


Обзорная статья

УДК 519.71 : 519.21 : 004.93

DOI: 10.17072/1993-0550-2026-1-100-117

<https://elibrary.ru/bpojeg>



Современные методы моделирования динамики и отслеживания траектории систем с высокой степенью свободы

Илья Иванович Коваленко¹, Евгения Александровна Ахременко²,
Александр Игоревич Андреев³, Марина Александровна Барулина⁴

^{1, 2, 3, 4} Пермский государственный национальный исследовательский университет, Пермь, Россия

¹ilyaandko@ya.ru

²ahremencko.ev@yandex.ru

³i@mniium.ru

⁴mab@psu.ru

Аннотация. Работа посвящена анализу ключевого методологического сдвига в количественной оценке поведения био-объектов: перехода от классификации отдельных поведенческих актов к анализу их динамической структуры. Постановка проблемы заключается в наличии методологического разрыва: традиционные методы трекинга упрощают поведение до траектории центра масс, а современные алгоритмы глубокого обучения, обеспечивая высокую точность распознавания поз, часто игнорируют временной контекст и являются вычислительно затратными "черными ящиками". Цель работы – анализ существующих подходов к видеообработке и обоснование гибридной методологии, объединяющей детализацию нейросетевого анализа с системным подходом к динамике. Задачи включают обзор методов от ручного аннотирования до трансформерных архитектур и выявление их ограничений в задачах долгосрочного прогнозирования. Методы исследования базируются на сравнительном анализе алгоритмов компьютерного зрения, глубокого обучения и стохастического моделирования в контексте обработки видеоданных экспериментов с лабораторными животными. Основные результаты показывают, что нейросети оптимизированы преимущественно для локальной классификации. В работе предложена методологическая основа, интегрирующая классификацию на уровне кадров с построением интерпретируемых стохастических моделей (матриц вероятностей переходов). Главные выводы свидетельствуют о том, что использование марковских представлений в дискретных пространствах состояний позволяет эффективно выявлять устойчивые поведенческие режимы (аттракторы) и аномалии, создавая надежную базу для систем поддержки принятия решений без избыточных вычислительных мощностей.

Ключевые слова: динамический анализ; многомерные системы; системы высокой степени свободы; компьютерное зрение; глубокое обучение; нейронные сети; отслеживание объектов без маркеров; классификация состояний; матрицы вероятностей переходов; марковские модели.

Для цитирования: Коваленко И. И., Ахременко Е. А., Андреев А. И., Барулина М. А. Современные методы моделирования динамики и отслеживания траектории систем с высокой степенью



© Коваленко И. И., Ахременко Е. А., Андреев А. И., Барулина М. А., 2026
Лицензировано по CC BY 4.0. Чтобы посмотреть копию этой лицензии, посетите <https://creativecommons.org/licenses/by/4.0/>

свободы // Вестник Пермского университета. Математика. Механика. Информатика. 2026. № 1(72). С. 100–117. DOI: 10.17072/1993-0550-2026-1-100-117. <https://elibrary.ru/bpojeg>.

Статья поступила в редакцию 15.01.2025; одобрена после рецензирования 27.02.2025; принята к публикации 20.03.2026.

Review article

Modern Methods for Dynamics and Trajectory Tracking Modeling of High-Degree-of-Freedom Systems

Илья I. Kovalenko¹, Eugenia A. Ahremenko², Alexander I. Andreev³ Marina A. Barulina⁴

^{1, 2, 3, 4} Perm State University, Perm, Russia

¹ilyaandko@ya.ru

²ahremencko.ev@yandex.ru

³i@mniium.ru

⁴mab@psu.ru

Abstract. The study is devoted to analyzing a key methodological shift in the quantitative assessment of bio-object behavior: the transition from classifying individual behavioral acts to analyzing their dynamic structure. The problem statement lies in the existence of a methodological gap: traditional tracking methods simplify behavior to the center-of-mass trajectory, while modern deep learning algorithms, providing high pose recognition accuracy, often ignore the temporal context and function as computationally expensive "black boxes". The aim of the work is to analyze existing approaches to video processing and substantiate a hybrid methodology that combines the detail of neural network analysis with a systemic approach to dynamics. The objectives include reviewing methods ranging from manual annotation to transformer architectures and identifying their limitations in long-term forecasting tasks. The research methods are based on a comparative analysis of computer vision algorithms, deep learning, and stochastic modeling in the context of processing video data from laboratory animal experiments. The main results show that neural networks are optimized primarily for local classification. The paper proposes a methodological framework integrating frame-level classification with the construction of interpretable stochastic models (transition probability matrices). The main conclusions indicate that using Markov representations in discrete state spaces allows for the effective identification of stable behavioral modes (attractors) and anomalies, creating a reliable basis for decision support systems without excessive computational requirements.

Keywords: *dynamic analysis; multidimensional systems; high-degree-of-freedom systems; computer vision; deep learning; neural networks; markerless object tracking; state classification; transition probability matrices; Markov models.*

For citation: Kovalenko, I. I., Ahremenko, E. A., Andreev, A. I. and Barulina, M. A. (2026), "Modern Methods for Dynamics and Trajectory Tracking Modeling of High-Degree-of-Freedom Systems", *Bulletin of Perm University. Mathematics. Mechanics. Computer Science*, no 1(72), pp. 100–117. DOI: 10.17072/1993-0550-2026-1-100-117, <https://elibrary.ru/bpojeg>.

The article was submitted 15.01.2025; approved after reviewing 27.02.2025; accepted for publication 20.03.2026.

Введение

Анализ поведения лабораторных животных, или в общем смысле – био-объектов, является основой исследований в широком спектре наук о жизни, включая фармакологию, нейробиологию, этологию и генетику. В доклинических исследованиях поведенче-

ские тесты на лабораторных животных служат ключевым инструментом для оценки эффективности и безопасности новых лекарственных препаратов, изучения патогенеза заболеваний центральной нервной системы, а также для выявления функций генов [1]. Объективность, достоверность и воспроизводимость данных, получаемых в ходе таких экспериментов, напрямую влияют на принятие решений о дальнейшей разработке терапевтических подходов, что определяет высокую значимость и актуальность совершенствования методов поведенческого анализа.

С точки зрения системного анализа, поведение биологического объекта представляет собой выходной сигнал сложной динамической системы, характеризующейся стохастичностью, нелинейностью и наличием множества взаимосвязанных внутренних состояний [2]. Адекватное описание такой системы требует не просто фиксации отдельных поведенческих актов, но и анализа их последовательности, длительности, вероятностей переходов между ними и иных свойств. Именно временной контекст и динамические паттерны несут в себе критически важную информацию о функциональном состоянии организма [3]. Следовательно, ключевой научной задачей является разработка таких методов анализа, которые способны преобразовывать непрерывный поток видеоданных в информативную модель, сохраняющую ключевые динамические характеристики поведения для их последующей количественной оценки.

Исторически анализ поведения опирался на ручную обработку видеозаписей экспертами, что, несмотря на глубину экспертной оценки, сопряжено с рядом системных ограничений, таких как высокая трудоемкость, низкая пропускная способность и, что наиболее важно, элемент субъективности, снижающий воспроизводимость результатов [4]. Появление автоматизированных систем видео-трекинга частично решило эти проблемы, предоставив объективные метрики, такие как пройденная дистанция или время, проведенное в определенных зонах. Однако эти традиционные подходы, как правило, редуцируют сложное поведение биообъекта до анализа траектории центра масс его тела, игнорируя при этом богатый репертуар поз и коротких поведенческих актов [5]. В последние годы ведущими методами в данной области стали методы, основанные на машинном и, в частности, глубоком обучении. Современные архитектуры нейронных сетей позволяют с высокой точностью отслеживать множество точек на теле животного и классифицировать сложные поведенческие состояния с детализацией, ранее недоступной для автоматизированных систем трекинга [6, 7]. Тем не менее, эти мощные инструменты приводят к новым ограничениям: они часто требуют значительных вычислительных ресурсов, больших размеченных наборов данных для обучения и могут представлять собой "черные ящики", затрудняя интерпретацию полученных результатов и интеграцию временного контекста на длительных промежутках времени.

Таким образом, на текущем этапе развития технологий анализа поведения сформировался "научный пробел" между простыми, но ограниченными в пропускной способности или информативности традиционными методами, и мощными, но вычислительно сложными современными подходами. Существует острая потребность в разработке комплексных методов, которые обеспечивали бы баланс между детализацией анализа, способностью эффективно интегрировать временной контекст и вычислительной производительностью.

Целью данного обзора является проведение анализа существующих подходов к обработке видеoinформации о поведении быстродвижущихся биообъектов в стандартизированном экспериментальном пространстве. В ходе анализа будут выявлены их ключевые методологические и системные ограничения, что позволит обосновать необходимость разработки новых моделей и методов, а также определить наиболее перспективные направления для создания комплексных систем поддержки принятия решений в докли-

нических исследованиях. Для достижения поставленной цели был проведен анализ современных методов моделирования высокоразмерных систем с акцентом на машинное обучение и методы извлечения знаний. В работе предлагается методологическая база, объединяющая актуальные технологии распознавания с моделями, точно отражающими динамику исследуемых систем. Основные результаты работы заключаются в следующем.

1. Проанализированы традиционные методы, основанные на траекториях и классических алгоритмах компьютерного зрения, а также современные архитектуры глубокого обучения, применяемые для безмаркерной оценки поз и классификации поведения. Были рассмотрены ключевые предположения относительно динамики поведения и врожденные ограничения каждой методики в рамках системного подхода.
2. Выявлен методологический разрыв между точной локальной классификацией и комплексным системным анализом динамики. Особое внимание уделено отсутствию систематической структуры, позволяющей интегрировать последовательности меток с моделями общей структуры пространства состояний и динамики переходов.
3. Представлена четырехступенчатая структура динамического извлечения знаний, включающая высокоуровневое наблюдение, обучение позам или признакам, дискретизацию пространства состояний, а также стохастическое моделирование переходов с применением матриц вероятностей переходов и моделей Маркова.
4. Предложен исследовательский план, направленный на создание эффективных и интерпретируемых вычислительных методов, объединяющих технологии глубокого обучения с марковскими моделями и графовыми подходами к анализу поведения. Разрабатываемые методы обладают значительным потенциалом для применения в сферах механических систем, робототехники и фенотипизации поведения.

Данный подход ориентирован на переход от улучшения метрик классификации к разработке комплексных сквозных рабочих процессов, обеспечивающих преобразование исходных данных сенсоров в структурированные и интерпретируемые аналитические сведения о динамике сложных систем.

1. Традиционные методы поведенческого анализа и их ограничения

До широкого распространения глубокого обучения инструменты для анализа динамики сложных объектов были представлены двумя основными категориями: прямое наблюдение экспертами и ранние автоматизированные системы, основанные на классическом алгоритме компьютерного зрения и обработки сигналов. Эти традиционные методы стали основой для количественного описания динамических процессов и на протяжении многих лет широко использовались в экспериментальной механике и видеоанализе. Тем не менее, эти подходы имеют ряд системных ограничений. Анализ этих ограничений необходим для понимания того, почему современные методы развивались именно так.

1.1 Ручное аннотирование: золотой стандарт и его ограничения

Долгое время основным методом анализа сложной динамики было прямое наблюдение и ручное протоколирование (аннотирование) событий квалифицированным экспертом. Исследователь анализировал видеозаписи и, основываясь на заранее определенном классификаторе состояний, фиксировал моменты начала и окончания, а также частоту каждого динамического события [8]. Этот подход до сих пор считается "золотым стандартом" для верификации автоматизированных систем, поскольку человек способен

улавливать нюансы и контекстуальные детали движения, недоступные простым алгоритмам. Например, эксперт может отличить целевое функциональное движение от хаотического или сбойного режима на основе сложно формализуемых различий в кинематике. Именно такие детальные, длительные наблюдения позволяют выявлять специфические феноменологические особенности динамики, как, например, в задачах диагностики систем с накоплением усталостных повреждений или деградацией параметров, где специфические особенности поведения объекта обнаруживаются лишь при длительном мониторинге в штатных режимах эксплуатации [9].

Несмотря на свою информационную ценность, ручное аннотирование обладает критическими системными ограничениями, которые препятствуют его широкому применению в современных исследованиях с большими объемами данных.

Субъективность и низкая воспроизводимость: Оценка динамики человеком неизбежно несет в себе элемент субъективности. Воспроизводимость результатов существенно зависит от согласованности между разными экспертами – межэкспертная надежность, и даже от стабильности оценок одного и того же специалиста в разное время – внутриэкспертная надежность [10, 11]. Усталость, изменение фокуса внимания и разная интерпретация пограничных случаев приводят к вариативности данных [12], что является серьезной проблемой для стандартизации исследований.

Низкая пропускная способность и высокая трудоемкость: Процесс ручного аннотирования чрезвычайно медленный. Анализ одного часа видеозаписей может занимать время, кратно превышающее длительность записи, в зависимости от сложности классификатора и опыта эксперта [13]. Это делает данный подход практически неприменимым для крупномасштабных экспериментов, анализа длительных временных рядов или задач, включающих взаимодействие множества объектов в группе [14].

Ограниченная детализация: как правило, эксперт фиксирует лишь категориальные данные (тип режима/события) и их временные характеристики (длительность, частота). При этом теряется информация о тонкой кинематике: точные траектории движения отдельных элементов системы, мгновенные скорости, ускорения и плавность переходов. Эти параметры могут нести важную диагностическую информацию о состоянии системы, но их точная количественная оценка при ручном анализе невозможна.

1.2 Автоматизированный видео-трекинг в стандартизированных установках

Стремление преодолеть ограничения ручного аннотирования привело к созданию автоматизированных систем видео-трекинга, которые стали стандартом де-факто в задачах кинематического анализа подвижных объектов [5]. Эти системы, как правило, применяются в тандеме со стандартизированными экспериментальными полигонами, представляющими собой ограниченные двумерные или трехмерные области, геометрия которых накладывает граничные условия на динамику исследуемой системы [15].

Принцип работы таких систем заключается в редукции сложного многокомпонентного объекта к одной материальной точке – его центру масс (центроиду) или геометрическому центру проекции, с последующим анализом траектории этой точки в пространстве и времени. Программное обеспечение, такое как EthoVision XT [5] или ANY-maze [16], в режиме реального времени определяет координаты объекта на основе контраста с фоном (например, темный объект на светлой подложке). На основе полученных временных рядов координат рассчитывается набор объективных и легко интерпретируемых кинематических инвариантов:

1. Локомоторные метрики: длина траектории, векторы мгновенных скоростей и ускорений, распределение периодов движения и покоя.

2. Пространственно-топологические характеристики: время пребывания в заданных подмножествах конфигурационного пространства (зонирование), частота пересечения границ зон, параметры взаимодействия со стенками.
3. Событийные метрики: количество дискретных событий, определяемых пересечением виртуальных триггеров или достижением целевых областей пространства.

Главным достоинством такого подхода является объективность, воспроизводимость и высокая пропускная способность. Анализ проводится по детерминированным алгоритмам, исключая ошибку оператора, и позволяет обрабатывать большие массивы данных, что критически важно для моделирования.

Однако с точки зрения системного анализа динамики многомерных систем, такой подход является примером глубокого информационного редуционизма. Вся сложность фазового пространства системы, обладающей множеством внутренних степеней свободы (например, шарнирные механизмы, деформируемые тела), сводится к анализу проекции на плоскость движения центра масс. Это порождает фундаментальное ограничение: система не способна различать динамические режимы, которые реализуются в одной и той же точке пространства при нулевой скорости центра масс. Например, объект может находиться в стационарном состоянии (нулевая трансляционная скорость), но при этом испытывать сложные внутренние перестроения (вращение, вибрация, изменение конфигурации) или находиться в состоянии полного покоя. Для классических трекинг-систем эти принципиально разные термодинамические или механические состояния будут классифицированы одинаково – как "иммобильность" в заданной зоне [17]. Таким образом, теряется критически важная информация о внутренней динамике и фазовых переходах системы, что может приводить к неверной идентификации режимов функционирования.

1.3 Ранние подходы компьютерного зрения для расширенного анализа

Для частичного преодоления ограничений центроидного трекинга были предприняты попытки использовать более сложные, но все еще "классические" методы компьютерного зрения и обработки сигналов, не требующие применения глубоких нейронных сетей. Эти методы позволили перейти от анализа материальной точки к анализу распределенных характеристик объекта.

Вычитание фона

Этот метод является базисом для большинства систем видеоаналитики и детекции движения. Алгоритм формирует эталонную модель статической сцены (фона), а затем из каждого последующего кадра вычитает этот фон. Оставшиеся ненулевые пиксели интерпретируются как объекты переднего плана [18]. Главный недостаток метода – высокая чувствительность к нестационарности условий: изменениям освещенности, появлению динамических теней или медленному дрейфу параметров фона, например, при вибрации камеры, что приводит к существенным ошибкам сегментации и появлению артефактов [19].

Анализ силуэта

После сегментации объекта методом вычитания фона становится возможным анализ не только положения центра масс, но и геометрии его проекции (силуэта). Такие дескрипторы формы, как площадь, периметр, коэффициент эксцентриситета (вытянутость) или компактность, позволяют с некоторой долей вероятности классифицировать простые конфигурационные состояния системы. Например, изменение ориентации вытянутого объекта относительно вертикальной оси или переход из компактного состояния в развернутое характеризуется значимым изменением эксцентриситета и площади проекции [20]. Тем не менее, данный метод обладает низкой селективностью: он сильно зависит от ра-

курса наблюдения (проекционные искажения) и часто не способен различить кинематически разные состояния, имеющие схожие проекционные площади – например, отличить вращение симметричного объекта от его покоя [21].

Оптический поток

Этот метод оценивает поле скоростей видимого движения на изображении путем вычисления векторов смещения пикселей или их групп между последовательными кадрами на основе гипотезы постоянства яркости [22]. Анализ векторного поля оптического потока позволяет детектировать наличие движения и оценивать его интенсивность даже без явной сегментации границ объекта. Метод успешно применялся для детекции высокочастотных низкоамплитудных колебаний (микровибрации, дрожь) и кратковременных импульсных возмущений. Однако оптический поток плохо справляется с задачей семантической сегментации сложных динамических режимов, чувствителен к проблеме апертуры – неоднозначность движения в однородных текстурах, и сильно зашумлен в условиях реальных экспериментов с изменяющимся освещением [23].

1.4 Системные ограничения традиционных подходов

Подводя итог анализу традиционных методов исследования динамики, можно заключить, что они, несмотря на существенный вклад в стандартизацию экспериментальных методик, обладают общим системным недостатком: исследователь сталкивается с выбором между низкой воспроизводимостью экспертных оценок и объективностью, достигаемой ценой кардинального упрощения модели (информационного редукционизма). Рассмотрение сложной многокомпонентной системы как материальной точки или обобщенного геометрического примитива ("силуэта") приводит к игнорированию кинематической структуры объекта и сложной временной топологии переходов между динамическими режимами.

Попытки извлечь дополнительную информацию с помощью классических детерминированных алгоритмов компьютерного зрения оказались недостаточно робастными к вариациям условий эксперимента и плохо масштабируемыми для задач высокой размерности. Эта фундаментальная неспособность традиционных подходов эффективно и объективно реконструировать внутреннюю структуру динамики, ограничиваясь лишь интегральными пространственно-временными характеристиками, послужила главным стимулом для поиска принципиально новых решений, ставших доступными с развитием методов машинного обучения и нейросетевого моделирования [24].

2. Современные подходы на основе машинного и глубокого обучения

Радикальные ограничения традиционных методов анализа динамики послужили катализатором поиска принципиально новых подходов, ставших возможными благодаря стремительному развитию машинного обучения и, в особенности, глубоких нейронных сетей. Этот переход ознаменовал смену парадигмы в инженерном анализе и техническом зрении: от анализа одномерных траекторий центроидов и простых геометрических примитивов к детальному многомерному описанию конфигураций и кинематики распределенных систем. Современные методы позволяют автоматизировать не только трекинг, но и идентификацию сложных динамических режимов с точностью, сопоставимой с экспертной оценкой, открывая новые горизонты для диагностики механических систем, робототехники и биомеханики [4].

2.1. Революция в оценке позы: безмаркерный трекинг ключевых точек

Ключевым технологическим прорывом, позволившим преодолеть проблему информационного редукционизма классического трекинга, стало появление инструментов для безмаркерной оценки позы (markerless pose estimation). Вместо редукции сложного объекта к материальной точке, эти системы позволяют с высокой точностью восстанавливать

кинематику многозвенных механизмов, отслеживая координаты множества заранее определенных ключевых узлов (например, шарниров манипулятора, точек крепления деформируемых конструкций или суставов биомеханических моделей), фактически реконструируя "скелетную" модель объекта в каждом кадре видеопотока [25].

В основе этих инструментов лежат глубокие сверточные нейронные сети (CNN) [26], в частности архитектуры с остаточными связями (ResNet) [27], предварительно обученные на масштабных наборах данных, таких как ImageNet [28]. За счет механизма трансферного обучения (transfer learning) эти сети способны адаптироваться к новым задачам на основе относительно небольших выборок (100–200 кадров), размеченных вручную. Это позволяет с высокой точностью предсказывать положение узловых точек на новых изображениях даже в условиях сложного фона и меняющегося освещения.

Одним из наиболее известных инструментов, адаптированных для широкого спектра задач динамики, является библиотека DeepLabCut [6]. Ее архитектура сделала технологию оценки кинематики доступной для лабораторий, не специализирующихся на глубоком обучении. DeepLabCut позволяет пользователю гибко определять топологию отслеживаемой системы, что обеспечивает применимость как для анализа биологических объектов, так и для диагностики промышленных роботов или испытаний механических узлов. Дальнейшее развитие инструментария позволило перейти к трехмерной реконструкции движения и анализу взаимодействия нескольких объектов в едином рабочем пространстве [7, 29].

Другим мощным инструментом является SLEAP (Social LEAP Estimates Animal Poses), архитектура которого изначально оптимизирована для задач мультиобъектного трекинга, включая сценарии с перекрытиями взаимодействующих агентов [30]. Современные версии SLEAP демонстрируют высокую скорость инференса, что делает их предпочтительным выбором для обработки высокоскоростных видеопотоков в реальном времени.

Получение временных рядов координат ключевых точек кардинально меняет уровень доступной информации. Исследователи получают доступ к полному фазовому портрету системы: углам в сочленениях, угловым скоростям, фазовым сдвигам между элементами и деформациям. Это позволяет перейти от вопроса "где находится объект?" к вопросам "в каком режиме он функционирует?" и "наблюдаются ли признаки деградации кинематической цепи?", открывая возможности для предиктивной диагностики и анализа тонкой структуры движения [31].

2.2. Автоматическая классификация поведения

Наличие высокоточных данных о конфигурации системы является основой для следующего шага – автоматической идентификации динамических режимов и диагностики состояний. Здесь доминируют подходы на основе машинного и глубокого обучения, которые методологически можно разделить на две категории.

Первый подход является двухэтапным. Сначала с помощью систем типа DeepLabCut или SLEAP из видеопотока извлекаются временные ряды координат ключевых узлов. Затем эти кинематические данные, а также их производные (скорости, ускорения, углы), используются как векторы признаков для классических моделей обучения с учителем. Эксперт размечает временные интервалы, соответствующие различным режимам работы (например, "штатный режим", "дисбаланс", "переходный процесс"), и на этих данных обучается классификатор, такой как метод опорных векторов (SVM) [32], случайный лес (Random Forest) [33] или градиентный бустинг (Gradient Boosting) [34, 35]. Этот метод обладает хорошей интерпретируемостью, так как позволяет оценить вклад каждого кинематического параметра в принятие решения, но его точность критически зависит от полноты сформированного пространства признаков.

Более современные подходы стремятся к созданию сквозных (end-to-end) моделей, обучающихся классифицировать состояния системы непосредственно из "сырых" сенсорных данных (пикселей видео или сигналов датчиков), минуя этап явного конструирования признаков [36]. Это позволяет модели самостоятельно выделять скрытые нелинейные паттерны, которые могут быть неочевидны для эксперта-человека.

Анализ отдельных кадров с помощью CNN

Простейший вариант реализации – использование стандартных сверточных архитектур (например, ResNet, Inception) для классификации состояния системы в каждом отдельном кадре [37]. Модель обучается распознавать статические конфигурации, характерные для того или иного режима. Однако этот подход имеет фундаментальное ограничение: он игнорирует временной контекст. Многие дефекты, например, такие как, низкочастотная модуляция, прецессия вала, являются динамическими процессами и не могут быть идентифицированы по мгновенному снимку.

Анализ последовательностей с помощью рекуррентных и трансформерных сетей

Для преодоления ограничений статического анализа необходимо использование архитектур, способных обрабатывать последовательности. Исторически для этого применялись рекуррентные нейронные сети (RNN) [38] и их модификации LSTM [39], обладающие "памятью" о предыстории процесса [40]. Однако в последние годы доминирующей архитектурой для анализа временных рядов в механике стали трансформеры (Transformers) [41]. Модели, использующие механизм внимания (Attention) [42], позволяют эффективно взвешивать значимость различных временных отсчетов и улавливать как краткосрочные импульсные возмущения, так и долгосрочные тренды деградации. Это дает им значительное преимущество в задачах прогнозирования отказов и диагностики сложных нелинейных систем [43].

2.3. Применение и методологические инновации

Современные методы глубокого обучения уже доказали свою эффективность при решении задач идентификации состояний в системах с высокой стохастичностью. Показательным примером может служить количественная оценка специфических высокочастотных паттернов, в частности, актов грызения, у лабораторных биомоделей линии 5xFAD [44]. Применение нейросетевых алгоритмов позволило формализовать и объективно измерить поведенческий фенотип, характеризующийся сложной микроструктурой движений, который ранее оставался недоступным для фиксации традиционными интегральными методами. Этот результат демонстрирует потенциал метода не только в биологии, но и как универсального инструмента для детектирования тонких динамических аномалий в любых сложных системах.

Тем не менее, высокая вычислительная сложность трансформерных моделей ограничивает их применение в аппаратных системах реального времени. В связи с этим перспективным направлением является разработка эффективных методов предобработки данных, кодирующих временную динамику в компактные статические представления. Примером такого подхода является метод пространственно-селективного временного цветокодирования (ЦВК) [45], который преобразует последовательность кадров движения в единое композитное изображение, где цветовые каналы кодируют изменение состояния системы во времени. Такая предобработка позволяет сохранить информацию о фазовой траектории, существенно снижая требования к вычислительным ресурсам классификатора.

2.4. Новые возможности и новые вызовы

Подводя итог, можно утверждать, что методы на основе глубокого обучения кардинально расширили инструментарий системного анализа динамики, обеспечив высокий

уровень автоматизации и объективности. Они позволяют не просто регистрировать факты отказов, а количественно описывать изменение динамических состояний, открывая путь к предиктивной аналитике.

Вместе с тем, эти мощные инструменты порождают и новые вызовы. К ним относятся потребность в больших, качественно размеченных наборах данных для обучения, высокая требовательность к вычислительным ресурсам, а также проблема "черного ящика", когда принятое моделью решение сложно интерпретировать с физической точки зрения, а попытки post-hoc объяснения могут быть ненадежными [46]. Анализ этих ограничений и поиск путей их преодоления (Explainable AI, XAI) является ключевой задачей на современном этапе развития вычислительной механики и диагностики.

3. Анализ ограничений современных подходов

Внедрение методов глубокого обучения, существенно изменило область анализа поведения, предоставив исследователям инструменты для детальной и объективной количественной оценки. Однако, как и любая технология, методы глубокого обучения обладают собственным набором системных ограничений и компромиссов. Простого стремления к повышению метрик точности классификации недостаточно для построения адекватных моделей сложных динамических систем. Критический анализ выявляет ряд фундаментальных проблем, которые препятствуют полному раскрытию потенциала современных подходов и формируют "научный пробел" данной области.

3.1. Проблема временного горизонта и потеря долгосрочной динамики

Одним из наиболее существенных ограничений является неспособность большинства современных моделей эффективно анализировать динамику в долгосрочной перспективе. Архитектуры, основанные на анализе отдельных кадров (CNN), по своей сути инвариантны к временному контексту. Более продвинутые модели, такие как RNN или трансформеры, решают эту проблему, но лишь в рамках ограниченного временного окна – как правило, от долей секунды до нескольких секунд [47].

Однако функционирование сложной системы – это не просто сумма независимых событий секундной или субсекундной длительности. Это структурированная последовательность, обладающая собственной внутренней логикой и иерархией временных масштабов [31]. Долгосрочные эксплуатационные стратегии, медленные тренды деградации параметров (дрейф), циклы накопления усталости и, что особенно важно, переходные процессы между режимами – все это остается за рамками анализа коротких временных отрезков. Таким образом, происходит потеря информации на макроуровне системной динамики, что не позволяет ответить на вопросы о том, как организована глобальная структура фазового пространства и как она трансформируется под влиянием внешних факторов или внутренних изменений параметров системы.

3.2. Вычислительная сложность как барьер для практического применения

Стремление уловить более сложные пространственно-временные зависимости напрямую ведет к другой системной проблеме – высокой вычислительной сложности. Модели, демонстрирующие наилучшую точность (SOTA), особенно 3D-CNN и видеотрансформеры, требуют для обучения и инференса значительных вычислительных ресурсов: мощных графических процессоров (GPU) и существенного времени на обработку [48]. Это ограничение имеет несколько критических практических следствий:

1. Барьер для внедрения: Высокие требования к аппаратному обеспечению затрудняют интеграцию этих методов в промышленные системы мониторинга и встроенные системы диагностики с ограниченным энергопотреблением.
2. Невозможность анализа в реальном времени: обработка данных часто происходит в режиме post-processing и может занимать время, превышающее длительность

ность самого процесса. Это исключает возможность создания адаптивных систем управления с обратной связью, где управляющее воздействие должно корректироваться в зависимости от мгновенного состояния объекта.

3. Проблема масштабируемости: Анализ длительных временных рядов (например, ресурсных испытаний или непрерывного мониторинга) становится вычислительно неразрешимой задачей, что ограничивает исследования кумулятивных эффектов и редких событий.

3.3. Проблема "черного ящика" и дефицит интерпретируемости

Глубокие нейронные сети часто характеризуются как "черные ящики". Несмотря на высокую точность аппроксимации, внутренняя логика принятия решений моделью остается непрозрачной [46]. Модель может научиться классифицировать режимы, основываясь на артефактах сигнала или фона, а не на физически значимых кинематических инвариантах. Это создает риск получения формально точных, но физически некорректных результатов и подрывает доверие к автоматизированной системе диагностики. Для инженерных приложений и задач обеспечения надежности критически важна не только точность детекции, но и понимание того, на каких именно признаках (физических параметрах) модель основывает свой вывод.

3.4. Смещение фокуса с анализа системы на точность классификации

Вышеперечисленные ограничения приводят к общей методологической проблеме: большинство современных работ в области машинного обучения фокусируются на решении локальной задачи – достижении максимальной точности классификации отдельных состояний. Публикации часто ограничиваются демонстрацией высоких значений F1-метрики. Однако, с точки зрения системного анализа, классификация – это не конечная цель, а лишь этап предварительной обработки: преобразование сырых данных в символичный временной ряд (последовательность состояний).

Истинная научная задача начинается дальше – с анализа этого ряда для понимания топологии и динамики системы как единого целого. Ключевой шаг от дискретной классификации к системному анализу заключается в смещении фокуса с самих состояний на динамику переходов между ними. Иллюстративным примером такого подхода является использование матриц переходных вероятностей (Transition Probability Matrices) как инструмента для описания динамического "портрета" системы. Анализ спектральных свойств таких матриц позволяет количественно оценить вероятности переключений между режимами, выявить устойчивые циклы и аттракторы, и, самое главное, объективно сравнить эти динамические паттерны для различных состояний системы (например, "норма" или "дефект"). Этот подход позволяет извлечь информацию о внутренней организации процессов, которая полностью теряется при анализе лишь интегральных статистик пребывания в состояниях [49].

Таким образом, существующий "научный пробел" заключается не столько в недостаточной точности классификаторов, сколько в отсутствии методологического моста между результатом их работы и инструментами для последующего системного анализа динамической структуры процессов.

Заключение

В настоящем обзоре прослежена эволюция методологии количественного анализа динамики систем с большим числом степеней свободы: от интерпретируемых, но редуционистских классических подходов (ручное аннотирование, центроидный трекинг) до современных методов глубокого обучения, которые обеспечивают высокую детализацию описания конфигурации, но ограничены вычислительной сложностью и слабой объяснимостью. Ключевой выявленный методологический разрыв заключается в отсутствии устойчивых процедур перехода от последовательности локальных классификационных

решений к объектно-ориентированному системному анализу динамики, опирающемуся на глобальную структуру фазового пространства. Для его преодоления мы предлагаем рассматривать современные классификаторы не как конечную цель, а как первый шаг в pipeline извлечения знаний: "высокоразмерный сенсорный поток → оценка позы/признаков → дискретизация пространства состояний → оценка матриц переходных вероятностей и марковских моделей → анализ устойчивости, аттракторов и аномалий".

В контексте машинного обучения и извлечения знаний такой взгляд определяет несколько приоритетных направлений дальнейших исследований.

1. Компактное кодирование временной динамики. Разработка методов преобразования длинных временных рядов в информативные статические представления, сохраняющие структуру переходов между состояниями и пригодные для обучения легких классификаторов и регрессоров.
2. Совместное обучение состояний и переходов. Построение гибридных архитектур, в которых модели глубокого обучения для распознавания позы и состояний оптимизируются совместно с марковскими моделями, отражающими ожидаемую структуру переходов, что должно повысить устойчивость к шуму и увеличить интерпретируемость.
3. Интеграция с Explainable AI. Использование графов состояний, матриц переходных вероятностей и производных от них метрик (энтропии, времён первого возврата, устойчивых циклов) в качестве глобальных объяснений поведения сложных моделей и основы для диагностических показателей, понятных эксперту инженеру.
4. Масштабируемые алгоритмы анализа динамики. Разработка вычислительно эффективных процедур оценки и регуляризации переходных матриц для длинных временных рядов, включая обработку редких событий, нестационарность и иерархические уровни описания.
5. Мультидоменная валидация. Систематическое тестирование предложенного фреймворка на задачах из механики, робототехники и поведенческой биологии с сопоставлением вариантов разбиения пространства состояний и различных семейств стохастических моделей.

Развитие этих направлений позволит перейти от узко ориентированных систем распознавания отдельных событий к комплексным, вычислительно эффективным и физически интерпретируемым системам динамического анализа, замыкающим цикл от извлечения признаков и классификации до извлечения знаний о глобальной структуре поведения многомерных объектов и поддержки принятия инженерных решений.

Список источников

1. *Schiehlen W.* Multibody system dynamics: roots and perspectives // *Multibody system dynamics*. 1997. V. 1, no 2. P. 149–188.
2. *Strogatz S. H.* Nonlinear dynamics and chaos: with applications to physics, biology, chemistry, and engineering. Chapman and Hall/CRC, 2024.
3. *Rabiner L. R.* A tutorial on hidden Markov models and selected applications in speech recognition // *Proceedings of the IEEE*. 2002. V. 77, no 2. P. 257–286.
4. *Berman G. J.* Measuring behavior across scales // *BMC biology*. 2018. V. 16, no 1. P. 23.
5. *Noldus L. P. J. J., Spink A. J., Tegelenbosch R. A. J.* EthoVision: a versatile video tracking system for automation of behavioral experiments // *Behavior Research Methods, Instruments, & Computers*. 2001. V. 33, no 3. P. 398–414.
6. *Mathis A. et al.* DeepLabCut: markerless pose estimation of user-defined body parts with deep learning // *Nature neuroscience*. 2018. V. 21, no 9. P. 1281–1289.

7. *Nath T. et al.* Using DeepLabCut for 3D markerless pose estimation across species and behaviors // *Nature protocols*. 2019. V. 14, no 7. P. 2152–2176.
8. *Dawkins M. S., Martin P., Bateson P.* Measuring Behaviour. An Introductory Guide // *Journal of Animal Ecology*. 1994. V. 63, no 3. P. 746.
9. *Ушакова А. А. и др.* Некоторые поведенческие особенности сенильных животных 5XFAD, выявляемые при длительных наблюдениях в домашних клетках // *Вестник Пермской государственной фармацевтической академии "Кромеровские чтения 2023"*. 2023. С. 95–98.
10. *Tuytens F. A. M. et al.* Observer bias in animal behaviour research: can we believe what we score, if we score what we believe? // *Animal Behaviour*. 2014. V. 90. P. 273–280.
11. *Fort K., Nazarenko A., Rosset S.* Modeling the complexity of manual annotation tasks: a grid of analysis // *International conference on computational linguistics*. 2012. P. 895–910.
12. *Ahmadzadeh A. et al.* A Guide for Manual Annotation of Scientific Imagery: How to Prepare for Large Projects // *arXiv preprint arXiv:2508.14801*. 2025.
13. *Thakur A., Arya S.* Comparative analysis of manual and programmed annotations for crowd assessment and classification using artificial intelligence // *Data Science and Management*. 2024. V. 7, no 4. P. 340–348.
14. *Dell A. I. et al.* Automated image-based tracking and its application in ecology // *Trends in ecology & evolution*. 2014. V. 29, no 7. P. 417–428.
15. *Seibenhener M. L., Wooten M. C.* Use of the open field maze to measure locomotor and anxiety-like behavior in mice // *Journal of visualized experiments: JoVE*. 2015. No 96. P. 52434.
16. *Lim C. J. M. et al.* Comparison of automated video tracking systems in the open field test: ANY-Maze versus EthoVision XT // *Journal of Neuroscience Methods*. 2023. V. 397. P. 109940.
17. *Escalona J. L., Urda P., Muñoz S.* A track geometry measuring system based on multi-body kinematics, inertial sensors and computer vision // *Sensors*. 2021. V. 21, no 3. P. 683.
18. *Piccardi M.* Background subtraction techniques: a review // *2004 IEEE international conference on systems, man and cybernetics (IEEE Cat. No. 04CH37583)*. IEEE, 2004. V. 4. P. 3099–3104.
19. *Bouwman T.* Traditional and recent approaches in background modeling for foreground detection: An overview // *Computer science review*. 2014. V. 11. P. 31–66.
20. *Bobick A. F., Davis J. W.* The recognition of human movement using temporal templates // *IEEE Transactions on pattern analysis and machine intelligence*. 2002. V. 23, no 3. P. 257–267.
21. *Haro G.* Shape from silhouette consensus and photo-consistency // *2014 IEEE International Conference on Image Processing (ICIP)*. IEEE, 2014. P. 4837–4841.
22. *Barron J. L., Fleet D. J., Beauchemin S. S.* Performance of optical flow techniques // *International journal of computer vision*. 1994. V. 12, no 1. P. 43–77.
23. *Baker S. et al.* A database and evaluation methodology for optical flow // *International journal of computer vision*. 2011. V. 92, no 1. P. 1–31.
24. *Brunton S. L., Noack B. R., Koumoutsakos P.* Machine learning for fluid mechanics // *Annual review of fluid mechanics*. 2020. V. 52, no 1. P. 477–508.
25. *Pereira T. D. et al.* SLEAP: A deep learning system for multi-animal pose tracking // *Nature methods*. 2022. V. 19, no 4. P. 486–495.
26. *LeCun Y. et al.* Gradient-based learning applied to document recognition // *Proceedings of the IEEE*. 2002. V. 86, no 11. P. 2278–2324.

27. He K. et al. Deep residual learning for image recognition // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. P. 770–778.
28. Deng J. et al. Imagenet: A large-scale hierarchical image database // 2009 IEEE conference on computer vision and pattern recognition (CVPR 2009). 2009. P. 248–255.
29. Lauer J. et al. Multi-animal pose estimation, identification and tracking with DeepLabCut // Nature Methods. 2022. V. 19, no 4. P. 496–504.
30. Pereira T. D. et al. Fast animal pose estimation using deep neural networks // Nature methods. 2019. V. 16, no 1. P. 117–125.
31. Wiltschko A. B. et al. Mapping sub-second structure in mouse behavior // Neuron. 2015. V. 88, no 6. P. 1121–1135.
32. Cortes C., Vapnik V. Support-vector networks // Machine learning. 1995. V. 20, no 3. P. 273–297.
33. Breiman L. Random forests // Machine learning. 2001. V. 45, no 1. P. 5–32.
34. Friedman J. H. Greedy function approximation: a gradient boosting machine // Annals of statistics. 2001. P. 1189–1232.
35. Kabra M. et al. JAABA: interactive machine learning for automatic annotation of animal behavior // Nature methods. 2013. V. 10, no 1. P. 64–67.
36. Zhang L. et al. A nearly end-to-end deep learning approach to fault diagnosis of wind turbine gearboxes under nonstationary conditions // Engineering applications of artificial intelligence. 2023. V. 119. P. 105735.
37. Sturman O. et al. Deep learning-based behavioral analysis reaches human accuracy and is capable of outperforming commercial solutions // Neuropsychopharmacology. 2020. V. 45, no 11. P. 1942–1952.
38. Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network // Physica D: Nonlinear Phenomena. 2020. V. 404. P. 132306.
39. Graves A. Long short-term memory // Supervised sequence labelling with recurrent neural networks. 2012. P. 37–45.
40. Graves A., Mohamed A., Hinton G. Speech recognition with deep recurrent neural networks // 2013 IEEE international conference on acoustics, speech and signal processing. Ieee, 2013. P. 6645–6649.
41. Ashish V. Attention is all you need // Advances in neural information processing systems. 2017. V. 30. P. 1.
42. Bertasius G., Wang H., Torresani L. Is space-time attention all you need for video understanding? // Icml. 2021. V. 2, no 3. P. 4.
43. Nascimento E. G. S. et al. T4PdM: A deep neural network based on the transformer architecture for fault diagnosis of rotating machinery // arXiv preprint arXiv:2204.03725. 2022.
44. Ushakova A. et al. Assessment of Gnawing Behavior in 5xFAD Mice // International Perm Forum Science and Global Challenges of the 21st Century. Cham : Springer Nature Switzerland, 2022. P. 493–498.
45. Barulina M. et al. Method for preprocessing video data for training deep-learning models for identifying behavioral events in bio-objects // Mathematics. 2024. V. 12. no 24. P. 3978.
46. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead // Nature machine intelligence. 2019. V. 1, no 5. P. 206–215.
47. Carreira J., Zisserman A. Quo vadis, action recognition? a new model and the kinetics dataset // proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017. P. 6299–6308.

48. Tran D. et al. Learning spatiotemporal features with 3d convolutional networks // Proceedings of the IEEE international conference on computer vision. 2015. P. 4489–4497.
49. Shirobokova S. et al. Application of Transition Matrices as Selective Descriptors for Behavioral Phenotyping of Young 5xFAD Animals // International Perm Forum Science and Global Challenges of the 21st Century. Cham: Springer Nature Switzerland, 2022. P. 499–506.

References

1. Schiehlen, W. (1997), "Multibody system dynamics: roots and perspectives", *Multibody System Dynamics*, 1(2), pp. 149–188.
2. Strogatz, S.H. (2024), *Nonlinear dynamics and chaos: with applications to physics, biology, chemistry, and engineering*. Chapman and Hall/CRC.
3. Rabiner, L.R. (2002), "A tutorial on hidden Markov models and selected applications in speech recognition", *Proceedings of the IEEE*, 77(2), pp. 257–286.
4. Berman, G.J. (2018), "Measuring behavior across scales", *BMC Biology*, 16(1), p. 23.
5. Noldus, L.P.J.J., Spink, A.J. and Tegelenbosch, R.A.J. (2001), "EthoVision: a versatile video tracking system for automation of behavioral experiments", *Behavior Research Methods, Instruments, & Computers*, 33(3), pp. 398–414.
6. Mathis, A. et al. (2018), "DeepLabCut: markerless pose estimation of user-defined body parts with deep learning", *Nature Neuroscience*, 21(9), pp. 1281–1289.
7. Nath, T. et al. (2019), "Using DeepLabCut for 3D markerless pose estimation across species and behaviors", *Nature Protocols*, 14(7), pp. 2152–2176.
8. Dawkins, M.S., Martin, P. and Bateson, P. (1994), "Measuring Behaviour. An Introductory Guide", *Journal of Animal Ecology*, 63(3), p. 746.
9. Ushakova, A.A. et al. (2023), "Some behavioral features of senile 5XFAD animals identified during long-term observations in home cages", in *Vestnik Permskoy gosudarstvennoy farmatsevticheskoy akademii "Kromerovskie chteniya 2023"*, pp. 95–98.
10. Tuytens, F.A.M. et al. (2014), "Observer bias in animal behaviour research: can we believe what we score, if we score what we believe?", *Animal Behaviour*, 90, pp. 273–280.
11. Fort, K., Nazarenko, A. and Rosset, S. (2012), "Modeling the complexity of manual annotation tasks: a grid of analysis", in *International Conference on Computational Linguistics*, pp. 895–910.
12. Ahmadzadeh, A. et al. (2025), "A Guide for Manual Annotation of Scientific Imagery: How to Prepare for Large Projects", *arXiv preprint arXiv:2508.14801*.
13. Thakur, A. and Arya, S. (2024), "Comparative analysis of manual and programmed annotations for crowd assessment and classification using artificial intelligence", *Data Science and Management*, 7(4), pp. 340–348.
14. Dell, A.I. et al. (2014), "Automated image-based tracking and its application in ecology", *Trends in Ecology & Evolution*, 29(7), pp. 417–428.
15. Seibenhener, M.L. and Wooten, M.C. (2015), "Use of the open field maze to measure locomotor and anxiety-like behavior in mice", *Journal of Visualized Experiments: JoVE*, (96), p. e52434.
16. Lim, C.J.M. et al. (2023), "Comparison of automated video tracking systems in the open field test: ANY-Maze versus EthoVision XT", *Journal of Neuroscience Methods*, 397, p. 109940.
17. Escalona, J.L., Urda, P. and Muñoz, S. (2021), "A track geometry measuring system based on multi-body kinematics, inertial sensors and computer vision", *Sensors*, 21(3), p. 683.
18. Piccardi, M. (2004), "Background subtraction techniques: a review", in *2004 IEEE International Conference on Systems, Man and Cybernetics*. IEEE, Vol. 4, pp. 3099–3104.

19. Bouwmans, T. (2014), "Traditional and recent approaches in background modeling for foreground detection: An overview", *Computer Science Review*, 11, pp. 31–66.
20. Bobick, A.F. and Davis, J.W. (2002), "The recognition of human movement using temporal templates", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(3), pp. 257–267.
21. Haro, G. (2014), "Shape from silhouette consensus and photo-consistency", in *2014 IEEE International Conference on Image Processing (ICIP)*. IEEE, pp. 4837–4841.
22. Barron, J.L., Fleet, D.J. and Beauchemin, S.S. (1994), "Performance of optical flow techniques", *International Journal of Computer Vision*, 12(1), pp. 43–77.
23. Baker, S. et al. (2011), "A database and evaluation methodology for optical flow", *International Journal of Computer Vision*, 92(1), pp. 1–31.
24. Brunton, S.L., Noack, B.R. and Koumoutsakos, P. (2020), "Machine learning for fluid mechanics", *Annual Review of Fluid Mechanics*, 52(1), pp. 477–508.
25. Pereira, T.D. et al. (2022), "SLEAP: A deep learning system for multi-animal pose tracking", *Nature Methods*, 19(4), pp. 486–495.
26. LeCun, Y. et al. (2002), "Gradient-based learning applied to document recognition", *Proceedings of the IEEE*, 86(11), pp. 2278–2324.
27. He, K. et al. (2016), "Deep residual learning for image recognition", in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770–778.
28. Deng, J. et al. (2009), "Imagenet: A large-scale hierarchical image database", in *2009 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, pp. 248–255.
29. Lauer, J. et al. (2022), "Multi-animal pose estimation, identification and tracking with DeepLabCut", *Nature Methods*, 19(4), pp. 496–504.
30. Pereira, T.D. et al. (2019), "Fast animal pose estimation using deep neural networks", *Nature Methods*, 16(1), pp. 117–125.
31. Wiltschko, A.B. et al. (2015), "Mapping sub-second structure in mouse behavior", *Neuron*, 88(6), pp. 1121–1135.
32. Cortes, C. and Vapnik, V. (1995), "Support-vector networks", *Machine Learning*, 20(3), pp. 273–297.
33. Breiman, L. (2001), "Random forests", *Machine Learning*, 45(1), pp. 5–32.
34. Friedman, J.H. (2001), "Greedy function approximation: a gradient boosting machine", *Annals of Statistics*, pp. 1189–1232.
35. Kabra, M. et al. (2013), "JAABA: interactive machine learning for automatic annotation of animal behavior", *Nature Methods*, 10(1), pp. 64–67.
36. Zhang, L. et al. (2023), "A nearly end-to-end deep learning approach to fault diagnosis of wind turbine gearboxes under nonstationary conditions", *Engineering Applications of Artificial Intelligence*, 119, p. 105735.
37. Sturman, O. et al. (2020), "Deep learning-based behavioral analysis reaches human accuracy and is capable of outperforming commercial solutions", *Neuropsychopharmacology*, 45(11), pp. 1942–1952.
38. Sherstinsky, A. (2020), "Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network", *Physica D: Nonlinear Phenomena*, 404, p. 132306.
39. Graves, A. (2012), "Long short-term memory", in *Supervised Sequence Labelling with Recurrent Neural Networks*, pp. 37–45.
40. Graves, A., Mohamed, A. and Hinton, G. (2013), "Speech recognition with deep recurrent neural networks", in *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. IEEE, pp. 6645–6649.
41. Ashish, V. (2017), "Attention is all you need", *Advances in Neural Information Processing Systems*, 30, p. 1.

42. Bertasius, G., Wang, H. and Torresani, L. (2021), "Is space-time attention all you need for video understanding?", *ICML*, 2(3), p. 4.
43. Nascimento, E.G.S. et al. (2022), "T4PdM: A deep neural network based on the transformer architecture for fault diagnosis of rotating machinery", *arXiv preprint arXiv:2204.03725*.
44. Ushakova, A. et al. (2022), "Assessment of Gnawing Behavior in 5xFAD Mice", in *International Perm Forum Science and Global Challenges of the 21st Century*. Cham: Springer Nature Switzerland, pp. 493–498.
45. Barulina, M. et al. (2024), "Method for preprocessing video data for training deep-learning models for identifying behavioral events in bio-objects", *Mathematics*, 12(24), p. 3978.
46. Rudin, C. (2019), "Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead", *Nature Machine Intelligence*, 1(5), pp. 206–215.
47. Carreira, J. and Zisserman, A. (2017), "Quo vadis, action recognition? A new model and the kinetics dataset", in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 6299–6308.
48. Tran, D. et al. (2015), "Learning spatiotemporal features with 3d convolutional networks", in *Proceedings of the IEEE International Conference on Computer Vision*, pp. 4489–4497.
49. Shirobokova, S. et al. (2022), "Application of Transition Matrices as Selective Descriptors for Behavioral Phenotyping of Young 5xFAD Animals", in *International Perm Forum Science and Global Challenges of the 21st Century*. Cham: Springer Nature Switzerland, pp. 499–506.

Информация об авторах:

И. И. Коваленко – аспирант, заведующий лабораторией Центра искусственного интеллекта Физико-математического института Пермского государственного национального исследовательского университета (614068, г. Пермь, ул. Букирева, д.15), eLibrary Author ID: 1161522, Scopus AuthorID: 57878997400, ORCID: 0000-0003-4450-1184, SPIN-код: 5738-0770;

Е. А. Ахременко – аспирант, научный сотрудник Центра искусственного интеллекта Пермского государственного национального исследовательского университета (614068, г. Пермь, ул. Букирева, д.15), eLibrary Author ID: 1072291, Scopus AuthorID: 57217008504, ORCID: 0000-0003-0757-064X, SPIN-код: 8315-9400;

А. И. Андреев – заведующий Лабораторией экспериментальной фармакологии Химического факультета Пермского государственного национального исследовательского университета (614068, г. Пермь, ул. Букирева, д.15), eLibrary Author ID: 718454, Scopus AuthorID: 55973997200, ORCID: 0000-0002-3718-4830, SPIN-код: 2892-7750;

М. А. Барулина – доктор физико-математических наук, доцент; директор Физико-математического института Пермского государственного национального исследовательского университета (614068, г. Пермь, ул. Букирева, д.15), eLibrary Author ID: 174006, Scopus AuthorID: 51161080800, ORCID: 0000-0003-3867-648X, SPIN-код: 1987-9965.

Information about the authors:

I. I. Kovalenko – Postgraduate Student, Head of the Laboratory of the Artificial Intelligence Center, Institute of Physics and Mathematics, Perm State University (15 Bukireva St., Perm, 614068, Russia), eLibrary Author ID: 1161522, Scopus AuthorID: 57878997400, ORCID: 0000-0003-4450-1184, SPIN-code: 5738-0770;

E. A. Ahremenko – Postgraduate Student, Researcher at the Artificial Intelligence Center, Perm State University (15 Bukireva St., Perm, 614068, Russia), eLibrary Author

ID: 1072291, Scopus AuthorID: 57217008504, ORCID: 0000-0003-0757-064X, SPIN-code: 8315-9400;

A. I. Andreev – Head of the Laboratory of Experimental Pharmacology, Faculty of Chemistry, Perm State University (15 Bukireva St., Perm, 614068, Russia), eLibrary Author ID: 718454, Scopus AuthorID: 55973997200, ORCID: 0000-0002-3718-4830, SPIN-code: 2892-7750;

M. A. Barulina – Doctor of Physical and Mathematical Sciences, Associate Professor; Director of the Institute of Physics and Mathematics, Perm State University (15 Bukireva St., Perm, 614068, Russia), eLibrary Author ID: 174006, Scopus AuthorID: 51161080800, ORCID: 0000-0003-3867-648X, SPIN-code: 1987-9965.