УДК 004.94

ГИБРИДНЫЕ ЦИФРОВЫЕ МОДЕЛИ С ПРИМЕНЕНИЕМ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

© 2026 С.М. Бекетов, Л.М. Хабибуллина, К.Н. Поспелов, А.Д. Нигматулин, Г.В. Васильев, А.М. Гинцяк

Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург, Россия

Статья поступила в редакцию 17.11.2025

Статья посвящена всестороннему анализу современного состояния и тенденций развития гибридного моделирования, основанного на интеграции механистических, логико-символьных и интеллектуальных методов. В работе обосновывается необходимость объединения физико-математических моделей с алгоритмами искусственного интеллекта для повышения интерпретируемости, адаптивности и точности прогнозирования сложных социально-экономических, социотехнических и организационных систем. На основе систематического обзора литературы и анализа публикационной активности выявлены ключевые направления эволюции гибридных подходов, включая физически информированные нейронные сети, суррогатное моделирование, цифровые двойники и обучение с подкреплением. Предложена многоуровневая классификация методов по уровню интеграции, направлению взаимодействия и типу технологий искусственного интеллекта, отражающая концептуальные принципы построения современных гибридных вычислительных архитектур. Установлено, что гибридные модели обеспечивают синергетическое сочетание интерпретируемости и теоретической обоснованности механистических описаний с гибкостью и вычислительной эффективностью методов машинного обучения. Показано, что дальнейшее развитие области связано с переходом к глубоким симбиотическим структурам «моделирование – искусственный интеллект», повышением значимости объяснимого искусственного интеллекта, развитием адаптивных цифровых двойников и расширением сфер применения гибридных методов. Полученные результаты формируют методологическую основу для создания интеллектуальных систем нового поколения, способных к самообучению, когнитивной эволюции и устойчивому функционированию в условиях высокой неопределённости.

Ключевые слова: гибридное моделирование, искусственный интеллект, машинное обучение, цифровое моделирование, имитационное моделирование, суррогатное моделирование, оптимизация моделей, моделирование сложных систем.

DOI: 10.37313/1990-5378-2026-28-2(2)-369-380
EDN: BWAAIC

Исследование выполнено при поддержке Министерства науки и высшего образования Российской Федерации в рамках программы стратегического академического лидерства «Приоритет 2030» (соглашение № 075-15-2025-210 от 04 апреля 2025)

ВВЕДЕНИЕ

Современные тенденции цифровизации, развитие вычислительных архитектур и повышение доступности высокопроизводительных вычислений способствуют активному внедрению интеллектуальных методов в инженерные и научные исследования [1-3]. Постепенное расширение классов задач, решаемых с помощью искусственного интеллекта, а также растущие требования к точности и интерпретируемости вычислительных моделей приводят к формированию новой парадигмы описания и анализа сложных систем. Одним из наиболее перспективных направлений, отражающих эту трансформацию, является гибридное моделирование, ориентированное на интеграцию разнородных подходов к представлению знаний о функционировании исследуемых объектов [4].

Бекетов Сальбек Мустафаевич, лаборант-исследователь лаборатории «Цифровое моделирование индустриальных систем», ассистент Высшей школы проектной деятельности и ин-новаций в промышленности. E-mail: salbek.beketov@spbpu.com

Хабибуллина Лия Марсовна, лаборант-исследователь лаборатории «Цифровое моделирование индустриальных систем. E-mail: liya.khabibullina@spbpu.com

Поспелов Капитон Николаевич, младший научный сотрудник лаборатории «Цифровое моделирование индустриальных систем». E-mail: kapiton.pospelov@spbpu.com

Нигматулин Артем Денисович, лаборант-исследователь лаборатории «Цифровое моделирование индустриальных систем». E-mail: artem.nigmatulin@spbpu.com

Васильев Глеб Владиславович, лаборант-исследователь лаборатории «Цифровое моделирование индустриальных систем». E-mail: gleb.vasiliev@spbpu.com

Гинцяк Алексей Михайлович, кандидат технических наук, заведующий лабораторией «Цифровое моделирование индустриальных систем». E-mail: aleksei.gintciak@spbpu.com

В рамках данной парадигмы особое внимание уделяется объединению механистических и логико-символьных моделей с методами анализа данных и алгоритмами искусственного интеллекта [5, 6]. Под механистическими моделями в строгом смысле понимаются математические конструкции, основанные на фундаментальных физических закономерностях, уравнениях движения, балансах энергии и массы, а также других универсальных принципах, описывающих эволюцию состояния системы. Логико-символьные модели, в свою очередь, охватывают широкий класс формальных представлений, включая дискретно-событийные, агентные, системно-динамические и логико-ориентированные моделирование. Их применение важно при моделировании организационных, социально-экономических, социотехнических и производственных систем, где процессы описываются не только непрерывными физическими зависимостями, но и множеством дискретных, стохастических, поведенческих и структурно-логических факторов. Гибридизация подразумевает не только слияние физико-математического описания с методами машинного и глубокого обучения, но и комплексное объединение формализованных символьных моделей с методами статистического и интеллектуального анализа данных [7, 8].

Гибридное моделирование социально-экономических систем в современном понимании представляет собой интеграцию моделей различной природы в единую вычислительную архитектуру, в которой механистическое и логико-символьное описание служит фундаментом, обеспечивающим интерпретируемость, устойчивость и возможность экстраполяции [9, 10], а интеллектуальные методы – адаптивность, способность к обобщению, работу с неполными или зашумлёнными данными и повышение точности прогнозов. Сочетание детерминированных и вероятностных компонентов, формализованных правил и обучаемых параметров позволяет создавать многоуровневые модели, способные отражать как фундаментальные свойства изучаемых процессов, так и эмпирически выявляемые закономерности, которые невозможно представить в аналитической форме [11].

На необходимость развития гибридных подходов указывают ограничения каждого из направлений при их раздельном применении. Механистические и логико-символьные модели нередко сталкиваются с проблемой неполноты описания, вызванной сложностью реальных систем и невозможностью точного учёта всех факторов, влияющих на их динамику [12]. Кроме того, построение высокоточных моделей такого типа может быть связано со значительными вычислительными затратами, особенно при переходе к большим масштабам или многомерным задачам. С другой стороны, модели, основанные исключительно на данных, требуют больших объёмов качественной обучающей информации, чувствительны к распределению данных и зачастую демонстрируют снижение качества при попытке экстраполировать результаты за пределы наблюдаемых условий [13]. Интеграция этих подходов позволяет компенсировать их индивидуальные недостатки: использование механистических и логико-символьных структур снижает потребность в больших обучающих выборках, направляет обучение модели в физически или логически обоснованные области, а интеллектуальные алгоритмы обеспечивают дополнительную гибкость, адаптацию к неопределённости и уточнение параметров, недоступных традиционным методам.

Особую актуальность гибридное моделирование приобретает также в контексте развития технологии цифровых двойников, интеллектуальных систем управления и прогнозирования поведения сложных социотехнических и социально-экономических систем. Начиная с середины 2010-х годов наблюдается устойчивый рост числа научных публикаций, отражающих интеграцию методов искусственного интеллекта и физического моделирования. Анализ публикационной активности (рис. 1) подтверждает значительное увеличение количества исследований в данной области, что указывает на формирование нового этапа развития научного прогнозирования и инженерного анализа.

Рис. 1. Количество публикаций по тематике гибридного моделирования, размещенных в научной электронной библиотеке eLIBRARY

В ходе систематического поиска и анализа литературы было выявлено более 115 тысяч публикаций по теме гибридного моделирования за весь период наблюдения, при этом только за неполный 2025 год в изданиях, входящих в перечень ВАК, было зафиксировано более 13 тысяч публикаций. Такая тенденция свидетельствует о высокой интенсивности исследований и росте интереса научного сообщества к вопросам интеграции искусственного интеллекта и традиционных методов моделирования.

Таким образом, целью данной работы является проведение всестороннего обзора методов гибридного моделирования с использованием технологий искусственного интеллекта, систематизация знаний, а также выявление основных направлений их применения в различных отраслях науки и экономики. На основе анализа публикационной активности и обобщения научных результатов формируется представление о текущем состоянии и тенденциях развития данного междисциплинарного направления.

МЕТОДЫ ИССЛЕДОВАНИЯ

Для подготовки данного обзора были проанализированы статьи в области гибридного моделирования. Были отобраны обзоры и оригинальные исследования, посвящённые моделированию с использованием искусственного интеллекта и физических моделей. Учитывались публикации, содержащие как архитектурные описания, так и эмпирические результаты. Несмотря на ограниченный доступ к полным метаданным Scopus, были использованы открытые версии статей и метаданные, статьи из журналов, входящих в базу данных RSCI, а также из перечня ВАК. По мере проведения анализа онтологическая модель поиска последовательно уточнялась и расширялась, что позволило включить в неё исследования, описывающие отдельные технологии и концепции, потенциально формирующие основу гибридного моделирования. Итоговая онтологическая модель, использованная для проведения литературного обзора, представлена на рис. 2.

Рис. 2. Онтологическая модель литературного обзора

Таким образом, был составлен перечень ключевых слов, по интеграциям которых производился поиск как в русскоязычных, так и в англоязычных изданиях: гибридное моделирование, искусственный интеллект, машинное обучение, имитационное моделирование, физически информированные нейронные сети, цифровые двойники, суррогатное моделирование, обучение с подкреплением, объяснимый искусственный интеллект, механистические модели, интеграция моделей, оптимизация моделей, интерпретируемость модели, адаптивные системы, глубокое обучение, аппроксимация моделей, валидация и верификация, многодисциплинарное моделирование, управление сложными системами.

Для проведения дальнейшего систематического обзора литературы был реализован многоэтапный процесс идентификации и отбора источников (рис. 3).

На первом этапе осуществлялся широкий поиск публикаций в открытых научных базах данных. На втором этапе проводился отбор по формальным признакам, включая тип публикации (научная статья, монография, отчёт), наличие аннотации и год публикации. На третьем этапе проводилась

Рис. 3. Процесс идентификации и отбора источников

оценка релевантности и современности источников, в рамках которой анализировалось соответствие тематике исследования, а также актуальность результатов с учётом периода их публикации. На заключительном этапе были проведены качественный анализ и обобщение данных по публикациям, наиболее полно отражающим предметную область исследования.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЯ

Как отмечалось ранее, начиная с середины 2010-х годов наблюдается выраженный рост числа публикаций, что отражает усиление интереса к интеграции искусственного интеллекта и физических моделей, особенно в контексте цифровых двойников и интеллектуальных систем управления. В результате качественного анализа и обобщения отобранных публикаций было проведено систематизирование знаний о применении гибридных моделей в различных секторах экономики. На рис. 4 представлена диаграмма распределения исследований, отражающая отраслевую структуру применения гибридных моделей.

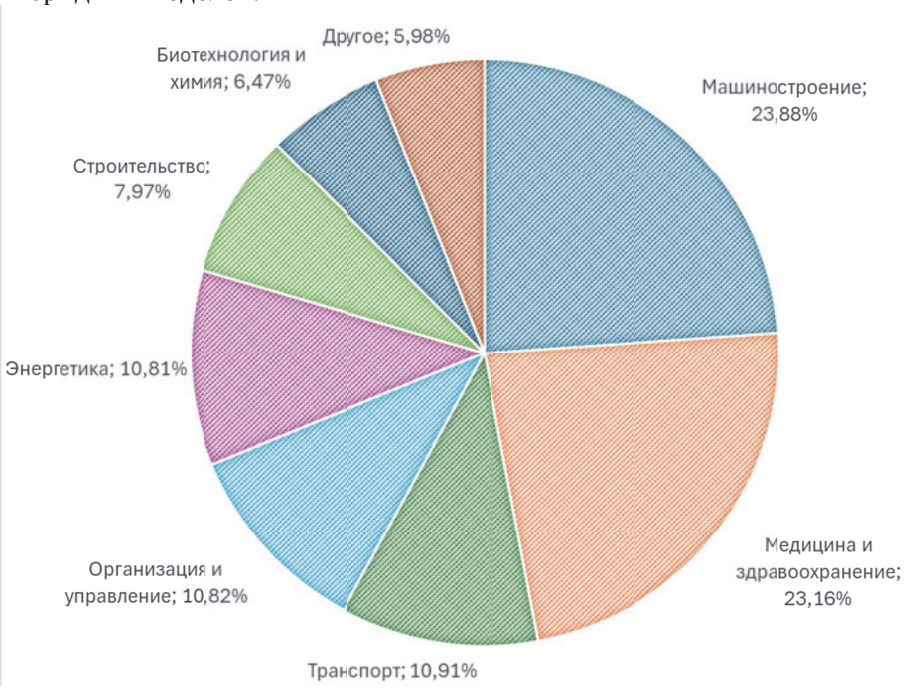

Рис. 4. Диаграмма распределения исследований, отражающая отраслевую структуру применения гибридных моделей

Анализ распределения публикаций по отраслям экономики показывает, что наибольший интерес к применению гибридных моделей наблюдается в высокотехнологичных и наукоёмких сферах, таких как машиностроение и медицина [14-16]. В этих областях активно внедряются интеллектуальные системы, способствующие развитию интеграции искусственного интеллекта и физических моделей.

Значительное внимание уделяется также применению гибридных подходов в транспорте [17], энергетике [18], управлении и организации производственных процессов [19], где эти модели используются для оптимизации систем и повышения их эффективности.

Относительно меньшая, но стабильная исследовательская активность наблюдается в сфере строительства [20], биотехнологий и химии [21], что свидетельствует о расширении спектра применения гибридных моделей за пределами традиционно цифровых отраслей. В целом результаты демонстрируют междисциплинарный характер подхода и его растущее значение в современной экономике.

Современные представления о роли искусственного интеллекта в имитационном моделировании отражает эволюцию методов анализа сложных систем и преодоление ограничений традиционных подходов, основанных на статичных предположениях и ретроспективных данных. Классические имитационные модели, традиционно применяемые для анализа сценариев типа «что, если», требуют значительных усилий на этапах калибровки, валидации и интерпретации результатов, особенно при исследовании многофакторных и стохастических систем [22]. В свою очередь, технологии искусственного интеллекта, включая машинное обучение и методы глубокого обучения, обеспечивают возможность автоматизированного выявления закономерностей и прогнозирования поведения систем без непосредственного участия человека, достигая высокой точности и адаптивности [23, 24].

Ключевая идея интеграции искусственного интеллекта и имитационного моделирования заключается в формировании синергетического взаимодействия, при котором компенсируются слабые стороны каждой из методологических парадигм. Имитационные модели предоставляют искусственному интеллекту контролируемую и репрезентативную виртуальную среду, способную генерировать синтетические данные в масштабах, недостижимых в реальных условиях [25]. Искусственный интеллект, в свою очередь, выступает инструментом интеллектуальной автоматизации анализа, параметрической оптимизации и представления сложного адаптивного поведения в рамках имитационных систем [23, 26, 27].

Однако интеграция искусственного интеллекта в имитационные структуры сопряжена с новыми вызовами, связанными с прозрачностью и интерпретируемостью создаваемых моделей. Высокая сложность современных нейросетевых архитектур, функционирующих как «чёрные ящики», затрудняет анализ причинно-следственных связей между входными и выходными параметрами и снижает доверие к результатам моделирования. В связи с этим возрастает значение концепции объяснимого искусственного интеллекта (Explainable Artificial Intelligence, XAI), направленной на обеспечение интерпретируемости, надёжности и подотчётности гибридных систем [28–30]. Развитие методов XAI, адаптированных к интегрированным моделям, рассматривается как одно из ключевых направлений исследований, позволяющее не только верифицировать поведение компонентов искусственного интеллекта, но и получать новые знания о моделируемых процессах.

Для систематизации различных подходов к интеграции искусственного интеллекта и имитационного моделирования целесообразно использовать многоуровневую классификацию [23], позволяющую структурировать методы по трём ортогональным признакам: уровню интеграции, направлению взаимодействия и типу применяемых технологий искусственного интеллекта.

Классификация по уровню интеграции отражает глубину и характер взаимосвязи между компонентами искусственного интеллекта и имитационного моделирования. На аналитическом уровне искусственный интеллект применяется преимущественно для постобработки данных, полученных в ходе имитационных экспериментов. Здесь искусственный интеллект выступает как инструмент интеллектуального анализа больших массивов выходных данных (временных рядов, траекторий состояний, статистических распределений), что позволяет выявлять скрытые закономерности и проводить анализ чувствительности модели [22, 31, 32].

На уровне оптимизации взаимодействие становится итеративным: алгоритмы искусственного интеллекта управляют процессом моделирования, выбирая наборы параметров для последующих симуляций с целью поиска оптимальных решений. В данном случае симулятор функционирует как функция оценки, а искусственный интеллект – как оптимизатор, реализующий метаэвристические методы (генетические алгоритмы, эволюционные стратегии, байесовскую оптимизацию и др.), что позволяет эффективно исследовать сложные многомерные пространства параметров [27, 33, 34].

На гибридном уровне достигается наиболее глубокая интеграция: компоненты искусственного интеллекта и имитационного моделирования функционируют как взаимозависимые элементы единой системы, взаимодействуя в режиме реального времени. В таких моделях агенты на основе искусственного интеллекта могут быть встроены непосредственно в логику имитационной модели, формируя динамическую адаптивную систему, способную к самообучению и адаптации. Данный уровень интеграции лежит в основе концепции цифровых двойников [26, 35], обеспечивающих постоянную взаимосвязь между физическим объектом и его виртуальной копией.

Классификация по направлению взаимодействия дифференцирует подходы в зависимости от того, какая из парадигм – имитационное моделирование или искусственный интеллект – играет ведущую роль. В рамках машинного обучения с использованием имитационного моделирования (Simulation-Assisted Machine Learning) имитационные модели используются как источник синте-

тических данных для обучения систем на основе искусственного интеллекта, что важно при ограниченной доступности или высокой стоимости реальных данных [25, 27, 36]. В противоположность этому в подходе машинно-обучаемых симуляций (Machine Learning-Assisted Simulation) ИИ применяется для ускорения, аппроксимации и анализа имитационных моделей. Основным инструментом здесь выступают суррогатные модели, позволяющие заменять ресурсоёмкие симуляции простыми аппроксимациями на основе данных, что значительно ускоряет процессы оптимизации и анализа неопределённостей [26, 37-40].

Классификация по типу технологий искусственного интеллекта охватывает два основных направления: обучение с учителем и обучение с подкреплением. Методы обучения с учителем (включая полиномиальную регрессию, метод опорных векторов и гауссовские процессы) применяются в основном для построения суррогатных моделей и анализа чувствительности [41, 42]. Глубокие нейронные сети (DNN), в том числе физически обоснованные архитектуры (PINN) и свёрточные сети (CNN), обеспечивают высокую точность аппроксимации нелинейных зависимостей и позволяют интегрировать физические законы непосредственно в структуру модели [43, 44]. Методы обучения с подкреплением, включая классические алгоритмы Q-обучения, глубокое обучение с подкреплением (deep learning with reinforcement, DRL) и мультиагентные системы (multiagent systems, MARL), ориентированы на поиск оптимальных стратегий управления в динамических средах и играют ключевую роль в задачах адаптивного управления и автономных системах [45-47].

Интеграция методов искусственного интеллекта и имитационного моделирования формирует новую исследовательскую парадигму, в рамках которой моделирование становится не только инструментом анализа, но и активным участником процесса обучения и принятия решений. Предложенная классификация позволяет рассматривать данное направление не как набор изолированных подходов, а как единую многоуровневую систему взаимодополняющих методологий, различающихся степенью взаимосвязи, направлением интеграции и технологическим базисом. Системный подход обеспечивает основу для разработки адаптивных, интерпретируемых и устойчивых гибридных моделей, способных к самокоррекции и когнитивной эволюции в сложных динамических средах.

Классификация представлена на рис. 5.

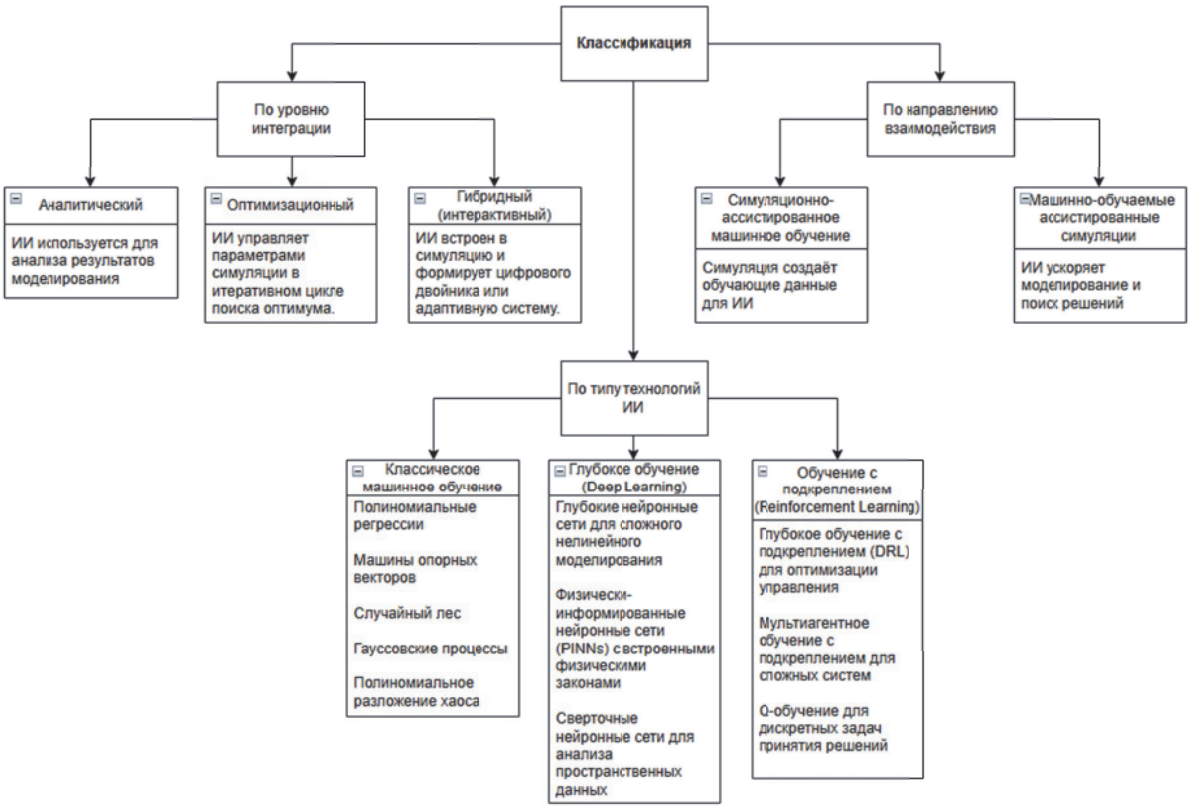

Рис. 5. Классификация методов гибридного моделирования

Проведённая классификация методов интеграции искусственного интеллекта и имитационного моделирования позволяет систематизировать существующие подходы по трём ключевым параметрам: уровню интеграции, направлению взаимодействия и типу используемых технологий искусственного интеллекта. Такая структура даёт целостное представление о спектре существующих решений – от аналитических и оптимизационных до гибридных систем, а также о том, как искус-

ственный интеллект может либо опираться на симуляцию, либо активно её усиливать. В совокупности эти аспекты формируют базовую онтологию взаимодействия искусственного интеллекта и имитационного моделирования, отражающую не только технические различия, но и концептуальную глубину интеграции.

Предложенная классификация может претендовать на универсальность для дальнейших исследований, поскольку охватывает основные направления эволюции гибридных систем. Она позволяет сопоставлять различные подходы, выявлять их сильные и слабые стороны, а также определять перспективные области развития – например, переход от последовательных архитектур к симбиотическим, в которых искусственный интеллект и физическое моделирование действуют как единая когнитивная система.

Вместе с тем классификация не претендует на исчерпывающий характер. Гипотетически её можно дополнить другими основаниями, например типом данных (реальные, синтетические, мультимодальные), характером управления (централизованное или распределённое), степенью автономности компонента искусственного интеллекта или уровнем доверия и объяснимости (интерпретируемые и неинтерпретируемые модели). Такие дополнения могут быть полезны при разработке специализированных гибридных систем в конкретных предметных областях.

В таблицах 1-3 представлена информация по области применения, преимуществам и ограничениям конкретных типов методов в рассматриваемой классификации.

Таблица 1. Сравнительный анализ методов по уровню интеграции

Класс методов	Область применения	Преимущества	Ограничения
Аналитический	Постобработка результатов моделирования; анализ чувствительности; выявление закономерностей в больших массивах данных	– Выявление скрытых зависимостей; – Повышение информативности моделирования; – Упрощение анализа сложных процессов	– Не влияет на ход моделирования; – Зависит от полноты данных моделирования; – Ограниченная адаптивность
Оптимизационный	Подбор параметров и сценариев в инженерных моделях; калибровка систем; управление процессами	– Автоматизация оптимизации; – Эффективное исследование многомерных пространств; – Сокращение трудозатрат на поиск решений	– Большие вычислительные затраты; – Возможность переобучения; – Требует баланса между скоростью и точностью
Гибридный	Цифровые двойники, адаптивные системы управления, автономные агенты, работа в режиме реального времени	– Глубокая интеграция искусственного интеллекта и симуляции; – Самообучение и адаптация; – Повышенная реалистичность и устойчивость	– Высокие требования к вычислительным ресурсам; – Проблемы интерпретируемости («чёрный ящик»); – Необходимость XAI-подходов

Представленная классификация показывает, что различные классы методов, применяемых при моделировании сложных систем, обладают взаимодополняющими свойствами и ориентированы на решение задач разной природы. Аналитические методы повышают интерпретируемость результатов и позволяют выявлять скрытые закономерности, однако их роль ограничивается постобработкой данных

Таблица 2. Сравнительный анализ методов по направлению взаимодействия

Класс методов	Область применения	Преимущества	Ограничения
Машинное обучение с использованием симуляции (обучение ИИ с помощью симуляции)	Генерация синтетических данных для обучения моделей; сценарное прогнозирование; редкие или дорогостоящие эксперименты	– Возможность обучения при недостатке реальных данных; – Контролируемая и безопасная среда для обучения; – Масштабируемость экспериментов	– Риск смещения из-за разницы между симуляцией и реальностью; – Требуется валидация симулятора; – Ограниченная переносимость на реальные данные
Моделирование с использованием машинного обучения (ускорение моделирования с помощью ИИ)	Суррогатное моделирование, ускорение вычислений, аппроксимация сложных физических моделей.	– Существенное сокращение времени вычислений; – Возможность многократного запуска симуляции; – Упрощённый анализ неопределённостей	– Потеря точности при аппроксимации; – Зависимость от обучающей выборки; – Сложности с интерпретируемостью

и зависит от качества исходного моделирования. Оптимизационные подходы обеспечивают автоматизацию поиска решений и эффективное исследование параметрических пространств, но сопряжены с высокими вычислительными затратами и риском переобучения. Гибридные методы представляют собой наиболее технологически продвинутое направление, обеспечивающее интеграцию моделирования и искусственного интеллекта с возможностью адаптации и работы в режиме реального времени, хотя их применение требует значительных вычислительных ресурсов и использования методов объяснимого ИИ для повышения прозрачности моделей. Таким образом, выбор класса методов определяется балансом между интерпретируемостью, адаптивностью и вычислительной сложностью, что подчёркивает необходимость их комплексного использования в современных исследованиях.

Сравнение двух направлений интеграции симуляции и методов машинного обучения показывает, что каждое из них ориентировано на решение конкретных задач и имеет свои преимущества и ограничения. Подход, основанный на обучении моделей ИИ с использованием симуляции, позволяет генерировать синтетические данные в условиях дефицита реальных наблюдений, создаёт контролируемую и безопасную среду для экспериментов и масштабирует обучающие сценарии, однако его эффективность ограничивается рисками смещения, возникающими при расхождении между виртуальной и реальной средами, а также необходимостью строгой проверки используемого симулятора. В отличие от этого, применение машинного обучения для ускорения моделирования направлено на создание суррогатных моделей и снижение вычислительных затрат при аппроксимации сложных физических процессов. Это значительно повышает эффективность вычислительных экспериментов, но в то же время приводит к потенциальным потерям точности, зависимости от качества обучающей выборки и снижению интерпретируемости результатов. В совокупности это подчёркивает, что оба направления являются взаимодополняющими элементами современной гибридной методологии, выбор которых определяется балансом между точностью, скоростью, надёжностью и доступностью данных.

Интеграция методов искусственного интеллекта и имитационного моделирования охватывает широкий спектр задач – от анализа данных и оптимизации параметров до создания цифровых двойников и автономных систем. На аналитическом уровне искусственный интеллект используется для постобработки результатов моделирования и выявления закономерностей в больших данных. Данные методы повышают информативность и позволяют анализировать сложные процессы, однако они не влияют на ход моделирования и зависят от качества исходных данных.

Оптимизационные подходы применяются для автоматизации подбора параметров, калибровки и поиска наилучших решений в инженерных и управленческих системах. Они обеспечивают высокую эффективность и сокращают трудозатраты, но требуют значительных вычислительных ресурсов и баланса между точностью и скоростью.

Таблица 3. Сравнительный анализ методов по типу технологий ИИ

Класс методов	Области применения	Преимущества	Ограничения
Классические методы обучения с учителем	Построение суррогатных моделей для гладких зависимостей; анализ чувствительности; построение интерпретируемых эмпирических аппроксимаций	– Хорошая интерпретируемость (особенно регрессии, SVM в простых вариантах); – Эффективность при невысокой размерности и умеренных объёмах данных; – GP дают вероятностную оценку неопределённости (важно для байесовских методов и планирования экспериментов).	– Ограниченная способность моделировать очень сложные и высокоразмерные нелинейности; – Могут требовать вручную подобранных признаков; – Масштабируемость GP ограничена для больших наборов данных.
Глубокие нейронные сети (обучение с учителем)	Точные суррогатные модели для высокоразмерных симуляций; аппроксимация полей (CNN для пространственных данных); интеграция физических законов в обучение (PINN)	– Высокая аппроксимирующая способность для сложных нелинейных взаимосвязей; – PINN позволяют встроить уравнения и ограничения физики прямо в функцию потерь, повышая обобщающую способность при малом числе данных; – CNN эффективно работают с пространственно структурированными полями симуляций.	– Требуют больших объёмов данных и вычислительных ресурсов; – Часто низкая интерпретируемость («чёрный ящик»); – Необходимость аккуратной регуляризации и валидации, риск переобучения.
Методы обучения с подкреплением	Обучение оптимальных политик управления в динамических средах; адаптивное/онлайн управление; автономные агенты и сценарии с принятием последовательных решений	– Позволяют обучать стратегии поведения в средах с неизвестной или стохастической динамикой; – DRL масштабируется до больших пространств состояний/действий благодаря нейросетям; – MARL моделирует взаимодействие нескольких агентов в сложных системах	– Обучение может быть нестабильным и ресурсоёмким; – Неоднозначность в интерпретации выученных политик; – Требуется тщательная настройка вознаграждений, риск нежелательных побочных эффектов при переносе в реальную среду

Гибридные модели находят применение в цифровых двойниках, адаптивных и автономных системах. Их преимущества – самообучение, адаптивность и высокая реалистичность. Основные ограничения – высокая вычислительная сложность и низкая интерпретируемость, что требует применения XAI-подходов.

По направлению взаимодействия методы, основанные на симуляции, эффективны при нехватке реальных данных (например, в медицине и авиации), а симуляции с машинным обучением – при необходимости ускорить расчёты (в инженерии и климатическом моделировании).

По типу технологий искусственного интеллекта классические методы обучения с учителем подходят для интерпретируемых аппроксимаций и анализа чувствительности, глубокие нейронные сети – для сложных нелинейных зависимостей и физически обоснованных моделей, а обучение с подкреплением – для адаптивного управления и автономных агентов. Каждое направление имеет собственный баланс между точностью, вычислительной сложностью и объяснимостью, что определяет выбор подхода в зависимости от задач моделирования.

ВЫВОДЫ И ЗАКЛЮЧЕНИЯ

Проведённый обзор позволил обобщить и систематизировать современные подходы к гибридному моделированию, основанному на интеграции физических и интеллектуальных методов. Данный подход является ключевым направлением развития современной методов анализа и прогнозирования сложных систем, объединяя достоинства физико-механических моделей (интерпретируемость, теоретическую обоснованность и способность к экстраполяции) с преимуществами методов искусственного интеллекта, обеспечивающими адаптивность, высокую точность и автоматизацию аналитических процессов.

Результаты анализа публикационной активности и содержательного наполнения научных работ свидетельствуют о стремительном росте интереса к гибридному моделированию в различных областях науки и техники, особенно начиная с середины 2010-х годов. Формируется устойчивая тенденция к интеграции искусственного интеллекта в традиционные модели и системы, что проявляется в активном внедрении технологий машинного обучения, глубокого обучения, обучения с подкреплением и объяснимого искусственного интеллекта в архитектуры

Проведённая классификация показывает, что современное гибридное моделирование эволюционирует от изолированных инструментов анализа и прогнозирования к интеллектуальным экосистемам, в которых симуляция и обучение взаимно усиливают друг друга. Такая интеграция обеспечивает не только повышение точности и устойчивости моделей, но и переход к новым формам адаптивных цифровых двойников, способных к постоянному самообновлению и когнитивной эволюции.

Таким образом, текущее состояние области гибридного моделирования характеризуется высокой степенью междисциплинарности, методологическим разнообразием и активным развитием инструментов интеграции искусственного интеллекта в физические и имитационные модели. Основные тенденции развития включают: переход от постобработки и оптимизационных сценариев к глубокой симбиотической интеграции искусственного интеллекта и моделирования; усиление роли XAI и физически обоснованных нейронных сетей (PINN) как средств обеспечения объяснимости и достоверности моделей; рост значимости мультиагентных и обучающихся систем в задачах адаптивного управления и автономного принятия решений; расширение сферы применения гибридных подходов за пределами инженерных дисциплин – в социально-экономическом моделировании, экологии и управлении рисками.

Гибридное моделирование формирует новую исследовательскую и инженерную парадигму, в которой искусственный интеллект становится не только инструментом анализа, но и активным участником моделирования, обеспечивающим интеллектуализацию, адаптивность и саморефлексию сложных систем.

СПИСОК ИСТОЧНИКОВ

1. *Ashyralyeva, M. A. Methodological approaches to the application of artificial intelligence in modern science and technology / M.A. Ashyralyeva, A.N. Charyeva // Science and Worldview. 2025. Vol. 1. No. 58. P. 71-77.Luckyardi S. et al.* Emerging trends in technology: Insights across machine learning, digitalization, and industry applications // Journal of Engineering Science and Technology. 2025. Т. 20. №. 2. Pp. 458-475.
2. *Malikov V. N. et al.* Features of the implementation of artificial intelligence and digital technologies in industrial production: promising directions and modern trends in automation //Journal of Physics: Conference Series. IOP Publishing, 2021. Т. 1889. №. 2. P. 022012.
3. *Chen M. et al.* Iterative integration of deep learning in hybrid Earth surface system modelling //Nature Reviews Earth & Environment. 2023. Т. 4. №. 8. Pp. 568-581.
4. *Mystridis G. A. et al.* Artificial intelligence/machine learning and mechanistic modeling approaches as translational tools to advance personalized medicine decisions //Advances in Molecular Pathology. – 2022. Т. 5. №. 1. Pp. 131-139.
5. *Zhao H., Alshehri S.* Development of advanced hybrid mechanistic-artificial intelligence computational model for learning of numerical data of flow in porous membranes //Engineering Applications of Artificial Intelligence. 2023. Т. 126. P. 106910.

6. *Muñoz-Carpena R. et al.* Convergence of mechanistic modeling and artificial intelligence in hydrologic science and engineering //PLoS Water. 2023. Т. 2. №. 8. P. e0000059.
7. *Procopio A. et al.* Combined mechanistic modeling and machine-learning approaches in systems biology-A systematic literature review //Comput. Methods Programs Biomed. 2023. Т. 240. P. 107681.
8. *Gintciak, A., Bolsunovskaya, M., Burlutskaya, Z., Petryaeva, A.* Hybrid Simulation as a Key Tool for Socio-economic Systems Modeling // Lecture Notes in Networks and Systems. 2022. № 442 LNNS. Pp. 262-272. DOI: 10.1007/978-3-030-98832-6_23.
9. *Bolsunovskaya M., Gintsyak A., Burlutskaya Zh., Petryaeva A., Zubkova D., Uspensky M., Seledtsova I.* Possibilities of applying a hybrid approach in modeling socio-economic and socio-technical systems // Bulletin of Voronezh State University. Series: Systems Analysis and Information Technology. 2022. No. 3. pp. 73–86. DOI: 10.17308/sait/1995-5499/2022/3/73-86.
10. Digital modeling of socio-technical and socio-economic systems: monograph / A.M. Gintsyak, Zh.V. Burlutskaya, D.E. Fedyaevskaya [et al.] St. Petersburg: POLYTECH-PRESS, 2023. 164 p.
11. *Yao L. et al.* Exploring large language models for knowledge graph completion //ICASSP 2025-2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2025. Pp. 1-5.
12. *Shchelokova Yu. K.* Using big data to analyze and optimize the educational process in higher education institutions // Education Management: Theory and Practice. 2024. Vol. 14. No. 2-1. Pp. 114-122.
13. *Bellini V. et al.* Evolution of hybrid intelligence and its application in evidence-based medicine: a review //Medical Science Monitor: International Medical Journal of Experimental and Clinical Research. 2023. Т. 29. С. e939366-1.
14. *Saravi B. et al.* Artificial intelligence-driven prediction modeling and decision making in spine surgery using hybrid machine learning models //Journal of Personalized Medicine. 2022. Т. 12. №. 4. P. 509.
15. *Kurz S. et al.* Hybrid modeling: towards the next level of scientific computing in engineering //Journal of Mathematics in Industry. 2022. Т. 12. №. 1. P. 8.
16. *Zhan C. et al.* A hybrid approach for low-carbon transportation system analysis: integrating CRITIC-DEMATEL and deep learning features //International Journal of Environmental Science and Technology. 2024. Т. 21. № 1. Pp. 791-804.
17. *Khan A. et al.* Comprehensive Review of Hybrid Energy Systems: Challenges, Applications, and Optimization Strategies //Energies. 2025. Т. 18. №. 10. P. 2612.
18. *Copola Azenha F., Aparecida Reis D., Leme Fleury A.* The role and characteristics of hybrid approaches to project management in the development of technology-based products and services // Project Management Journal. 2021. Т. 52. №. 1. Pp. 90-110.
19. *Moroz I. V., Shavrin A. V.* Using a hybrid approach in managing road construction projects // Bulletin of Economic and Sociological Research. 2024. No. 4. Pp. 28–34.
20. *Sharma N., Liu Y. A.* A hybrid science-guided machine learning approach for modeling chemical processes: A review //AIChE Journal. 2022. Т. 68. №. 5. Pp. e17609.
21. *Zeigler B., Muzy A., Yilmaz L.* Artificial intelligence in modeling and simulation // Computational Complexity. – Springer, New York, NY, 2012. Pp. 204-227.
22. *Sarker I. H.* AI-based modeling: techniques, applications and research issues towards automation, intelligent and smart systems //SN computer science. 2022. Т. 3. №. 2. P. 158.
23. *Karimov K. S.* Methods of artificial intelligence and their application in transport // Post-Soviet continent. 2023. No. 4 (40). Pp. 106–115.
24. *Deist T. M. et al.* Simulation-assisted machine learning //Bioinformatics. 2019. Т. 35. №. 20. Pp. 4072-4080.
25. *Feldkamp N.* Application of machine learning within hybrid systems modelling //Hybrid modeling and simulation: conceptualizations, methods and applications. Cham : Springer Nature Switzerland, 2024. Pp. 159-183.
26. *Tolk A.* Hybrid modeling integrating artificial intelligence and modeling & simulation paradigms //2024 winter simulation conference (wsc). IEEE, 2024. Pp. 1271-1280.
27. *Gunning D.* Explainable artificial intelligence (xai) //Defense advanced research projects agency (DARPA), nd Web. 2017. Т. 2. №. 2. P. 1.
28. *Saranya A., Subhashini R.* A systematic review of Explainable Artificial Intelligence models and applications: Recent developments and future trends //Decision analytics journal. 2023. Т. 7. P. 100230.
29. *Arrieta A. B. et al.* Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI //Information fusion. 2020. Т. 58. Pp. 82-115.
30. *Banks J.* Discrete event system simulation. Pearson Education India, 2005.
31. *Razavi S. et al.* The future of sensitivity analysis: an essential discipline for systems modeling and policy support //Environmental Modelling & Software. 2021. Т. 137. P. 104954.
32. *David N.* Artificial Intelligence in Modeling and Simulation. – MDPI-Multidisciplinary Digital Publishing Institute, 2024. P. 278.
33. *Amaran S. et al.* Simulation optimization: a review of algorithms and applications //Annals of Operations Research. 2016. Т. 240. №. 1. Pp. 351-380.
34. *Grieves M., Vickers J.* Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems // Transdisciplinary perspectives on complex systems: New findings and approaches. – Cham : Springer International Publishing, 2016. Pp. 85-113.
35. *Nikolenko S. I.* Synthetic simulated environments //Synthetic Data for Deep Learning. Cham : Springer International Publishing, 2021. Pp. 195-215.
36. *von Rueden L. et al.* Combining machine learning and simulation to a hybrid modelling approach: Current and future directions //International symposium on intelligent data analysis. Cham : Springer International Publishing, 2020. Pp. 548-560.

37. *Zhu Y. et al.* Physics-constrained deep learning for high-dimensional surrogate modeling and uncertainty quantification without labeled data //Journal of Computational Physics. 2019. T. 394. P. 56-81.
38. *Beketov S.M., Zubkova D.A., Gintsyak A.M., Burlutskaya Zh.V., Redko S.G. Modern optimization methods and features of their application* // Russian Technological Journal. 2025. № 13 (4). P. 78-94.
39. *Beketov S.M., Dergachev M.V., Gintciak A.M., Redko S.G.* Team Formation in Software Projects: Multi-criteria Paret Optimization // Programmnaya Ingeneria. 2025. № 2 (16). P. 92-99.
40. *Chen W.* The Application of Different Surrogate Models in Engineering Predictions //Applied and Computational Engineering. 2024. T. 80. P. 87-93.
41. *Li J., Wang H.* Gaussian Processes Regression for Uncertainty Quantification: An Introductory Tutorial //arXiv preprint arXiv:2502.03090. 2025.
42. *Bengio Y. et al.* Deep learning. – Cambridge, MA, USA : MIT press, 2017. T. 1. P. 23-24.
43. *Raissi M., Perdikaris P., Karniadakis G. E.* Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational physics. 2019. T. 378. C. 686-707.
44. *Kara A., Saldi N., Yüksel S.* Q-learning for MDPs with general spaces: Convergence and near optimality via quantization under weak continuity //Journal of Machine Learning Research. 2023. T. 24. №. 199. P. 1-34.
45. *Klu E. et al.* SDGym: Low-Code Reinforcement Learning Environments using System Dynamics Models //arXiv preprint arXiv:2310.12494. 2023.
46. *Ning Z., Xie L.* A survey on multi-agent reinforcement learning and its application //Journal of Automation and Intelligence. 2024. T. 3. №. 2. P. 73-91.

HYBRID DIGITAL MODELS USING TECHNOLOGY ARTIFICIAL INTELLIGENCE

© 2026 S.M. Beketov, L.M. Khabibullina, K.N. Pospelov,
A.D. Nigmatulin, G.V. Vasiliev, A.M. Gintciak

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

The article is devoted to a comprehensive analysis of the current state and development trends of hybrid modeling based on the integration of mechanistic, logical-symbolic and intelligent methods. The paper substantiates the need to combine physical and mathematical models with artificial intelligence algorithms to increase the interpretability, adaptability and accuracy of forecasting complex socio-economic, sociotechnical and organizational systems. Based on a systematic review of the literature and analysis of publication activity, key areas of evolution of hybrid approaches have been identified, including physically informed neural networks, surrogate modeling, digital doubles, and reinforcement learning. A multilevel classification of methods is proposed according to the level of integration, the direction of interaction and the type of artificial intelligence technologies, reflecting the conceptual principles of building modern hybrid computing architectures. It is established that hybrid models provide a synergetic combination of interpretability and theoretical validity of mathematical descriptions with flexibility and computational efficiency of machine learning methods. It is shown that the further development of the field is associated with the transition to deep symbiotic structures of "modeling – artificial intelligence", the increasing importance of explicable artificial intelligence, the development of adaptive digital twins and the expansion of the scope of hybrid methods. The obtained results form the methodological basis for the creation of a new generation of intellectual systems capable of self-learning, cognitive evolution and sustainable functioning in conditions of high uncertainty.
Keywords: hybrid modeling, artificial intelligence, machine learning, digital modeling, simulation modeling, surrogate modeling, model optimization, modeling of complex systems.

DOI: 10.37313/1990-5378-2026-28-2(2)-369-380
EDN: BWAAIC

Salbek Beketov, Laboratory Researcher at the Laboratory of Digital Modeling of Industrial Systems.
E-mail: salbek.beketov@spbpu.com
Liya Khabibullina, Laboratory Researcher at the Laboratory of Digital Modeling of Industrial Systems.
E-mail: liya.khabibullina@spbpu.com
Kapiton Pospelov, Junior researcher at the Laboratory of Digital Modeling of Industrial Systems.
E-mail: kapiton.pospelov@spbpu.com
Artem Nigmatulin, Laboratory Researcher at the Laboratory of Digital Modeling of Industrial Systems.
E-mail: artem.nigmatulin@spbpu.com
Gleb Vasiliev, Laboratory Researcher at the Laboratory of Digital Modeling of Industrial Systems.
E-mail: gleb.vasiliev@spbpu.com
Aleksei Gintciak, Candidate of Technics, Head of Laboratory of Digital Modeling of Industrial Systems.
E-mail: aleksei.gintciak@spbpu.com