

Применение инструментария ИИ при решении задач механики открывает широкие возможности для формирования новых подходов в теоретических изысканиях, математическом и численном моделировании сложных реальных механических и сопряженных с ними процессов, а также способствует дальнейшему развитию и совершенствованию собственно методов и технологий искусственного интеллекта. Так, Нобелевская премия по физике в 2024 г. была присуждена ученым Дж. Хопфилду и Дж. Хинтону за использование инструментов физики для разработки технологий современного машинного обучения.



Интеллектуальная механика



Денис Мармыш,
доцент кафедры
теоретической и прикладной
механики механико-
математического факультета
БГУ, кандидат физико-
математических наук, доцент



Михаил Журавков,
заведующий кафедрой
теоретической и прикладной
механики механико-
математического факультета
БГУ, доктор физико-
математических наук,
профессор

Можно утверждать, что в настоящее время идет становление нового направления – интеллектуальной механики, представляющей собой симбиоз нескольких областей классической и современной механики, прикладной математики и информатики. Современные технологии моделирования в механике (что можно сказать по существу обо всех физических и производственных процессах) – это «высокопроизводительные вычисления + знания и «большие данные» + математические модели + технологии искусственного интеллекта» [1].

Возможности математического и компьютерного моделирования качественно изменяются, и одно из существенных новых требований к данным технологиям – наличие в них элементов ИИ. Необходимо, чтобы интеллектуальные системы работали как «черные ящики», выдающие заключение. Они должны не только представлять собой вызывающий доверие инструмент, но и демонстрировать понятный и эффективный путь получения результата. В особенности это проявляется при создании автоматизированных систем поддержки принятия решений как одного из наиболее перспективных направлений развития ИИ, в частности интеллектуальных систем моделирования и прикладных расчетов. Отметим, что на нынешнем этапе речь идет именно об автоматизированных системах с участием человека в управлении процессом, осуществляемым при поддержке ИИ.

Для разработки высокоэффективных систем интеллектуального моделирования и инженерных расчетов в механике необходимо

в первую очередь сосредоточиться на решении нескольких стратегических задач, которые можно сгруппировать следующим образом:

- *методы интеллектуальной обработки и анализа первичной информации и данных;*
- *технологии выбора и построения механико-математических моделей исследуемых процессов, решения прикладных задач;*
- *технологии построения численных моделей и расчетных схем; сопряженных расчетных схем и алгоритмов, базирующихся на методах ИИ и классических методах механико-математического моделирования;*
- *интеллектуальная интерпретация и анализ результатов моделирования;*
- *методы и технологии новых интеллектуальных CAD-, CAE- и CAM-систем.*

Принцип работы алгоритмов ИИ заключается в интеллектуальной обработке огромных объемов данных с автоматическим выявлением содержащихся в них закономерностей и признаков, что позволяет программам автоматически обучаться и, главное,

моделировать и предсказывать новые события и генерировать данные [1].

Вместе с тем при реализации попыток внедрения методов машинного обучения (МО) и, в частности, искусственных нейронных сетей (ИНС) в такие области, как механика, физика, химия, исследователи сталкиваются с существенными проблемами. Так, если с обработкой визуальной информации и/или синтезом звука нейросетевые модели уже достаточно хорошо справляются, и исследования в этой области в основном направлены на совершенствование существующих архитектур ИНС и их усложнение с целью более точной обработки входящей информации, то использование ИИ для построения методов решения сложных прикладных классов задач механики, физики или химии находится на начальной стадии развития. Важным моментом при этом является наличие у разработчиков не только навыков в области ИИ, но и глубоких специализированных знаний в соответствующей предметной области. Так, например, при применении методов ИИ в задачах механики деформируемого твер-




Рис. 1. Ежегодное количество публикаций по приложениям ИНС в механике

дого тела (МДТТ) в первую очередь необходимы фундаментальные знания в механике сплошных и дискретных сред, механике материалов, математических моделях МДТТ и сопряженных задачах, механики прочности и разрушения и большого количества других специальных дисциплин. Помимо этого, конечно, требуется наличие знаний в области прикладной математики и информатики.

С 2018 г. наблюдается резкий скачок числа научных публикаций, связанных с приложениями методов машинного обучения, в частности искусственных нейронных сетей, для решения различных задач механики деформируемого твердого тела, механики жидкости и газа, биомеханики, геомеханики, механики строительных конструкций, механики машин и механизмов и других разделов. На *рис. 1* представлен график количества публикаций с 1988 по 2023 г. по данным базы научных статей Scopus.

Согласно классификации, представленной в работе [2], перспективно использовать ИНС для решения следующих типов задач механики:

- *моделирование отклика механической системы на внешнее воздействие по входным физико-механическим параметрам;*
- *идентификация параметров механической системы по ее отклику на внешнее воздействие;*
- *идентификация внешних возбудителей системы по целевым параметрам и ее отклику;*
- *комплексная оценка внешних возбудителей и отклика системы по всем релевантным физико-механическим параметрам и условиям ее работы.*

Отметим, что достаточно полное и систематизированное изложение математических основ методов МО и ИНС присутствует в [3, 4]. В работах [5, 6] рассматриваются различные нейросетевые алгоритмы решения широкого спектра прикладных задач геотехники, анализа пластического поведения и разру-

фикации, условные порождающие состязательные сети (Conditional Generative Adversarial Nets, cGAN) эффективно применяются для создания микроструктур метаматериалов, генерации пространственных структур по картинкам их плоских срезов, а также оценки упругих параметров для новых материалов [14].



Рис. 2. Блок-схема технологии решения задач механики с использованием методов ИИ

шения материалов, исследования прочностных свойств строительных материалов и конструкций, вычислительные аспекты взаимодействия нейросетевых алгоритмов и метода конечных элементов при анализе напряженно-деформированного состояния твердого тела. Существенным импульсом к вопросу изучения применения ИИ в механике послужили научные работы, опубликованные после 2017 г., в которых рассматриваются теоретические возможности создания материалов с заранее заданными физико-механическими и химическими свойствами (например, [7–10]). Хорошие перспективы имеются в области разработки метаматериалов и метаповерхностей, в которых периодическая структура среды генерируется нейросетевыми алгоритмами [11–13]. Порождающие состязательные сети (Generative Adversarial Nets, GAN) и их моди-

Рассмотрим некоторые аспекты применения ИНС и методов машинного обучения в целом при разработке новых технологий моделирования и решения задач МДТТ. Общую схему с использованием методов ИИ, которые развиваются в настоящее время и обладают потенциалом, можно представить в виде блок-схемы, изображенной на *рис. 2* [11]. Как было указано, перспективным и важным является создание технологий построения сопряженных расчетных схем и алгоритмов, базирующихся на методах ИИ и классических методах механико-математического моделирования.

Источниками данных для обучения нейросетевых моделей выступают материалы эксперимента и/или математического моделирования (*рис. 2*). Важным представляется использование дополнительных сведений в таких доступных источниках,

как базы данных и знаний, литературные источники, экспертные системы [1]. На этапе предобработки происходит преобразование всего набора первичной информации, ее интеллектуальный анализ. В блок входных данных передается массив структурированных материалов. Здесь же формируются обучающая и тестовая выборки, выдаются рекомендации к выбору/построению механико-математической модели. На данный момент существует достаточно большое количество библиотек с готовыми архитектурами искусственных нейронных сетей, которые могут быть применены в качестве инструмента для построения нейросетевой модели в задачах МДТТ.

Поступающие в нейронные сети входные данные представляют собой набор численных значений, характеризующих признаки исследуемого объекта. Опираясь только на них, обучение сети может прийти к некорректному результату, который будет противоречить физическим законам поведения деформируемой твердой среды. Так, в классической теории упругости фундаментальными соотношениями являются уравнения движения/равновесия среды, уравнения совместности

деформаций, закон Гука, которые должны быть учтены при разработке модели упругого поведения объекта с помощью методов ИНС. С этой целью в последние годы были сгенерированы специальные модели нейронных сетей, основанные на физико-механических законах поведения материалов (physics informed neural networks, PINN) (например, [15–16]). Используя такой тип ИНС, в работе [17] решается задача исследования напряженно-деформированного состояния (НДС) твердых деформируемых тел в остановке плоской задачи линейной теории упругости. В [18] описывается применение PINN в трибологии и механике износа – крайне сложного феномена для математического моделирования. При построении механико-математической модели износа в системе твердых тел необходим учет множества факторов и переменных. Методы ИИ позволяют снизить размерность задачи и получить более предсказуемые результаты. Кроме того, в силу комплексности развития физико-механических процессов, происходящих в твердых телах, в одной архитектуре нейронной сети могут использоваться различные «подсети». Такие модели получили название гибридных

нейронных сетей (Hybrid Neural Network, HNN) [19, 20].

Важный этап при построении ИНС – выбор функции активации отдельного нейрона. Анализ работ показывает, что наиболее распространенной, применяемой в МДТ, является сигмоидальная [1, 2, 8, 14, 18]:

$$\sigma(x) = [1 + \exp(-x)]^{-1} \quad (1)$$

Выражение (1) представляет собой монотонно возрастающую логистическую кривую, такую, что $\sigma(x) \rightarrow 0$ при $x \rightarrow -\infty$ и $\sigma(x) \rightarrow 1$ при $x \rightarrow \infty$. Данная ситуация обусловлена тем, что любую непрерывную функцию $f(x)$ от n переменных $x_1, x_2, \dots, x_n$, заданную в единичном гиперкубе $[0, 1]^n$, можно равномерно аппроксимировать суммой сигмоидальных функций (1) в виде [21]:

$$f(x) = \sum_{j=1}^N \alpha_j \sigma(\mathbf{w}_j \cdot \mathbf{x} + b_j), \quad (2)$$

где $\mathbf{w}_j \cdot \mathbf{x} = w_{j1}x_1 + w_{j2}x_2 + \dots + w_{jn}x_n$

В работе [22] рассмотрено применение модели нейронной сети достаточно простой архитектуры с сигмоидальной функцией активации (модель логистической регрессии, логит-модель) для численной оценки повреждаемости твердой деформируемой среды. Показано, что в комбинации с методом граничных элементов для предварительного анализа НДС и формирования обучающего набора данных логит-модель позволяет заменить ресурсоемкий расчет НДС оценкой вероятности принадлежности рассматриваемого объема тела повреждаемой области.

В МДТТ все задачи можно разделить на два класса:

- *прямая задача – расчет НДС по заданным характеристикам, таким как начальные*




Рис. 3. Эффективные технологии моделирования и решения задач современной механики

и граничные условия, физико-механические свойства, геометрические параметры;

- обратная задача – оценка физико-механических свойств, начальных и граничных условий, идентификация геометрических параметров изучаемого объекта или системы.

Такие широко распространенные численные методы, как методы конечных, граничных и дискретных элементов, ориентированы главным образом на решение прямой задачи. Они применяются в комбинированных подходах совместно с ИНС [22–24].

Искусственные нейронные сети успешно применяются в решении обратных задач МДТТ [25–27]: например, по идентификации неоднородностей в твердом теле (полостей, трещин, включений) или оценке упруго-пластических параметров среды по заданной диаграмме деформирования тела.

Искусственный интеллект открывает широкие и перспективные возможности для исследователей в прикладных науках [28]. В комбинации с классическими методами и технологиями аналитического и численного анализа инструменты ИИ позволяют разработать новый класс эффективных способов моделирования и решения сложных типов и классов задач современной механики (рис. 3).

Следует подчеркнуть, что применение технологий ИИ в прикладных науках – это междисциплинарные исследования. В Республике Беларусь сформированы хорошо известные в мире научные школы по искусственному интеллекту и прикладному математическому моделированию и есть все возможности и перспективы быть лидером в этой области. ■

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Журавков М.А. Технологии искусственного интеллекта и интеллектуальные системы компьютерного моделирования и инженерных расчетов. Вводный курс: учеб. пособие / М.А. Журавков. — Минск, 2024.
2. Paez T.L. Neural networks in mechanical system simulation, identification and assessment / T.L. Paez // Shock and Vibration. 1993. №2(1). P. 177–199.
3. Bishop C.M. Neural networks for pattern recognition / C.M. Bishop. — Oxford, 1995.
4. Haykin S. Neural networks: a comprehensive foundation / S. Haykin. — Prentice Hall, 1999.
5. Waszczyszyn Z. Neural Networks in the Analysis and Design of Structures / Z. Waszczyszyn. — Springer, 1999.
6. Waszczyszyn Z. Artificial neural networks in civil engineering: another five years of research in Poland / Z. Waszczyszyn // Computer Assisted Mechanics and Engineering Sciences. 2011. №18. P. 131–146.
7. Butler K.T. Machine learning for molecular and material science / K.T. Butler [et al.]. // Nature. 2018. №559. P. 547–555.
8. Balokas G. Neural network assisted multiscale analysis for the elastic properties prediction of 3D braided composites under uncertainty / G. Balokas, S. Czichon, R. Rolfes // Composite Structures. 2018. №183. P. 550–562.
9. Luna P. D. Use machine learning to find energy materials / P. D. Luna [et al.]. // Nature. 2017. №552. P. 23–27.
10. Pham M.-S. Damage-tolerant architected materials inspired by crystal microstructure / M.-S. Pham [et al.]. // Nature. 2019. №565. P. 305–311.
11. Guo K. Artificial intelligence and machine learning in design of mechanical materials / K. Guo [et al.]. // Mater Horizons. 2021. №8(4). P. 1153–1172.
12. Yago D. Machine learning in solid mechanics: Application to acoustic metamaterial design / D. Yago [et al.]. // <https://onlinelibrary.wiley.com/doi/book/10.1002/0471784192>.
13. Jin H. Recent advances and applications of machine learning in experimental solid mechanics: a review / H. Jin, E. Zhang, H.D. Espinosa // Applied Mechanics Reviews. 2023. №75 (6). Art. N061001. Doi. 10.1115/1.4062966.
14. Karniadakis G.E. Physics-informed machine learning / G.E. Karniadakis [et al.]. // Nature Reviews Physics. 2021. №3(6). P. 422–440.
15. Raissi M. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations / M. Raissi, P. Perdikaris, G.E. Karniadakis // Journal of Computational Physics. 2019. №378. P. 686–707.
16. Roy A.M. Deep learning-accelerated computational framework based on physics informed neural network for the solution of liner elasticity / A.M. Roy [et al.]. // Neural networks. 2023. №162. P. 472–489.
17. Argatov I. Artificial neural networks (ANNs) as a novel modelling technique in tribology / I. Argatov // Frontiers of Mechanical Engineering. 2019. №5(30).
18. Li D. Hybrid neural network-based prediction model for tribological properties of polyamide6-based friction material / D. Li, R. Lv, Y. You // Polymer composites. 2017. №38(8). P. 1705–1711.
19. Margenberg N. DNN-MG: A hybrid neural network/finite element method with applications to 3D simulations of the Navier-Stokes equations / N. Margenberg [et al.]. // Computer Methods in Applied Mechanics and Engineering. 2024. №420. Art. N116692 21. Cybenko G. Approximation by superpositions of a sigmoidal function / G. Cybenko // Mathematics of Control, Signals and Systems. 1989. №2. P. 303–314. Doi.org/10.1016/j.cma.2023.116692.
20. Мармыш Д.Е. Применение логистической регрессии к вычислению повреждаемости твердого деформируемого тела / Д.Е. Мармыш // Механика машин, механизмов и материалов. 2021. №2(54). С. 46–53.
21. Stoffel M. Artificial neural networks and intelligent finite elements in non-linear structural mechanics / M. Stoffel, F. Bamer, B. Markert // Thin-Walled Structures. 2018. №131. P. 102–106.
22. Stoffel M. Artificial neural networks in structural dynamics / M. Stoffel, F. Bamer, B. Markert // Proceedings in Applied Mathematics and Mechanics. 2019. №19, e201900128.
23. Желткович А.Е. Применение нейросетевых алгоритмов при разработке акустических методов контроля прочности бетона / А. Е. Желткович [и др.] // Вестник Брестского государственного технического университета. 2024. №1(133). С. 101–109.
24. Соловьев А.Н. Определение упругих и диссипативных свойств материалов с помощью сочетания метода конечных элементов и комплекснозначных искусственных нейронных сетей / А.Н. Соловьев, Н.З.Ч. Занг // Вестник ДГТУ. 2014. Т. 14, №2(77). С. 84–92.
25. Соловьев А.Н. Реконструкция дефектов в упругих телах сочетанием генетического алгоритма и метода конечных элементов / А.Н. Соловьев, М.Ю. Шевцов // Вестник ДГТУ. 2016. Т. 16, №2(85). С. 5–12.
26. Журавков М.А. Технологии искусственного интеллекта: системы компьютерного моделирования в прикладных исследованиях / М.А. Журавков, С.М. Босяков, С.С. Щербаков // Наука и инновации. 2023. №4(421). С. 43–51.