

Анализ подходов к моделированию потока в центробежном компрессоре с использованием алгоритмов машинного обучения

Николаев Н.С.¹

Научный руководитель – канд. техн. наук, доцент Кожухов Ю.В.¹

¹Университет ИТМО

nnikolaev@itmo.ru

Введение

Центробежные компрессоры (ЦК) являются важнейшими компонентами систем транспортировки природного газа и холодильных установок. Точное прогнозирование параметров пространственного потока — скорости, давления, температуры, числа Маха — важно для оптимизации конструкции, оценки запаса прочности и работы с цифровым двойником. Текущий стандартный инструмент, вычислительная гидродинамика Навье-Стокса с усреднением по Рейнольдсу (RANS), достигает точности 1-3 %, но в зависимости от сложности геометрических параметров и требований к модели турбулентности требует от нескольких часов до недель на моделирование [1].

Применение алгоритмов машинного обучения (ML) вызвано необходимостью ускорения и увеличения точности расчетов для проектирования ЦК. Научным сообществом были продемонстрированы четыре основные парадигмы: суррогаты на основе CNN, достигающие $MAE^1 < 1\%$ при ускорении вычислений в 10^2 раза [2,3]; графовые нейронные сети (GNN), обучающиеся на неструктурированных 3D-сетках [4,5]; нейронные операторы Фурье (FNO), независимые от разрешения сетки при $MSE^2 \approx 10^{-4}$ и ускорении до 10^3 [6]; основанные на физике нейронные сети (PINNs), встраивающие уравнения Навье-Стокса в функцию потерь [7,8]; В частности, в турбомашиностроении эти подходы были применены для прогнозирования полей расходов в осевых и центробежных компрессорах.

Однако систематический сравнительный анализ, применительно к центробежным компрессорам в системах газоснабжения, и интеграция ML с существующими решателями CFD остаются открытыми проблемами.

Основная часть

Было проведено сравнение четырех парадигм ML для моделирования потока в центробежном компрессоре.

Сверточные нейронные сети (CNN) с многомасштабными механизмами внимания преобразуют геометрические параметры (в виде структурированных сеток) и граничные условия в поля полного потока. Механизм внимания улавливает пространственные корреляции, критически важные для распространения ударных волн. На структурированных сетках суррогаты CNN достигают средней абсолютной ошибки (MAE) ниже 1% по сравнению с эталонными данными CFD, одновременно ускоряя прогнозирование примерно на три порядка. Подход CNN в настоящее время является наиболее развитым в промышленном применении [2,3].

Графовые нейронные сети (GNN) в которых узлы соответствуют вершинам сетки, а ребра задают связность граней, подходят для произвольных неструктурированных сеток. Это делает суррогаты GNN предпочтительными для сложных трехмерных геометрий рабочего колеса и диффузора. Точность несколько ниже (MAE 5–10 %), что отражает большую геометрическую общность. Ускорение моделирования в 100–500 раз [4,5].

¹ MAE — Mean absolute error (Средняя абсолютная ошибка)

² MSE — Mean squared error (Среднеквадратическая ошибка)

Ключевым преимуществом нейронных операторов Фурье (FNO) является независимость от разрешения сетки. FNO, обученный на грубой сетке, способен моделировать поток на более точной сетке того же семейства геометрии. Это свойство важно для параметрического проектирования, где геометрические параметры компрессора постоянно изменяются. FNO достигает MSE порядка 10^{-4} с ускорением в 1000–10000 раз, что делает его самой быстрой оцененной архитектурой. Текущие ограничения включают чувствительность к сильно неперiodическим областям и необходимость в структурированных [6].

Нейронные сети, основанные на физике (PINN), встраивают уравнения Навье-Стокса непосредственно в функцию потерь посредством автоматического дифференцирования, сохраняя при этом физическую обоснованность моделирования потока. Поля потока реконструируются на основе измерений скорости и давления. PINN достигают MAE 1-5 % при числах Рейнольдса до среднего 10^5 с ускорением вычислений в 40–100 раз, но сходимость обучения заметно ухудшается при числах Рейнольдса выше 10^5 [7,8].

Последние исследования в области применения алгоритмов машинного обучения для моделирования потока в центробежном компрессоре опираются на гибридную стратегию интеграции ML-CFD. Во-первых, модели турбулентности, дополненные ML — в частности, поправки нейронных сетей к уравнениям переноса вихревой вязкости — используются для устранения неточностей RANS в области безлопастного диффузора компрессоров с высокой степенью сжатия. Во-вторых, модели уравнения состояния. ML заменяют итеративный поиск корней для реального газа, что особенно актуально для приложений сжатия природного газа, где уравнения состояния, требуют больших затрат для оценки в каждой ячейке сетки и на каждой итерации.

Выводы

В ходе обзора и анализа применения алгоритмов ML для прогнозирования поля в центробежных компрессорах было выявлено, что CNN на структурированных сетках обеспечивают высокую точность и представляют собой наиболее проверенный в промышленности подход. GNN на неструктурированных сетках предлагают наибольшую геометрическую обобщенность. FNO подходят для параметрического исследования проектирования, где необходимо оценить тысячи вариантов геометрических параметров PINN наиболее подходят для обратных задач и сценариев с ограниченным объемом данных, обеспечивая при этом физическую согласованность моделирования.

Предполагается, что гибридное моделирование ML-CFD является наиболее практичным направлением развития, сочетающим в себе баланс между гарантированной физической согласованностью RANS и вычислительной экономией обученных моделей.

Литература

1. Blazek J. Computational Fluid Dynamics: Principles and Applications: Third Edition // Computational Fluid Dynamics: Principles and Applications: Third Edition. 2015.
2. Gao G., Wang G. A deep neural network with attention mechanism for flow prediction of compressor blade // Sci. Rep. Nature Publishing Group UK London, 2025. Т. 15, № 1. С. 16336.
3. Owens K. L. и др. Computational Fluid Dynamics Surrogate Based on Convolutional Neural Networks for Design Space Exploration // AIAA SCITECH 2024 Forum. 2024. С. 0252.
4. Zhao R. и др. A two-stage CFD-GNN approach for efficient steady-state prediction of urban airflow and airborne contaminant dispersion // Sustain. Cities Soc. Elsevier, 2024. Т. 112. С. 105607.
5. Ahangarkiasari M., Pouraria H. Multi-Stage Graph Neural Networks for Data-Driven Prediction of Natural Convection in Enclosed Cavities // arXiv preprint arXiv:2509.06041. 2025.
6. Li Z. и др. Fourier neural operator for parametric partial differential equations // arXiv preprint arXiv:2010.08895. 2020.
7. Jnini A. и др. Physics-constrained deepnet for surrogate cfd models: a curved backward-facing step case // arXiv preprint arXiv:2503.11196. 2025.
8. Cai S. и др. Physics-informed neural networks (PINNs) for fluid mechanics: A review // Acta Mechanica Sinica. Springer, 2021. Т. 37, № 12. С. 1727–1738.