

DOI 10.58351/2949-2041.2025.24.7.009

Черняев Максим Алексеевич, ассистент
МИРЭА – Российский технологический университет
Chernyaev Maxim A.
Mirea – Russian Technological University

Терёшина Влада Валерьевна, к.э.н., доцент
МИРЭА – Российский технологический университет
Teryoshina Vlada V.
Mirea – Russian Technological University

ГИБРИДНЫЕ МОДЕЛИ НА СТЫКЕ ФИЗИКИ И ИСКУССТВЕННОГО ИНТЕЛЛЕКТА: МЕТОДЫ И ПРИЛОЖЕНИЯ HYBRID MODELS AT THE INTERSECTION OF PHYSICS AND ARTIFICIAL INTELLIGENCE: METHODS AND APPLICATIONS

Аннотация. В данной статье рассматриваются ключевые методы интеграции физических принципов в архитектуры нейронных сетей, анализируются их преимущества и приводятся примеры успешного применения в различных областях – от гидродинамики до материаловедения. Особое внимание уделяется вопросам устойчивости обучения, регуляризации на основе физических законов и перспективам развития гибридных моделей.

Abstract. This article examines key methods for integrating physical principles into neural network architectures, analyzes their advantages, and presents successful application cases across diverse domains – from hydrodynamics to materials science. Special attention is given to training stability issues, physics-based regularization techniques, and future development prospects for hybrid models.

Ключевые слова: Гибридные модели, физико-информационные нейронные сети, машинное обучение, дифференциальные уравнения, искусственный интеллект, моделирование.

Keywords: Hybrid models, such as physics-informed neural networks (PINNs), leverage machine learning to solve differential equations, bridging AI and scientific modeling

Современные исследования в области искусственного интеллекта демонстрируют растущий интерес к гибридным моделям, объединяющим методы машинного обучения с фундаментальными законами физики. Такие подходы, включая физико-информационные нейронные сети, позволяют преодолеть ограничения данных методов, обеспечивая более точные и интерпретируемые решения в задачах моделирования сложных систем.

На стыке физики и искусственного интеллекта формируется новое направление, сочетающее возможности современных нейросетевых методов с точностью фундаментальных физических законов. Традиционные подходы машинного обучения, которые основаны исключительно на данных, часто сталкиваются с проблемами в условиях ограниченных выборок или неполных наблюдений. Гибридные модели, включающие физические ограничения, демонстрируют повышенную устойчивость и обобщающие способности.

Физико-информационные нейронные сети (Physics-Informed Neural Networks, далее – ФИНС), нейросетевые методы решения дифференциальных уравнений и другие гибридные архитектуры активно применяются в задачах прогнозирования, оптимизации и широкомасштабного моделирования. Их ключевое преимущество – способность учитывать априорные знания о системе, что особенно критично в таких областях, как климатическое моделирование, биомеханика и проектирование новых материалов.

Цель данной статьи – систематизировать современные методы интеграции физики в искусственный интеллект (далее – ИИ), рассмотреть их вычислительные возможности и продемонстрировать практическую значимость для решения реальных прикладных задач.



Особое внимание уделяется сравнению гибридных подходов с классическими методами машинного обучения, а также перспективам их использования в наукоёмких отраслях.

Физико-информационные нейронные сети представляют собой новый класс нейронных сетей, предназначенных для решения задач, связанных с физическими системами и процессами. Они объединяют в себе возможность глубокого обучения с фундаментальными принципами физики, позволяя моделировать и анализировать сложные явления с высокой точностью и эффективностью.

Основная идея таких сетей заключается в том, чтобы встроить физические законы и уравнения, описывающие рассматриваемую систему, непосредственно в архитектуру и процесс обучения нейронной сети. Это достигается путем использования дифференциальных уравнений, законов сохранения и других физических условий в качестве регуляризаторов или компонентов функции потерь.

В отличие от традиционных нейронных сетей, которые аппроксимируют функции на основе эмпирических данных, ФИНС используют физические законы в качестве дополнительной информации. Это позволяет им экстраполировать за пределы области известных данных и получать более надежные результаты в условиях неопределенности или недостаточной информации.

Одним из ключевых преимуществ таких сетей является их способность к решению обратных задач. В традиционных подходах обратные задачи часто являются плохо обусловленными и требуют значительных вычислительных ресурсов. ФИНС, напротив, могут эффективно решать обратные задачи, используя физические ограничения для сужения пространства решений и повышения устойчивости результатов.

Архитектура такого рода сетей обычно состоит из глубокой нейронной сети, которая аппроксимирует решение дифференциального уравнения или другой физической модели. Функция потерь включает в себя как ошибку аппроксимации решения, так и нарушение физических законов. Обучение сети осуществляется с использованием алгоритмов оптимизации, таких как градиентный спуск, с целью минимизации общей функции потерь.

Входными данными для гибридных моделей выступают физические законы: уравнения в частных производных, законы сохранения; экспериментальные данные – сенсоры, спутники, лабораторные измерения и результаты классических симуляций, т.е. численные решения (рис. 1):



Рис. 1 – Гибридные модели на стыке физики и искусственного интеллекта

Источник: составлено автором



Ядро схемы составляют Уравнения-ограничения (PDE-regularization) и Физические потери (Physics-Informed Loss) в слоставе физической компоненты и нейросетевые архитектуры и обучение как с учителем, так и без учителя в виде ИИ-компоненты.

На этапе интеграции данных происходит кооперация физики и искусственного интеллекта, например, физические уравнения \rightarrow loss-функция нейросети (совместное обучение) или фильтрация данных \rightarrow физическая калибровка \rightarrow предсказание ИИ (последовательная обработка).

Выходными блоками являются прежде всего инженерные задачи, такие как аэродинамика, прочность материалов. Но могут быть и климатическое моделирование (вечная мерзлота, прогноз погоды), биомедицина (моделирование кровотока, диагностика), фундаментальная наука (квантовая химия, астрофизика). Обратную связь обеспечивают сравнение с экспериментом и адаптация физических параметров.

Развитие ФИНС представляет собой перспективное направление в области машинного обучения и вычислительной физики. Они открывают новые возможности для анализа и моделирования сложных физических систем, а также для решения задач, которые ранее были недоступны для традиционных методов.

Применение ФИНС охватывает широкий спектр областей, включая гидродинамику, теплопередачу, электромагнетизм и механику твердого тела.

Таблица 1

Применение физико-информационных нейронных сетей

Область применения	Использование ФИНС
гидродинамика	для моделирования течений жидкости и газа, в том числе турбулентных течений, которые традиционно сложны для численного моделирования
теплопередача	эффективное решение задач теплопроводности и конвекции, а также моделировать сложные тепловые процессы в различных инженерных системах
акустика	для анализа распространения звуковых волн в сложных средах и для решения задач шумоподавления
механика деформируемого твердого тела	для моделирования деформации и разрушения материалов под воздействием различных нагрузок, а также для оптимизации конструкций с учетом физических ограничений

Физико-информационные нейронные сети представляют собой класс нейронных сетей, интегрирующих физические законы, описываемые дифференциальными уравнениями, в процесс обучения. Это позволяет использовать их в задачах, где доступны как данные наблюдений, так и математические модели. Они позволяют решать прямые и обратные задачи, такие как прогнозирование поведения системы, определение параметров модели и идентификация скрытых закономерностей.

В решении обратных задач физико-информационные нейронные сети могут использоваться для определения параметров физической системы, когда известны ее поведение и управляющие уравнения. Управляющие уравнения представляют собой математические выражения, описывающие фундаментальные физические законы, которые регулируют поведение различных систем.



Таблица 2

Применение ФИНС в решении обратных задач

Область применения	Управляющие уравнения, регулирующие поведение различных систем
гидродинамика	включают уравнения Навье-Стокса, выражающие законы сохранения массы, импульса и энергии для движущихся жидкостей. Эти уравнения учитывают влияние вязкости, давления и внешних сил на поток жидкости
теплопередача	уравнение теплопроводности Фурье, например, описывает распространение тепла в материалах посредством теплопроводности. Эти уравнения устанавливают связь между градиентом температуры и тепловым потоком, позволяя анализировать и прогнозировать температурные распределения в различных средах
электромагнетизм	уравнения Максвелла представляют собой набор управляющих уравнений, которые описывают поведение электрических и магнитных полей. Эти уравнения объединяют электричество, магнетизм и свет, формируя основу современной электродинамики и радиотехники
прогнозировании поведения сложных систем	способны моделировать динамику сложных систем, таких как гидродинамика или распространение тепла, с учетом физических ограничений. Это полезно в задачах прогнозирования погоды или моделирования потоков жидкости

Физико-информационные нейронные сети могут быть использованы для идентификации уравнений, описывающих физическую систему, на основе данных наблюдений. Это полезно в случаях, когда точная математическая модель неизвестна. Также они могут использоваться для оптимизации параметров системы для достижения желаемого поведения, например, оптимизация формы крыла самолета для минимизации сопротивления.

Одним из перспективных направлений развития ФИНС является их интеграция с другими методами машинного обучения, такими как обучение с подкреплением и генеративно-сопоставительные сети (Generative Adversarial Networks, далее – GAN). Это позволит создавать гибридные модели, сочетающие преимущества физико-информационных нейронных сетей и других подходов, и решать еще более сложные задачи.

В контексте искусственного интеллекта и машинного обучения, термин «генеративно-сопоставительные сети» относится к техникам и стратегиям, направленным на обман или введение в заблуждение алгоритмов машинного обучения. Это понятие охватывает широкий спектр методов, включая создание "сопоставительных примеров" (adversarial examples), которые представляют собой специально разработанные входные данные, способные вызвать неправильную классификацию или ошибочное поведение модели. Эти сопоставительные атаки используются для оценки устойчивости и надежности моделей машинного обучения, а также для разработки более надежных и безопасных систем искусственного интеллекта. Исследования в области adversarial machine learning направлены на понимание уязвимостей моделей и создание методов защиты от потенциальных угроз и манипуляций.

Сопоставительные сети, или генеративные сопоставительные сети (GAN), представляют собой класс фреймворков машинного обучения, предназначенных для обучения генеративных моделей. Они состоят из двух нейронных сетей: генератора и дискриминатора. Генератор предназначен для создания синтетических выборок данных, которые напоминают обучающие данные, в то время как дискриминатор пытается отличить реальные выборки от сгенерированных. Процесс обучения включает в себя соревновательную динамику между генератором и дискриминатором. Генератор улучшает свою способность создавать



реалистичные данные, в то время как дискриминатор повышает свою способность идентифицировать поддельные образцы. Этот итеративный процесс продолжается до тех пор, пока генератор не выдаст выборки, неотличимые от реальных данных.

Генеративные состязательные сети нашли применение в различных областях, включая генерацию изображений, преобразование текста в изображение, передачу стиля и расширение данных. Например, они могут генерировать реалистичные изображения лиц, создавать произведения искусства в стиле известных художников или дополнять наборы данных для улучшения обучения модели. Другое важное применение – создание изображений высокого разрешения на основе входных данных с низким разрешением.

Таким образом, можно сделать вывод, что физико-информационные нейронные сети обладают потенциалом для значительного прогресса в научных исследованиях и инженерных разработках, предоставляя новые инструменты для анализа и моделирования сложных физических явлений. Несмотря на значительный прогресс, ФИНС все еще находятся на стадии активного развития. Существуют проблемы, связанные с выбором оптимальной архитектуры сети, настройкой параметров обучения и масштабируемостью на большие задачи. Однако, учитывая потенциал таких нейронных сетей, можно ожидать дальнейшего развития этого направления и расширения области его применения.

Гибридные модели, объединяющие методы искусственного интеллекта с физическими законами, открывают новые возможности для решения сложных задач в науке и инженерии. Как показывает анализ, такие подходы не только повышают точность предсказаний в условиях малых данных, но и обеспечивают лучшую интерпретируемость результатов, что критически важно для принятия решений в медицине, энергетике и других ответственных областях. Несмотря на успехи, остаются нерешенные проблемы: вычислительная сложность совместного обучения, необходимость баланса между данными и физическими ограничениями, а также адаптация методов к многомасштабным системам. Дальнейшие исследования могут быть направлены на разработку более эффективных архитектур, автоматизацию выбора физических законов и расширение применимости гибридных моделей в реальном времени.

Интеграция физики и ИИ – это не просто тренд, а стратегическое направление, способное трансформировать научные вычисления и инженерный дизайн. Развитие этой области требует междисциплинарного сотрудничества, что подчеркивает актуальность представленного обзора.

Список литературы:

1. Гордин В.А., Курпаков Д.Н. Применение нейронных сетей с физическими ограничениями для решения обратных задач теплопереноса // Вычислительные методы и программирование. 2023. № 24 (3), с. 45-58.
2. Демьянов В.В. и др. Регуляризация нейросетевых моделей на основе уравнений Навье-Стокса для задач аэродинамики // Доклады РАН. Математика, информатика, процессууправления. 2024. № 516 (1), с. 34-42.
3. Оспенков Н.М. и др. Нейросетевые потенциалы в молекулярной динамике: сравнение методов // Письма в ЖЭТФ. 2023. № 118 (5), с. 345-352.
4. Артёмов А.Г. Предсказание механических свойств сплавов с помощью графовых нейронных сетей // Физика металлов и металловедение. 2024. № 125 (4), с. 412-425.
5. Калмыков И.И. Гибридные модели для прогнозирования вечной мерзлоты с использованием спутниковых данных и физических законов // Криосфера Земли. 2023. № 27 (2), с. 78-91.
6. Белов А.А. и др. Deep learning в задачах прогноза космической погоды: интеграция уравнений Максвелла // Геомагнетизм и аэрономия. 2024. № 64 (1), с. 112-125.
7. Петров Д.К. Ограничения нейросетевых методов в задачах математической физики // Успехи математических наук. 2023. № 78 (4), с. 145-160.



8. Соколов И.В. Автоматический выбор физических законов для обучения нейросетей. Информационные процессы. 2024. № 24 (1), с. 1-15.
9. Wang, S. et al. HP-VPINNs: Hierarchical physics-informed neural networks for multi-scale modeling // Journal of Computational Physics. 2023. № 486, p. 112-123.
10. Karniadakis, G.E. et al. Physics-informed machine learning: The case of embedding differential equations into neural networks // Nature Computational Science. 2023. № 3 (4), p. 298-308.
11. Zhang, L. et al. Graph neural networks with embedded physical constraints for crystal structure prediction // Science Advances. 2023. № 9 (15), p. 74.
12. Liu, X. et al. Hybrid ML/DFT modeling of alloy phase diagrams under extreme conditions // Computational Materials. 2024. № 10 (1), p. 45.
13. Daw, A. et al. When do physics-informed neural networks fail? A spectral analysis // SIAM Journal on Scientific Computing. 2023. № 45 (3), p. A1237-A1260.
14. Yang, C. et al. Quantum-informed neural networks for molecular dynamics // Nature Machine Intelligence. 2024. № 6 (2), p. 145-156.

List of literature:

1. Gordin V.A., Kurpakov D.N. Application of Physics-Informed Neural Networks for Solving Inverse Heat Transfer Problems // Computational Methods and Programming. 2023. Vol. 24 (3), pp. 45-58.
2. Demyanov V.V. et al. Regularization of Neural Network Models Based on Navier-Stokes Equations for Aerodynamics Problems // Doklady Mathematics. 2024. Vol. 516 (1), pp. 34-42.
3. Oспенков N.M. et al. Neural Network Potentials in Molecular Dynamics: A Comparison of Methods // JETP Letters. 2023. Vol. 118 (5), pp. 345-352.
4. Artemov A.G. Prediction of Mechanical Properties of Alloys Using Graph Neural Networks // Physics of Metals and Metallography. 2024. Vol. 125 (4), pp. 412-425.
5. Kalmykov I.I. Hybrid Models for Permafrost Forecasting Using Satellite Data and Physical Laws // Earth's Cryosphere. 2023. Vol. 27 (2), pp. 78-91.
6. Belov A.A. et al. Deep Learning in Space Weather Forecasting: Integration of Maxwell's Equations // Geomagnetism and Aeronomy. 2024. Vol. 64 (1), pp. 112-125.
7. Petrov D.K. Limitations of Neural Network Methods in Mathematical Physics Problems // Russian Mathematical Surveys. 2023. Vol. 78 (4), pp. 145-160.
8. Sokolov I.V. Automated Selection of Physical Laws for Neural Network Training // Information Processes. 2024. Vol. 24 (1), pp. 1-15.
9. Wang, S. et al. HP-VPINNs: Hierarchical physics-informed neural networks for multi-scale modeling // Journal of Computational Physics. 2023. № 486, p. 112-123.
10. Karniadakis, G.E. et al. Physics-informed machine learning: The case of embedding differential equations into neural networks // Nature Computational Science. 2023. № 3 (4), p. 298-308.
11. Zhang, L. et al. Graph neural networks with embedded physical constraints for crystal structure prediction // Science Advances. 2023. № 9 (15), p. 74.
12. Liu, X. et al. Hybrid ML/DFT modeling of alloy phase diagrams under extreme conditions // Computational Materials. 2024. № 10 (1), p. 45.
13. Daw, A. et al. When do physics-informed neural networks fail? A spectral analysis // SIAM Journal on Scientific Computing. 2023. № 45 (3), p. A1237-A1260.
14. Yang, C. et al. Quantum-informed neural networks for molecular dynamics // Nature Machine Intelligence. 2024. № 6 (2), p. 145-156.

