

УДК 004.94: 004.8

ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ИМИТАЦИОННОМ МОДЕЛИРОВАНИИ**Л.М. Хабибуллина, К.Н. Пospelов (Санкт-Петербург)****Введение**

Интеграция технологий искусственного интеллекта (ИИ) с имитационным моделированием представляет собой одно из наиболее перспективных направлений развития современной вычислительной науки и инженерии [1, 2]. Синергетический эффект от сочетания аналитических возможностей ИИ с прогностическим потенциалом симуляционных систем открывает принципиально новые возможности для исследования сложных динамических процессов, оптимизации производственных систем и принятия обоснованных решений в условиях неопределенности [3, 4]. Согласно определению ГОСТ Р 59277-2020, искусственный интеллект представляет собой комплекс технологических решений, позволяющий имитировать когнитивные функции человека, включая самообучение, поиск решений без заранее заданного алгоритма и достижение инсайта, что делает его особенно ценным для совершенствования имитационных моделей сложных систем. Актуальность работы обусловлена растущей потребностью в более точных и адаптивных инструментах анализа сложных систем. Научная новизна заключается в разработке комплексной трехуровневой классификации методов интеграции ИИ и имитационного моделирования, а целью статьи является систематизация и описание этих подходов для формирования целостного представления о текущем состоянии данной области.

Материалы и методы

Методологической основой данного исследования является систематический анализ научных публикаций, посвященных интеграции искусственного интеллекта и имитационного моделирования, с последующим формированием целостного представления об этой области. В ходе работы был проведен обзор научных статей, докладов конференций для выявления ключевых тенденций и подходов в рассматриваемой области. На основе проанализированного материала была разработана многоуровневая классификация, систематизирующая существующие методы. В качестве критериев классификации были выбраны уровень интеграции, направление взаимодействия и тип применяемых технологий ИИ.

Теоретические основы интеграции искусственного интеллекта и имитационного моделирования

Текущее понимание роли искусственного интеллекта в имитационном моделировании учитывает ограничения традиционных методов, которые базируются на статичных предположениях и опираются на исторические данные. Являясь классическим инструментом для анализа сценариев «что, если», имитационные модели требуют значительных усилий по калибровке, валидации и интерпретации результатов, особенно при работе с многофакторными и стохастическими системами [5]. Искусственный интеллект, включая машинное и глубокое обучение, позволяет системам имитировать когнитивные процессы человека и выполнять задачи с высокой точностью прогнозирования без вмешательства оператора [1, 6].

Ключевая идея интеграции заключается в преодолении этих ограничений за счет синергии. Имитационное моделирование предоставляет для ИИ контролируемую виртуальную среду для обучения и тестирования, позволяя генерировать синтетические данные в объемах, недостижимых в реальных условиях [7]. В свою очередь, ИИ предоставляет для моделирования инструменты для автоматизации анализа,

оптимизации параметров, а также для представления сложного адаптивного поведения внутри самой модели [1, 4, 8].

Однако глубокая интеграция порождает и новые вызовы. Многие передовые модели ИИ, в частности глубокие нейронные сети, могут функционировать как непрозрачная модель «черного ящика» с совокупной сложностью. Это затрудняет интерпретацию полученных результатов и снижает доверие к гибридной системе в целом. Данная проблема обуславливает необходимость применения подходов объяснимого искусственного интеллекта (Explainable Artificial Intelligence, XAI) [9], направленного на повышение прозрачности, надежности и подотчетности систем ИИ [10, 11]. Разработка методов XAI, адаптированных для гибридных моделей, является одним из ключевых направлений современных исследований, поскольку позволяет не только верифицировать поведение ИИ-компонента, но и получать новые знания о моделируемой системе.

Результаты

Для систематизации многообразия методов искусственного интеллекта для задач имитационного моделирования целесообразно использовать многоуровневую классификацию [1]. Далее будет представлен обзор подходов, сгруппированных по трем ортогональным признакам: уровню интеграции, направлению взаимодействия и типу применяемых технологий ИИ.

1. Классификация по уровню интеграции

Данная классификация основана на глубине и характере взаимосвязи между компонентами ИИ и симуляции в процессе работы. Она отражает степень, в которой компоненты влияют друг на друга, от последовательного выполнения до полной симбиотической связи. Можно выделить три основных уровня (рис. 1), каждый из которых предполагает более тесную интеграцию.




Рис. 1. Классификация по уровню интеграции искусственного интеллекта в имитационном моделировании

1.1. Первый уровень – Аналитический

На аналитическом уровне интеграции технологии ИИ применяются для постобработки и анализа данных, сгенерированных в ходе выполнения имитационных экспериментов [1]. В этом случае имитационная модель и ИИ-модуль функционируют последовательно: сначала симуляция генерирует большие объемы выходных данных (траектории состояний, временные ряды, статистики), а затем алгоритмы машинного обучения используются для их анализа с целью выявления скрытых закономерностей [5, 12]. Этот уровень можно охарактеризовать как "Simulation for AI", где моделирование является источником "сырья" для интеллектуального анализа.

Основная ценность такого подхода заключается в способности ИИ обрабатывать высокоразмерные и сложные пространства выходных данных, которые трудно интерпретировать человеку. Методы МО, такие как кластеризация (например, k-means, DBSCAN, OPTICS) или деревья решений (например, MARS, C4.5, CART), способны автоматически находить неочевидные корреляции между входными параметрами модели и ее выходными характеристиками [1]. Например, можно сгруппировать тысячи прогонов модели транспортного потока по типам возникающих заторов и затем выявить ключевые факторы, приводящие к каждому типу [6]. Кроме того, методы МО используются для проведения анализа чувствительности, позволяя количественно оценить влияние каждого входного параметра на выходные переменные модели, что является критически важным для понимания и валидации модели [13]. На данном уровне ИИ используется как инструмент для интеллектуального анализа симуляционных данных, что позволяет извлекать из них ценные знания и инсайты.

1.2. Второй уровень – Оптимизационный

Оптимизационный уровень предполагает более активное и итеративное взаимодействие ИИ с процессом моделирования. Здесь алгоритмы ИИ используются для целенаправленного управления ходом симуляционных экспериментов с целью нахождения оптимальных решений. Имитационная модель выступает в роли функции оценки [14], которая для заданного набора входных параметров возвращает значение целевого показателя. Ключевой задачей является оптимизация параметров моделей [15].

В отличие от аналитического уровня, здесь существует обратная связь: ИИ анализирует результаты предыдущих прогонов и на их основе предлагает новые, более перспективные наборы параметров для следующей симуляции. Этот итерационный процесс продолжается до тех пор, пока не будет найдено удовлетворительное решение. Для решения таких задач широко применяются метаэвристические алгоритмы, такие как генетические алгоритмы, эволюционные стратегии, имитация отжига и байесовская оптимизация, способные эффективно исследовать сложные, негладкие и многоэкстремальные пространства поиска [2, 8, 16]. Кроме того, ИИ может использоваться для адаптивного управления процессом моделирования, динамически распределяя вычислительные ресурсы и решая, какие точки в пространстве параметров исследовать следующими, чтобы максимально быстро сойтись к оптимуму [5].

1.3. Третий уровень – Гибридный

Гибридный уровень является наиболее глубокой формой интеграции и предполагает создание систем, в которых ИИ и имитационная модель функционируют как взаимодополняющие компоненты единого вычислительного комплекса [4, 8]. В отличие от предыдущих уровней, здесь имеет место тесная интеграция с постоянной двусторонней связью, часто в режиме реального времени. Это уже не последовательное или итеративное взаимодействие, а полноценная ко-симуляция, где компоненты ИИ и моделирования работают параллельно и непрерывно обмениваются информацией.

В гибридных моделях компоненты ИИ могут быть встроены непосредственно в логику имитационной модели для представления поведения отдельных агентов или подсистем. Ключевой особенностью является совместное функционирование в реальном времени: имитационная модель предоставляет ИИ-агенту динамическую среду, а ИИ-агент своими действиями изменяет состояние этой среды. Этот подход лежит в основе концепции цифровых двойников [4, 17], где гибридная модель в реальном времени отражает состояние физического объекта, позволяя прогнозировать его поведение и оптимизировать управление. Гибридизация парадигм ИИ и моделирования помогает преодолеть ограничения каждой из них по отдельности, создавая более эффективные и адаптивные инструменты [8].

2. Классификация по направлению взаимодействия

В зависимости от того, какая из двух парадигм выступает в качестве основной, а какая — в качестве вспомогательной, можно выделить два больших класса подходов [4] (рис. 2).

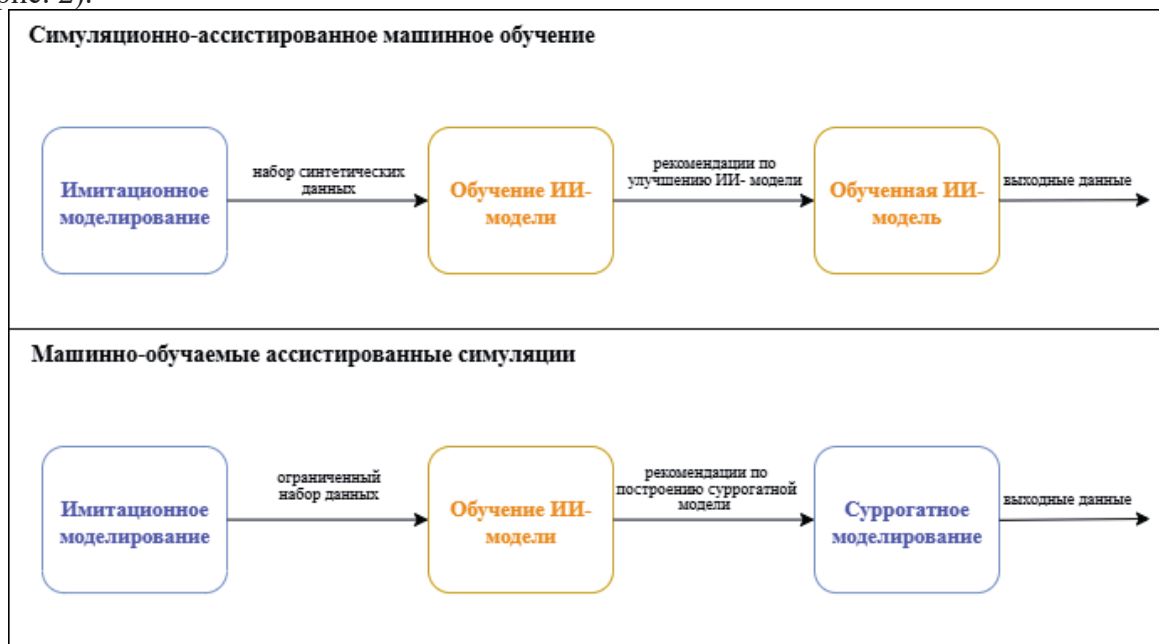


Рис. 2. Классификация по уровню направления взаимодействия искусственного интеллекта и имитационного моделирования

2.1. Симуляционно-ассистированное машинное обучение

В подходе симуляционно-ассистированного машинного обучения (Simulation-Assisted Machine Learning) [7] имитационное моделирование используется как инструмент для улучшения и ускорения разработки моделей машинного обучения. Основная идея заключается в том, что симуляции могут служить источником данных для обучения ИИ-систем, особенно когда сбор реальных данных затруднен, дорог или опасен. Одним из главных применений этого класса подходов является генерация синтетических данных для обучения алгоритмов МО [7, 8, 18]. Это особенно актуально для глубокого обучения, где требуются огромные массивы размеченных данных. Симуляторы позволяют генерировать данные для редких и критических сценариев (например, аварийных ситуаций для беспилотных автомобилей), которые практически невозможно собрать в реальности в достаточном количестве. Кроме того, симуляции предоставляют контролируемую и безопасную среду для обучения ИИ-систем, в частности, для обучения с подкреплением (Reinforcement Learning, RL), где агент может безопасно и быстро исследовать последствия своих действий методом проб и ошибок, не рискуя повредить реальное оборудование [19].

2.2. Машинно-обучаемые ассистированные симуляции

В подходе машинно-обучаемых ассистированных симуляций (Machine Learning-Assisted Simulation), наоборот, методы машинного обучения применяются для усовершенствования, ускорения и анализа самих имитационных моделей [3, 4]. Наиболее распространенным применением данного подхода является суррогатное моделирование. Суррогатная модель — это легковесная аппроксимация (метамодель) сложной, вычислительно дорогой симуляции, построенная с помощью методов МО на основе данных из ограниченного числа прогонов исходной модели [4, 20]. Такая модель обеспечивает практически мгновенные предсказания, что позволяет применять её для задач с большим числом обращений к модели, включая глобальную оптимизацию, анализ чувствительности и количественную оценку неопределённости. В целом, машинно-обучаемые ассистированные симуляции направлены на ускорение вычислений и повышение эффективности процесса моделирования, делая возможным решение задач, ранее недоступных из-за вычислительных ограничений.

3. Классификация по типу применяемых технологий ИИ

Данная классификация рассматривает конкретные семейства алгоритмов ИИ, применяемых для решения различных задач в рамках имитационного моделирования (рис. 3). Целесообразно разделить эти подходы на две основные парадигмы обучения: обучение с учителем, используемое преимущественно для аппроксимации и анализа поведения модели, и обучение с подкреплением, направленное на поиск оптимальных стратегий управления.



Рис. 3. Классификация по типу применяемых технологий искусственного интеллекта в имитационном моделировании

3.1. Подходы на основе обучения с учителем

В рамках этой парадигмы алгоритмы обучаются на размеченных данных, где для каждого набора входных параметров симуляции известен соответствующий выход. Эти методы идеально подходят для построения суррогатных моделей и классификации результатов. В зависимости от сложности и объема данных здесь могут применяться как классические методы, так и подходы на основе глубокого обучения.

3.1.1 Классические методы машинного обучения

Эти методы, как правило, хорошо интерпретируемы и менее требовательны к объему данных.

Полиномиальные регрессии

Полиномиальные регрессии и их обобщения часто используются для построения простых суррогатных моделей и поверхностей отклика, когда зависимость между входами и выходами симуляции является достаточно гладкой и нелинейной [21]. Они позволяют в аналитической форме представить сложную зависимость, что упрощает дальнейший анализ чувствительности и оптимизацию.

Методы опорных векторов

Методы опорных векторов [21] эффективно применяются для задач классификации результатов симуляций, например, они могут классифицировать исход симуляции как "успешный" или "неуспешный" на основе входных параметров, помогая определить область устойчивости или желаемого функционирования моделируемой системы.

Гауссовские процессы

Гауссовские процессы (Gaussian Processes, GP) представляют собой непараметрический байесовский метод для построения суррогатных моделей. В отличие от многих других методов GP не только дают точечное предсказание, но и предоставляют вероятностную оценку неопределенности этого предсказания в виде дисперсии [22]. Эта особенность делает их ценными для задач байесовской оптимизации и адаптивного планирования экспериментов, где необходимо балансировать между исследованием новых областей пространства параметров и уточнением уже известных.

3.1.2 Методы глубокого обучения

Эти методы основаны на использовании многослойных нейронных сетей и способны моделировать сложные, нелинейные зависимости, что делает их практически незаменимыми для работы с высокоразмерными симуляционными моделями [23].

Глубокие нейронные сети

Глубокие нейронные сети (Deep Neural Networks, DNN), такие как многослойные перцептроны, являются универсальными аппроксиматорами функций и широко используются для построения высокоточных суррогатных моделей для сложных симуляций с большим числом входных и выходных переменных [20]. Их способность обучаться на больших объемах данных позволяет создавать метамодел, которые точно воспроизводят поведение сложных физических или социально-экономических систем.

Физически-информированные нейронные сети (PINNs)

Это особый класс DNN, в функцию потерь которых при обучении явно включаются дифференциальные уравнения, описывающие физику моделируемого процесса. Это заставляет сеть не просто аппроксимировать данные, а находить решение, удовлетворяющее фундаментальным законам, что повышает точность и обобщающую способность модели при малом количестве данных [24].

Сверточные нейронные сети

Сверточные нейронные сети (Convolutional Neural Networks, CNN), изначально разработанные для анализа изображений, нашли применение в анализе симуляционных данных, имеющих пространственную структуру (например, полей давления или температуры в гидродинамических расчетах). Они могут использоваться как для постобработки данных, так и в качестве основы для суррогатных моделей физических полей [3].

3.2. Подходы на основе обучения с подкреплением

Обучение с подкреплением — это парадигма ИИ, в которой агент учится принимать оптимальные последовательности решений (политики) путем

взаимодействия с динамической средой и получения сигналов вознаграждения или штрафа. Имитационные модели отлично подходят на роль таких сред для обучения [19, 25].

Глубокое обучение с подкреплением (DRL)

Глубокое обучение (DRL) объединяет RL с глубокими нейронными сетями, что позволяет решать задачи с непрерывными или очень большими пространствами состояний и действий. Нейронная сеть используется для аппроксимации функций ценности или непосредственно политики агента. DRL является одной из ключевых технологий для обучения сложных управляющих систем в симуляторах.

Мультиагентное обучение с подкреплением

Мультиагентное обучение с подкреплением (Multi-Agent Reinforcement Learning, MARL) расширяет парадигму RL на системы, состоящие из множества взаимодействующих агентов. Это направление актуально для моделирования сложных адаптивных систем, таких как рой дронов, экономические рынки или транспортные потоки, где поведение каждого агента влияет на всех остальных [26].

Q-обучение

Q-обучение представляет собой классический алгоритм обучения с подкреплением для марковских процессов принятия решений с дискретными пространствами состояний и действий. Алгоритм итеративно обновляет Q-функцию, оценивающую качество выполнения действий в различных состояниях, и способен изучать оптимальную политику независимо от текущей стратегии поведения агента [19]. В имитационном моделировании Q-обучение эффективно применяется для оптимизации управляющих правил в агентных системах. Алгоритм также используется для поиска оптимальных маршрутов, где узлы сети представляют состояния, а выбор следующего узла — действия. Преимуществом Q-обучения является способность работать в стохастических средах без знания точной модели переходных вероятностей, что делает его подходящим для сложных многоагентных систем, где аналитическое решение затруднено.

Заключение

Интеграция искусственного интеллекта и имитационного моделирования открывает пространство для построения инструментов, способных не только ускорять вычисления, но и формировать новые способы понимания сложных систем. Разработанная классификация позволяет рассматривать методы на стыке этих областей не как разрозненные решения, а как взаимосвязанный спектр подходов с разной глубиной и направленностью интеграции. Практическая ценность подобного взгляда состоит в возможности точнее выбирать методологию в зависимости от исследовательских задач и ограничений. При этом особое значение приобретает поиск баланса между эффективностью вычислений и прозрачностью получаемых результатов, что определяет направление дальнейших исследований.

Благодарности

Исследование выполнено при поддержке Министерства науки и высшего образования Российской Федерации (государственное задание № 075-03-2025-256 от 16.01.2025).

Литература

1. **Sarker, I.H.** AI-Based Modeling: Techniques, Applications and Research Issues Towards Automation, Intelligent and Smart Systems. SN COMPUT. SCI. 3, 158 (2022). <https://doi.org/10.1007/s42979-022-01043-x>
2. **David N.** Artificial Intelligence in Modeling and Simulation. – MDPI-Multidisciplinary Digital Publishing Institute, 2024. – С. 278.

3. **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. – С. 548-560.
4. **Feldkamp, N.** (2024). Application of machine learning within hybrid systems modelling. In: Fakhimi M., Mustafee N. (eds) Hybrid modeling and simulation. Simulation Foundations, Methods and Applications. Springer, Cham. https://doi.org/10.1007/978-3-031-59999-6_7.
5. **Zeigler, B., Muzy, A., Yilmaz, L.** (2012). artificial intelligence in modeling and simulation. In: Meyers, R. (eds) Computational Complexity. Springer, New York, NY. https://doi.org/10.1007/978-1-4614-1800-9_14.
6. **Каримов К.С.** Методы искусственного интеллекта и применение их на транспорте // Постсоветский материк. 2023. №4 (40). URL: <https://cyberleninka.ru/article/n/metody-iskusstvennogo-intellekta-i-primenenie-ih-na-transporte> (дата обращения: 20.08.2025).
7. **Deist T. M. et al.** Simulation-assisted machine learning // Bioinformatics. 2019. Т. 35. №.20. С. 4072-4080.
8. **Tolk.** Hybrid modeling integrating artificial intelligence and modeling & simulation paradigms, 2024 Winter Simulation Conference (WSC), Orlando, FL, USA, 2024, pp. 1271-1280, doi: 10.1109/WSC63780.2024.10838942.
9. **Gunning D.** Explainable artificial intelligence (xai) // Defense advanced research projects agency (DARPA), nd Web. 2017. Т. 2. №. 2. С. 1.
10. **Saranya A., Subhashini R.,** A systematic review of explainable artificial intelligence models and applications: Recent developments and future trends, Decision Analytics Journal, Vol.7, 2023, 100230, ISSN 2772-6622, <https://doi.org/10.1016/j.dajour.2023.100230>.
11. **Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., ... & Herrera, F.** (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. Information fusion, 58, 82-115.
12. **Banks J., Carson J. S., Nelson B. L., Nicol D. M.** Discrete-event system simulation. 5th ed. Upper Saddle River, NJ : Prentice Hall, 2009. 638 p. ISBN 978-0-13-606212-7.
13. **Razavi S. et al.** The future of sensitivity analysis: an essential discipline for systems modeling and policy support // Environmental Modelling & Software. – 2021. – Т. 137. – С. 104954.
14. **Holland J. H.** Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. MIT press, 1992.
15. **Fu, M. C.** (Ed.). Handbook of Simulation Optimization / L. Jeff Hong, Barry L. Nelson, Jie Xu. — New York: Springer, 2015. — Vol. 216. Chapter 2, pp. 9-44.
16. **Amaran S. et al.** Simulation optimization: a review of algorithms and applications // Annals of Operations Research. 2016. Т. 240. №. 1. С. 351-380.
17. **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. С. 85-113.
18. **Nikolenko, S.I.** (2021). Synthetic Simulated Environments. In: Synthetic Data for Deep Learning. Springer Optimization and Its Applications, vol 174. Springer, Cham. https://doi.org/10.1007/978-3-030-75178-4_7.
19. **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. Т. 24. №. 199. С. 1-34.
20. **Zhu Y. et al.** Physics-constrained deep learning for high-dimensional surrogate modeling and uncertainty quantification without labeled data // Journal of Computational Physics. – 2019. Т. 394. С. 56-81.

21. **Chen, W.** The Application of Different Surrogate Models in Engineering Predictions // Applied and Computational Engineering. — 2024. — Vol. 80, No. 1. — Pp. 87–93. — DOI: 10.54254/2755-2721/80/2024CH0075.
22. **Li J., Wang H.** Gaussian Processes Regression for Uncertainty Quantification: An Introductory Tutorial //arXiv preprint arXiv:2502.03090. – 2025.
23. Goodfellow I., Bengio Y., Courville A. Deep learning. — Cambridge, Massachusetts; London, England: The MIT Press, 2016. — 800 p. — ISBN 978-0-262-03561-3.
24. **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.
25. **Klu E. et al.** SDGym: Low-Code Reinforcement Learning Environments using System Dynamics Models //arXiv preprint arXiv:2310.12494. – 2023.
26. **Ning Z., Xie L.** A survey on multi-agent reinforcement learning and its application //Journal of Automation and Intelligence. – 2024. – T. 3. – №. 2. – C. 73-91.