwo G., Vadera S., Alameer A. Vision transformers for automated detection of pig interactions in groups. *Smart Agricultural Technology.* 2024; 10: 100774. DOI: 10.1016/j.atech.2025.100774
39. Li J., Keselman M., Shlizerman E. OpenLabCluster: Active Learning Based Clustering and Classification of Animal Behaviors in Videos Based on Automatically Extracted Kinematic Body Keypoints. *BioRxiv.* 2022; DOI: 10.1101/2022.10.10.511660
40. Barulina M., Andreev A., Kovalenko I., Barmin I., Titov E., Kirillov D. Method for Preprocessing Video Data for Training Deep-Learning Models for Identifying Behavioral Events in Bio-Objects. *Mathematics.* 2024; 12(24): 3978. DOI: 10.3390/math12243978
41. Wiltshko A.B., Johnson M.J., Iurilli G., Peterson R.E., Katon J.M., Pashkovski S.L., Abaira V.E., Adams R.P., Datta S.R. Mapping Sub-Second Structure in Mouse Behavior. *Neuron.* 2015; 88(6): 1121-1135. DOI: 10.1016/j.neuron.2015.11.031
42. 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. DOI:10.1038/s41467-021-25420-x
43. Berman G.J., Choi D.M., Bialek W., Shaevitz J.W. Mapping the stereotyped behaviour of freely moving fruit flies. *J. R. Soc. Interface.* 2014; 11(99): 20140672. DOI: 10.1098/rsif.2014.0672
44. Luxem K., Mocellin P., Fuhrmann F., Kürsch J., Miller S.R., Palop J.J., Remy S., Bauer P. Identifying behavioral structure from deep variational embeddings of animal motion. *Commun. Biol.* 2022; 5(1): 1267. DOI: 10.1038/s42003-022-04080-7
45. Weinreb C., Pearl J., Lin S., Osman M.A.M., Zhang L., Annapragada S., Conlin E., Hoffman R., Makowska S., Gillis W.F., Jay M., Ye S., Mathis A., Mathis M.W., Pereira T., Linderman S.W., Datta S.R. Keypoint-MoSeq: parsing behavior by linking point tracking to pose dynamics. *Nat. Methods.* 2024; 21(7): 1329-1339. DOI: 10.1038/s41592-024-02318-2
46. Hu Y., Ferrario C.R., Maitland A.D., Ionides R.B., Ghimire A., Watson B., Iwasaki K., White H., Xi Y., Zhou J., Ye B. LabGym: Quantification of user-defined animal behaviors using learning-based holistic assessment. *Cell. Rep. Methods.* 2023; 3(3): 100415. DOI: 10.1016/j.crmeth.2023.100415
47. Parks R.J., Fares E., Macdonald J.K., Ernst M.C., Sinal C.J., Rockwood K., Howlett S.E. A procedure for creating a frailty index based on deficit accumulation in aging mice. *J. Gerontol. A. Biol. Sci. Med. Sci.* 2012; 67(3): 217-227. DOI: 10.1093/gerona/glr193

Сведения об авторах:

Шибеева Владлена Владимировна — студентка кафедры инновационной фармацевтики, медицинской техники и биотехнологий Физтех-школы биологической и медицинской физики Федерального государственного автономного образовательного учреждения высшего образования «Московский физико-технический институт (национальный исследовательский университет)»; <https://orcid.org/0009-0003-9841-3654>

Ильина Ирина Александровна — студентка кафедры системной и синтетической биологии Института биофизики будущего Федерального государственного автономного образовательного учреждения высшего образования «Московский физико-технический институт (национальный исследовательский университет)»; <https://orcid.org/0009-0006-4539-4244>

Балбек Кирилл Дмитриевич — преподаватель кафедры системной и синтетической биологии Института биофизики будущего Федерального государственного автономного образовательного учреждения высшего образования «Московский физико-технический институт (национальный исследовательский университет)»; <https://orcid.org/0000-0001-9885-1812>

Мелерзанов Александр Викторович — кандидат медицинских наук, заместитель заведующего кафедры инновационной фармацевтики, медицинской техники и биотехнологий Физтех-школы биологической и медицинской физики, заместитель исполнительного директора по науке и образованию Института биофизики будущего Федерального государственного автономного образовательного учреждения высшего образования «Московский физико-технический институт (национальный исследовательский университет)»; <https://orcid.org/0000-0002-4749-5851>