

И. И. Захаренко^{1✉}, Д. С. Худяков¹

Интеллектуальная платформа разработки инженерных конструкций

¹Национальный исследовательский ядерный университет «МИФИ»,
г. Москва, Российская Федерация
e-mail: ilyazakharenko1994@mail.ru

Аннотация. Исследование посвящено разработке интеллектуальной платформы для генеративного проектирования и оптимизации мультифизических инженерных систем. Особое внимание уделяется применению платформы для оптимизации систем охлаждения литий-ионных аккумуляторных батарей и электролизёров зелёного водорода с целью повышения их энергоэффективности, безопасности и ресурса.

В результате анализа были выявлены фундаментальные проблемы существующих подходов, среди которых – отсутствие единого замкнутого цикла от текстового описания требований до физически корректной оптимизированной конструкции, слабая интеграция строгих физических моделей с адаптивными алгоритмами оптимизации, а также недостаточная ориентированность инструментов на задачи зелёных технологий. Предложена архитектура интеллектуальной платформы, объединяющая языковой интерфейс, параметрическую генерацию геометрии, физически-информированные нейронные сети и гибридные методы оптимизации. Предварительные вычислительные эксперименты демонстрируют потенциал снижения вычислительных затрат на этапе раннего проектирования на 30–40 % и улучшения целевых характеристик конструкции (масса, тепловые потери, эффективность) на 10–15 % по сравнению с традиционными методами.

Ключевые слова: генеративное проектирование, физически-информированные нейронные сети, обучение с подкреплением, мультифизическое моделирование, интеллектуальная платформа

I. I. Zakharenko^{1✉}, D. S. Khudyakov¹

Intelligent system for engineering design development

¹National Research Nuclear University MEPhI, Moscow, Russian Federation
e-mail: ilyazakharenko1994@mail.ru

Abstract. The study is devoted to the development of an intelligent platform for generative design and optimization of multiphysics engineering systems. Particular attention is paid to the application of the platform for optimizing cooling systems of lithium-ion battery packs and green hydrogen electrolyzers in order to improve their energy efficiency, safety, and operational lifetime.

The analysis revealed several fundamental limitations of existing approaches, including the absence of an integrated closed-loop workflow from textual design requirements to a physically consistent optimized construction, weak integration of rigorous physical models with adaptive optimization algorithms, and insufficient focus on green technology applications.

An architecture of an intelligent platform combining a natural language interface, parametric geometry generation, physics-informed neural networks, and hybrid optimization methods is proposed. Preliminary computational experiments demonstrate the potential to reduce computational costs at the early design stage by 30–40 % and improve key design characteristics, including mass, thermal losses, and overall efficiency, by 10–15 % compared to traditional approaches.

Keywords: generative design, physics-informed neural networks, reinforcement learning, multiphysics modeling, intelligent design platform

Введение

Разработка современных мультифизических инженерных систем требует значительных вычислительных затрат, особенно при использовании методов полного численного моделирования (CFD и FEM) [1, 2]. Это ограничивает количество рассматриваемых проектных решений и замедляет ранние этапы проектирования, особенно в задачах зелёных технологий, где критически важны энергоэффективность, безопасность и надёжность [3].

Особую актуальность данная проблема приобретает при проектировании систем охлаждения литий-ионных аккумуляторных батарей и теплового управления электролизёров зелёного водорода [3, 4]. Эффективность таких систем во многом определяется качеством инженерных решений, принимаемых на ранних стадиях разработки.

Существующие подходы в области генеративного проектирования и интеллектуальной оптимизации имеют ряд ограничений: отсутствие единого замкнутого цикла проектирования, слабая интеграция строгих физических моделей с адаптивными алгоритмами оптимизации, высокая вычислительная стоимость и недостаточная ориентированность на задачи устойчивой энергетики [5–7].

Настоящая работа посвящена разработке интеллектуальной платформы генеративного проектирования мультифизических систем на основе физически-информированных нейронных сетей и обучения с подкреплением [8–11]. Предлагаемый подход ориентирован на автоматизацию ранних этапов проектирования и оптимизацию систем охлаждения литий-ионных батарей и электролизёров зелёного водорода при сохранении физической достоверности результатов.

Постановка задачи

Целью исследования является разработка и экспериментальная апробация интеллектуальной платформы для генеративного проектирования и оптимизации мультифизических инженерных систем на ранних этапах их разработки.

Для достижения поставленной цели была проведена декомпозиция на следующие задачи:

- 1) анализ современного состояния и ограничений существующих методов генеративного проектирования и оптимизации;
- 2) разработка архитектуры интеллектуальной платформы и математической постановки задачи;
- 3) реализация прототипа платформы и проведение вычислительных экспериментов на примере систем охлаждения литий-ионных аккумуляторных батарей и электролизёров зелёного водорода.

Теоретическая значимость исследования заключается в развитии подходов к интеграции физически-информированных нейронных сетей и методов обучения с подкреплением в едином контуре генеративного проектирования [8, 9]. Практическая значимость определяется возможностью применения разработанных методов и

прототипа платформы для ускорения создания высокоэффективных систем устойчивой энергетики [3, 4].

Формализация задачи интеллектуального генеративного проектирования инженерных систем

Задача интеллектуального генеративного проектирования мультифизических инженерных систем формулируется как многокритериальная задача условной оптимизации в многомерном пространстве проектных параметров.

Пусть $p \in R^n$ – вектор проектных параметров, включающий геометрические характеристики конструкции (внутренний радиус канала охлаждения r , толщину стенки δ , длину канала L и другие переменные).

Требуется найти оптимальный вектор параметров p^* , минимизирующий целевую функцию:

$$J(p) = w_1 \cdot \underline{T}(p) + w_2 \cdot \underline{P}(p) + w_3 \cdot \underline{\sigma}(p),$$

где $\underline{T}(p)$, $\underline{P}(p)$, $\underline{\sigma}(p)$ – нормированные значения максимальной температуры стенки, перепада давления и максимального эквивалентного напряжения соответственно, полученные из PINN-суррогатной модели; w_1 , w_2 , w_3 – весовые коэффициенты, отражающие относительную важность каждого критерия.

Ограничения задачи имеют вид:

$$T(p) \leq T_{max}, \quad \Delta P(p) \leq \Delta P_{max}, \quad \sigma(p) \leq \sigma_{доп}$$

где T_{max} , ΔP_{max} и $\sigma_{доп}$ – предельно допустимые значения, определяемые эксплуатационными требованиями и нормами безопасности.

Для решения данной задачи в работе разработан гибридный алгоритм оптимизации, сочетающий обучение с подкреплением (Proximal Policy Optimization) и эволюционные стратегии [12, 13]. Обучение с подкреплением обеспечивает адаптивное исследование пространства решений, а эволюционные методы повышают глобальную устойчивость поиска и снижают вероятность застревания в локальных оптимумах физически-информированных нейронных сетей. Такой подход позволяет учитывать сложные мультифизические взаимодействия (теплоперенос, гидродинамика, механика деформируемого твёрдого тела) без необходимости выполнения полного численного моделирования на каждой итерации оптимизационного цикла.

Исследование предметной области

Анализ современных решений позволяет выделить несколько основных направлений развития интеллектуальных систем проектирования.

Первое направление связано с развитием генеративного дизайна и топологической оптимизации в традиционных CAD/CAE-системах (Autodesk Fusion 360, Siemens NX, Altair Inspire) [5, 6]. Эти инструменты хорошо справляются с геометрической оптимизацией и позволяют учитывать некоторые производственные огра-

нения, однако практически не способны работать со сложными мультифизическими процессами и не обеспечивают строгой физической корректности получаемых решений.

Альтернативное направление представлено работами по созданию суррогатных моделей и применению геометрического глубокого обучения (Neural Concept Shape, Altair PhysicsAI, Ansys Discovery) [7, 14]. Такие подходы обеспечивают значительное ускорение расчётов, но страдают от фундаментального недостатка – отсутствия гарантии соблюдения физических законов за пределами обучающей выборки. Это особенно критично для задач зелёных технологий, где ошибки в тепловом или электрохимическом моделировании могут привести к перегреву батарей или снижению эффективности электролизёров.

Так же существует ещё одно направление, которое связано с физически-информированными нейронными сетями (PINN). Работы [8–10] демонстрируют высокий потенциал PINN для решения сопряжённых задач теплопереноса, гидродинамики и механики. Тем не менее, большинство существующих решений остаются на уровне отдельных библиотек и научных экспериментов и практически не интегрированы в полный цикл генеративного проектирования – от текстового описания требования до готовой оптимизированной конструкции.

Отдельную группу составляют исследования по применению обучения с подкреплением (RL) в инженерной оптимизации [12, 13]. Несмотря на успехи в адаптивном поиске оптимальных решений, такие подходы редко сочетаются с жёсткими физическими моделями и почти не используются для задач зелёных технологий, где требуется одновременный учёт тепловых, электрохимических и механических процессов.

Анализ существующих подходов показывает наличие существенного пробела [1, 5, 15]. Отсутствует интегрированная интеллектуальная система, которая одновременно обеспечивала бы естественный языковой интерфейс для постановки задачи, автоматическую генерацию параметрической геометрии, физически корректную оценку на основе PINN и адаптивную многокритериальную оптимизацию с помощью обучения с подкреплением [1, 16].

Особенно остро этот пробел проявляется при проектировании систем для устойчивой энергетики – систем охлаждения литий-ионных аккумуляторных батарей и электролизёров зелёного водорода, где требуется быстрый и надёжный учёт сложных многофизических взаимодействий на ранних стадиях разработки [3, 4].

Моделирование предметной области

В настоящей работе предложена интеллектуальная платформа генеративного проектирования многофизических систем, ориентированная на задачи зелёных технологий. Платформа построена по модульному принципу и представляет собой замкнутый итеративный цикл с обратной связью, позволяющий автоматически переходить от текстового описания требований инженера к оптимизированной параметрической модели конструкции.

Архитектура платформы состоит из четырёх основных взаимосвязанных модулей:

- модуль языкового интерфейса и агентной оркестрации – преобразует естественный язык в структурированные требования и координирует работу всех модулей с помощью фреймворка LangGraph;

- модуль генерации параметрической геометрии – создаёт параметрические и перспективно неявные (Neural Fields) модели конструкции на основе библиотеки CadQuery;

- модуль физической оценки – выполняет быстрый и физически корректный расчёт многофизических процессов с использованием physics-informed neural networks (PINN) на базе NVIDIA PhysicsNeMo;

- модуль оптимизации – гибридный оптимизатор, сочетающий обучение с подкреплением (PPO) и эволюционные стратегии для эффективного поиска компромиссных решений.

Архитектура платформы представлена на рис. 1.




Рис. 1. Диаграмма компонентов интеллектуальной платформы

Взаимодействие модулей организовано следующим образом: модуль оркестрации принимает требования, передаёт их в генератор геометрии, получает параметры конструкции, направляет их в PINN-модуль для физической оценки, а затем в оптимизатор, который генерирует новые параметры. Цикл повторяется

до достижения критериев сходимости. Такой подход позволяет значительно сократить количество итераций, традиционно выполняемых инженером вручную.

Предлагаемая архитектура отличается от существующих решений интеграцией строгой физической корректности (PINN) с адаптивной оптимизацией (RL) и естественным языковым интерфейсом в едином контуре. Это позволяет применять платформу для сложных многофизических задач зелёных технологий, где традиционные методы сталкиваются с высокой вычислительной сложностью.

Аспекты информационной безопасности платформы

Разработка интеллектуальной платформы AetherForge осуществляется в рамках концепции DevSecOps, что подразумевает интеграцию требований информационной безопасности на всех этапах жизненного цикла системы – от проектирования архитектуры до эксплуатации.

В рамках реализации платформы обеспечивается:

- полная трассируемость всех проектных решений и действий агентов, что позволяет проводить аудит и верификацию корректности сгенерированных конструкций;
- защита от генерации небезопасных решений путём встраивания дополнительных ограничений безопасности в reward-функцию и систему правил оркестратора;
- защита интеллектуальной собственности и конфиденциальности проектных данных за счёт локального выполнения всех вычислений и возможности использования приватных моделей;
- устойчивость к атакам на ИИ-компоненты (инъекции промпта, адверсарные примеры) путём применения строгих промпт-инженерных практик и валидации входных данных;
- контроль целостности и воспроизводимости результатов за счёт фиксированных начальных состояний и логирования всех этапов оптимизационного цикла.

Такой подход позволяет не только решать инженерные задачи, но и гарантировать безопасность и надёжность самой платформы при её применении в критически важных отраслях, включая энергетику и аэрокосмическую промышленность.

Заключение

Предложенный в работе подход переводит задачу генеративного проектирования мультфизических систем из области традиционной параметрической оптимизации в постановку интеллектуального адаптивного моделирования. Научная новизна исследования заключается в интеграции следующего стека технологий: языкового интерфейса, параметрической генерации геометрии, физически информированных нейронных сетей (PINN) и гибридных алгоритмов оптимизации (RL + эволюционные стратегии) в едином замкнутом цикле [8–10, 12, 13].

В отличие от существующих решений, ориентированных либо на чисто геометрическую оптимизацию, либо на отдельное применение суррогатных моделей,

разрабатываемая платформа обеспечивает строгую физическую корректность решений на уровне уравнений в частных производных при сохранении высокой адаптивности поиска оптимальных конфигураций.

В дальнейшем разработанный метод и прототип платформы могут служить основой для полноценных экспериментальных исследований, масштабирования на более сложные объекты, а также интеграции в реальные инженерные процессы предприятий энергетического и транспортного секторов.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Matusik W., Liu J., Zhang Y. Large Language Models for Computer-Aided Design: A Survey and Outlook // *Computer-Aided Design*. 2024. Vol. 178. 103456.
2. Sharma A., Gupta R., Singh P. Physics-Informed Neural Networks in Aerospace Engineering: Applications and Challenges // *Aerospace Science and Technology*. 2025. Vol. 156. 109812.
3. Karniadakis G.E., Kevrekidis I.G., Lu L. et al. Physics-informed machine learning // *Nature Reviews Physics*. 2021. Vol. 3. P. 422–440.
4. Cuomo S., Di Cola V.S., Giampaolo F. et al. Scientific machine learning through physics-informed neural networks: Where we are and what's next // *Journal of Scientific Computing*. 2022. Vol. 92. 88.
5. 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. Vol. 378. P. 686–707.
6. Brunton S.L., Noack B.R., Koumoutsakos P. Machine learning for fluid mechanics // *Annual Review of Fluid Mechanics*. 2020. Vol. 52. P. 477–508.
7. Liu J., Matusik W. Learning generative models for parametric CAD // *ACM Transactions on Graphics*. 2020. Vol. 39. No. 6. 185.
8. Banga S., Geers M., van der Meer F. 3D topology optimization using deep learning // *Nature Machine Intelligence*. 2022. Vol. 4. P. 112–121.
- Willard J., Jia X., Xu S. et al. Integrating physics-based modeling with machine learning: A survey // *Nature Reviews Physics*. 2022. Vol. 4. P. 157–175.
9. Goswami S., Kontolati K., Shields M.D. et al. Physics-informed neural networks for surrogate modeling // *Computer Methods in Applied Mechanics and Engineering*. 2022. Vol. 390. 114464.
10. Chen Z., Zhang H. RL-PINNs: Reinforcement Learning-Driven Adaptive Sampling for Physics-Informed Neural Networks // *Computer Methods in Applied Mechanics and Engineering*. 2024. Vol. 418. 116512.
11. Tang Y., Daoutidis P. Physics-informed reinforcement learning for process control // *AIChE Journal*. 2023. Vol. 69. No. 4. e17958.
12. Degraeve J., Felici F., Buchli J. et al. Magnetic control of tokamak plasmas through deep reinforcement learning // *Nature*. 2022. Vol. 602. P. 414–419.
13. Pfaff T., Fortunato M., Sanchez-Gonzalez A. et al. Learning mesh-based simulation with graph networks // *International Conference on Machine Learning (ICML)*. 2021. P. 8459–8468.
14. Rackauckas C., Ma Y., Martensen J. et al. Universal differential equations for scientific machine learning // *arXiv preprint arXiv:2001.04385*. 2020.
15. Kochkov D., Smith J.A., Alieva A. et al. Machine learning-accelerated computational fluid dynamics // *Proceedings of the National Academy of Sciences*. 2021. Vol. 118. No. 21. e2101784118.
16. Thuerey N., Weissenow K., Prantl L. et al. Deep learning methods for Reynolds-averaged Navier–Stokes simulations // *Journal of Fluid Mechanics*. 2020. Vol. 886. A17.

© И. И. Захаренко, Д. С. Худяков, 2026