

DOI: 10.51790/2712-9942-2022-3-1-6

## УТОЧНЕНИЕ ПОЛЯ ТЕЧЕНИЯ С ПОМОЩЬЮ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ ВНЕШНЕЙ АЭРОДИНАМИКИ

С. В. Зими́на<sup>а</sup>, М. Н. Петро́в<sup>б</sup>

Московский физико-технический институт (национальный исследовательский университет),  
г. Долгопрудный, Российская Федерация

<sup>а</sup> sofya.zimina@phystech.edu

<sup>б</sup> mikhail.petrov@phystech.edu

*Аннотация:* численное моделирование турбулентных течений около тел различной конфигурации является вычислительно затратным, особенно при проведении серийных расчетов, и требует нахождения баланса между скоростью и точностью вычислений. Целью работы является построение оператора, уточняющего результаты расчета, полученные менее точной вычислительно эффективной моделью, на основании расчетов схожих течений, полученных с помощью более точной базовой модели, с помощью методов машинного обучения. В качестве уточняемой модели был использован метод приближенной пристенной декомпозиции (ANDD) для модели Спаларта–Аллмараса, в качестве базовой модели — модель Спаларта–Аллмараса. В данной работе задача решена в нелокальной постановке, то есть учитывается влияние всего поля течения на ошибку в конкретной его точке. Оператор перехода от уточняемой модели к базовой строится с помощью сверточных нейронных сетей (CNN) архитектуры энкодер-декодер. Эффективность и точность построенной суррогатной модели демонстрируется на примере двумерной задачи сверхзвукового турбулентного обтекания угла сжатия при различных величинах угла сжатия и числах Рейнольдса (рассмотрены задачи интерполяции и экстраполяции по  $Re$ , а также интерполяции и экстраполяции по величине угла сжатия  $\alpha$ ).

*Ключевые слова:* сверточные нейронные сети, пристенная декомпозиция, турбулентные течения.

*Для цитирования:* Зими́на С. В., Петро́в М. Н. Уточнение поля течения с помощью сверточных нейронных сетей в задачах внешней аэродинамики. *Успехи кибернетики*. 2022;3(1):44–48. DOI: 10.51790/2712-9942-2022-3-1-6.

## APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS TO FLOW FIELDS REFINING IN EXTERNAL AERODYNAMICS PROBLEMS

S. V. Zimina<sup>a</sup>, M. N. Petrov<sup>b</sup>

Moscow Institute of Physics and Technology (National Research University),  
Dolgoprudny, Russian Federation

<sup>a</sup> sofya.zimina@phystech.edu

<sup>b</sup> mikhail.petrov@phystech.edu

*Abstract:* the simulation of turbulent flows around objects is computationally expensive and requires a balance between accuracy and computational performance. The objective of this work is to construct an operator that would improve the result of a less accurate, but more computationally efficient model using simulation results for similar flows obtained by a slower but more accurate method. The Spalart-Allmaras model is used as the turbulence model. The approximate near-wall domain decomposition (ANDD) approach is used as the fast, less accurate model, while the one-block approach (without decomposition) is used as the baseline, more accurate model. In this work, the operator is constructed with a non-local approach, where the entire input flow field affects every point of the output flow field. The operator is constructed with a convolutional neural network (CNN) of an encoder-decoder architecture. The efficiency and accuracy of the obtained surrogate model are demonstrated with a supersonic flow over a compression corner with different angle  $\alpha$  and Reynolds number values. We considered interpolation and extrapolation both by  $Re$  and  $\alpha$ .

*Keywords:* convolutional neural network, approximate near-wall domain decomposition, turbulent flows.

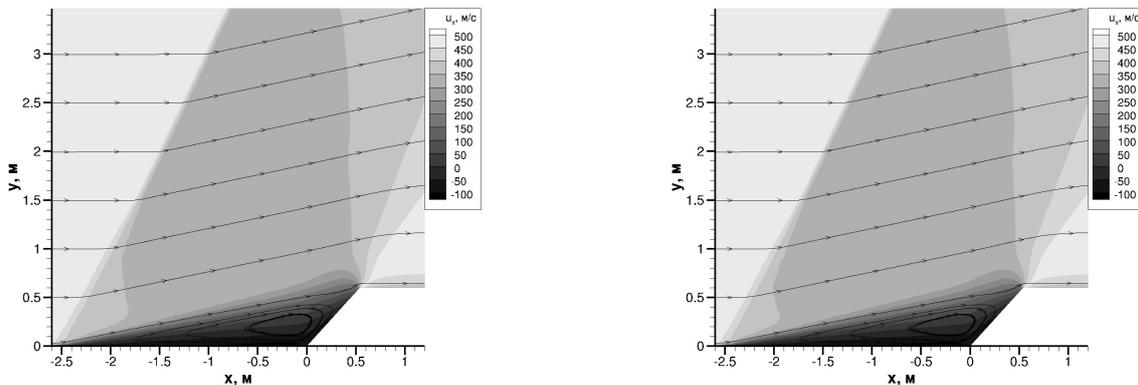
*Cite this article:* Zimina S. V., Petrov M. N. Application of Convolutional Neural Networks to Flow Fields Refining External Aerodynamics Problems. *Russian Journal of Cybernetics*. 2022;3(1):44–48. DOI: 10.51790/2712-9942-2022-3-1-6.

## Введение

В промышленности широко востребованы методы численного моделирования турбулентных течений. При этом для высокой точности расчета важно хорошее разрешение пограничного слоя, которое в некоторых задачах может занимать до 90 %. Разработаны специальные модели, к примеру RANS-модели с использованием пристеночных функций [1] или модели, основанные на методах декомпозиции расчетной области [2, 3], которые являются более вычислительно эффективными по сравнению с базовыми моделями, однако могут существенно проигрывать им в точности. Хотя для некоторых таких моделей, например для метода приближенной пристенной декомпозиции (ANDD) [4], потери в точности проявляются лишь локально и не затрагивают общую физику течения. Одним из путей построения одновременно вычислительно эффективной и точной модели может быть построение суррогатной модели с использованием методов машинного обучения.

Применение методов машинного обучения к задачам газовой динамики стремительно набирает популярность. Так, в работе [5] строится модель, уточняющая результаты расчетов на грубой сетке по результатам расчетов задач того же класса на более подробной сетке. Это позволяет локально скорректировать переменные поля течения на ошибку, вызванную огрублением сетки. Алгоритм строится на основании фактической разницы между переменными признакового пространства приближенного и точного решений. Также проводятся исследования по более глубокой адаптации суррогатной модели к задаче. Например, непосредственный учет дифференциальных уравнений, описывающих задачу, в архитектуре нейросети [6] или геометрии рассматриваемой области [7].

В работе с помощью методов машинного обучения предлагается построить суррогатную модель, уточняющую результаты расчетов, полученных специальной (менее точной) моделью, на основании данных расчетов, полученных для схожего класса задач в рамках базовой (более точной) модели. Построенная таким образом суррогатная модель позволит улучшить точность расчётов при сохранении преимуществ по вычислительной эффективности.



**Рис. 1.** Поле компоненты скорости  $v_x$  для задачи с  $\alpha = 132^\circ$ ,  $Re = 10^7$  для базовой одноблочной модели (слева) и уточняемой модели ANDD (справа)

## Идея построения суррогатной модели

В предлагаемом в статье подходе при проведении серии из  $N$  расчетов малое число расчетов  $m$  проводится как базовой, так и специальной моделью и используется для обучения суррогатной модели. Оставшиеся  $N - m$  расчетов серии проводятся быстрой специальной моделью и уточняются суррогатной моделью. При построении суррогатной модели нелокальным методом предполагается использование нейронной сети, предобученной на большом числе различных полей течения с последующим дообучением под конкретную задачу на малом объеме данных.

Общая методология, рассматриваемая в статье, может быть применена к любой паре выбранных специальной и базовой модели. В исследовании в качестве базовой модели используется модель

Спаларта–Аллмараса [8], решение для которой получается на подробной сетке с хорошим разрешением пристенной области. В качестве специальной (уточняемой) модели используется метод ANDD [4] для модели Спаларта–Аллмараса, так как дает достаточно хорошее решение для лучшего обучения суррогатной модели. Суть метода ANDD заключается в разделении расчетной области на внутреннюю пристенную и внешнюю область. При этом во внутренней области решаются уравнения тонкого слоя (TBLе). Во внешней области решаются полные уравнения с граничным условием третьего рода на границе сопряжения областей. Далее выполняется пересчет поля течения во внутренней области с использованием граничного условия Дирихле на границе между областями, полученного из решения задачи во внешней области. Вышеперечисленные шаги выполняются до выполнения условия сходимости. Одним из преимуществ данного метода является высокая скорость сходимости расчетов. Все расчеты проведены на основе имеющегося кода лаборатории Flowmodellium [9] для решения пространственных уравнений Навье–Стокса на неструктурированных сетках.

### Построение суррогатной модели нелокальным методом

Для построения суррогатной модели используется нейронная сеть архитектуры энкодер–декодер. Используемая архитектура схожа с архитектурой нейросети-генератора, использованной в работе [10], но имеет ряд отличий, описанных ниже. Как и генератор из работы, используемая архитектура включает residual-блоки [11], позволяющие бороться с проблемой затухания градиентов. К другим особенностям архитектуры относятся: сквозные соединения между энкодером и декодером, позволяющие при генерации выходного изображения лучше учитывать признаки, выделенные каждым слоем энкодера; механизм self-attention [12] для лучшего учета пространственных зависимостей. Последний слой сети представляет собой сглаживание по ближайшим соседям с обучаемыми весами.

В качестве входных данных и целевой переменной для обучения суррогатной модели используется все поле течения, при этом нейронная сеть обучается предсказывать результат расчета базовой модели, получая на вход результаты расчета приближенной модели. Так как расчетная сетка в рассматриваемой задаче структурированная, входные данные можно представить в виде матрицы с размерами  $(w, h, c)$ , где  $w, h$  — размеры расчетной сетки,  $c$  — число признаков переменных. Исследуемыми переменными в работе являются компоненты скорости  $v_x, v_y$ . С целью повышения значимости ошибки в пристенной области, являющейся областью наибольшего интереса, применяется логарифмирование, и в качестве признаков переменных используются нормированные логарифмы модуля скорости  $(\ln(|v_x| + 1)/(\ln(|\max(v_x)| + 1)), \ln(|v_y| + 1)/(\ln(|\max(v_y)| + 1)))$ , а также безразмерное расстояние от стенки  $l/\max(l)$ .

В качестве функции потерь при обучении нейронной сети используется средняя абсолютная ошибка (MAE), в качестве оптимизатора — Adam.

### Результаты

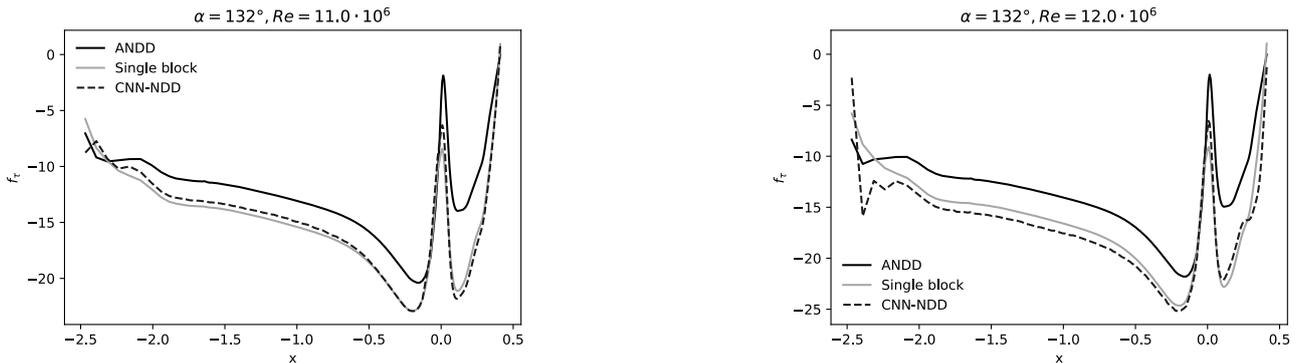
Оператор перехода от уточняемой модели к базовой строится на примере двумерной задачи сверхзвукового турбулентного обтекания угла сжатия с числом Маха  $M = 1.5$  при различных числах Рейнольдса  $Re$  и величине угла сжатия  $\alpha$ . На рисунке 1 показаны поля компоненты скорости  $v_x$  для задачи с  $Re = 10^7$ ,  $\alpha = 132^\circ$ , рассчитанные с помощью базовой одноблочной модели и менее точной модели ANDD. При расчете методом ANDD граница между внутренней и внешней областью находится на расстоянии от стенки, соответствующем  $y^+ \approx 100$ .

Была проведена серия расчетов с одинаковой геометрией ( $\alpha = 132^\circ$ ), отличающихся параметрами набегающего потока ( $M = 1.5, Re \in [8 \cdot 10^6; 1.3 \cdot 10^7]$ ), а также серия расчетов с одинаковыми параметрами набегающего потока, но разной геометрией обтекаемого тела ( $\alpha \in [124^\circ; 144^\circ]$ ). Каждый расчет был проведен с помощью базовой модели и с помощью специальной модели (ANDD). Далее результаты расчетов были поделены на обучающую и тестовую выборку. При этом были рассмотрены сценарии интерполяции и экстраполяции по числу Рейнольдса (для серии расчетов с одинаковой геометрией), а также сценарии интерполяции и экстраполяции по величине угла  $\alpha$  (для серии расчетов с одинаковыми параметрами набегающего потока).

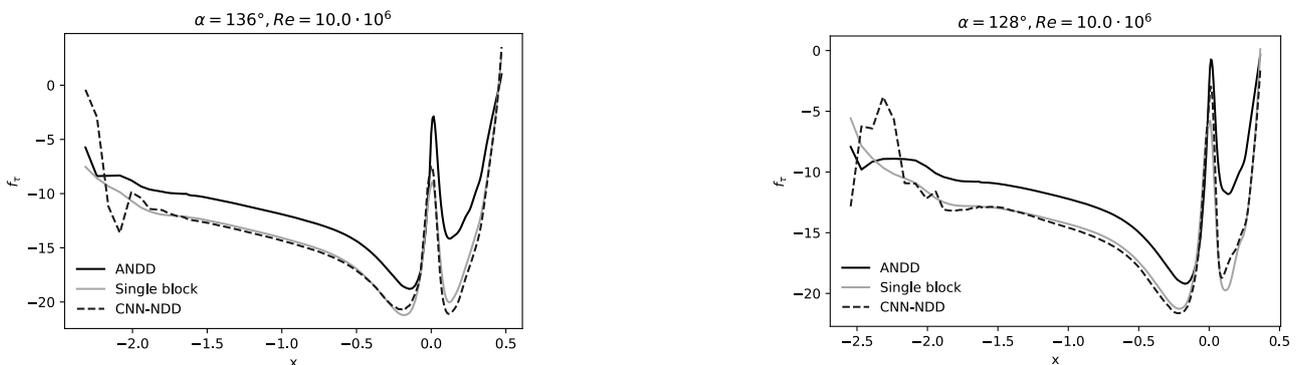
На основании полученных компонент поля скорости  $v_x, v_y$  рассчитывались трение на стенке  $f_\tau$  и коэффициент трения  $C_f$ . При расчете коэффициента трения интегрирование проводилось по части стенки, соответствующей области, где находится вихрь ( $x \in [-2.5, 0.5]$ ). Полученные с помощью суррогатной модели результаты для тестовой выборки сравнивались с результатами одноблочного расчета

и расчета методом ANDD. На рисунках 2–3 показано трение на стенке  $f_\tau$ , рассчитанное с помощью базовой, уточняемой и суррогатной модели для всех описанных выше сценариев. В таблице показаны коэффициенты трения  $C_f$  для базовой, уточняемой и суррогатной модели, а также относительная ошибка  $\varepsilon$ .

Из графиков и таблицы видно, что даже при обучении нейросети с нуля на малом числе данных метод показывает достаточно неплохие результаты. Построенный оператор уточняет результат расчета, проведенного по приближенной модели, с достаточно высокой точностью, особенно для задач интерполяции и экстраполяции по числу Рейнольдса. Для задач экстраполяции в топологическом случае метод дает более плохие результаты, чем для всех остальных сценариев, однако ошибка в интегральной характеристике — коэффициенте трения  $C_f$  все еще меньше, чем для расчетов, проведенных по приближенной модели ANDD.



**Рис. 2.** Трение на стенке для задач интерполяции (слева) и экстраполяции (справа) по числу Рейнольдса  $Re$ . Результаты для базовой модели (Single block), уточняемой модели (ANDD) и результат уточнения (CNN-NDD)



**Рис. 3.** Трение на стенке для задач интерполяции (слева) и экстраполяции (справа) по величине угла  $\alpha$ . Результаты для базовой модели (Single block), уточняемой модели (ANDD) и результат уточнения (CNN-NDD)

Таблица

Коэффициенты трения  $C_f$  для базовой модели (Single block), уточняемой модели (ANDD) и уточненной модели (CNN-NDD), а также относительная ошибка  $\varepsilon$

Сценарий	$C_f \cdot 10^{-4}$			$\varepsilon$	
	Single Block	ANDD	CNN-NDD	ANDD	CNN-NDD
1) Интерполяция по $Re$	−3.24	−2.64	−3.2	0.1849	0.0115
2) Экстраполяция по $Re$	−3.19	−2.6	−3.32	0.1841	0.04
3) Экстраполяция по $Re$	−3.35	−2.71	−3.59	0.1891	0.0731
4) Интерполяция по $\alpha$	−3.35	−2.74	−3.32	0.1822	0.009
5) Экстраполяция по $\alpha$	−3.32	−2.71	−3.25	0.1822	0.0213
6) Экстраполяция по $\alpha$	−3.15	−2.59	−3.43	0.1757	0.0877

### Заключение

В работе был рассмотрен нелокальный метод построения оператора, уточняющего результаты расчетов. На примере задачи сверхзвукового турбулентного обтекания угла сжатия было рассмотрено несколько сценариев: интерполяция и экстраполяция по числу Рейнольдса (при одинаковой геометрии), а также топологический случай: интерполяция и экстраполяция по величине угла сжатия  $\alpha$ . Для каждого из сценариев результаты уточняющей суррогатной модели оказались достаточно близки к результатам, полученным с помощью более точной базовой модели. При этом были получены неплохие результаты даже при обучении модели на малом количестве данных с нуля. При проведении серии из  $N$  расчетов число расчетов  $m$ , которые проводятся как уточняемой, так и базовой моделью и используются для обучения модели, достаточно мало, а остальные  $N - m$  расчетов проводятся только с помощью быстрой уточняемой модели, что подтверждает вычислительную эффективность метода.

### ЛИТЕРАТУРА

1. Grotjans H., Menter F. R. Wall Functions for Industrial Applications. *Computational Fluid Dynamics*. 1998;98(1):2.
2. Utyuzhnikov S., Petrov M., Chikitkin A., Titarev V. On Extension of Near-Wall Non-overlapping Domain Decomposition to Essentially Unsteady Turbulent Flows. *Smart Modeling for Engineering Systems: Proceedings of the Conference 50 Years of the Development of Grid-Characteristic Method*. 2019;133:199. Springer. DOI: 10.1007/978-3-030-06228-6\_17.
3. Chikitkin A., Utyuzhnikov S., Petrov M., Titarev V. Non-Overlapping Domain Decomposition for Modeling Essentially Unsteady Near-Wall Turbulent Flows. *Computers & Fluids*. 2020;202:104506. DOI: 10.1016/j.compfluid.2020.104506.
4. Petrov M., Utyuzhnikov S., Chikitkin A., Titarev V. On Extension of Near-Wall Domain Decomposition to Turbulent Compressible Flows. *Computers & Fluids*. 2020;210:104629. DOI: 10.1016/j.compfluid.2020.104629.
5. Hanna B. N., Dinh N. T., Youngblood R. W., Bolotnov I. A. Machine-Learning Based Error Prediction Approach for Coarse-Grid Computational Fluid Dynamics (CG-CFD). *Progress in Nuclear Energy*. 2020;118:103140. DOI: 10.1016/j.pnucene.2019.103140.
6. 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;378:686–707. DOI: 10.1016/j.jcp.2018.10.045.
7. Guo X., Li W., Iorio F. Convolutional Neural Networks for Steady Flow Approximation. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016;481–490. DOI: 10.1145/2939672.2939738.
8. Spalart P. R., Allmaras S. R. 30th Aerospace Sciences Meeting and Exhibit. *Aerospace Sciences Meetings. American Institute of Aeronautics and Astronautics, Reston, VA*. 1992. DOI: 10.2514/6.1992-439.
9. Petrov M. N., Tambova A. A., Titarev V. A., Utyuzhnikov S. V., Chikitkin A. V. FlowModellium Software Package for Calculating High-Speed Flows of Compressible Fluid. *Computational Mathematics and Mathematical Physics*. 2018;58(11):1865–1886. DOI: 10.1134/S0965542518110118.
10. Zhu J. Y., Park T., Isola P., Efros A. A. Unpaired Image-To-Image Translation Using Cycle-Consistent Adversarial Networks. *Proceedings of the IEEE International Conference on Computer Vision*. 2017;2223–2232.
11. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016;770–778.
12. Zhang H., Goodfellow I., Metaxas D., Odena A. Self-Attention Generative Adversarial Networks. *International Conference on Machine Learning*. 2019;7354–7363.