

ИНФОРМАТИКА, МОДЕЛИРОВАНИЕ И УПРАВЛЕНИЕ

Научная статья

УДК 004.89

URL: <https://trudymai.ru/published.php?ID=186314>

EDN: <https://www.elibrary.ru/QJKQWW>

РАСЧЕТ АЭРОДИНАМИЧЕСКОГО НАГРУЖЕНИЯ ПРОФИЛЯ МЕТОДОМ ВИХРЕВЫХ ЭЛЕМЕНТОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Никита Дмитриевич Каменев^{1✉}, Георгий Александрович Щеглов²

ФГБОУ ВО «Московский государственный технический университет имени Н.Э.
Баумана (национальный исследовательский университет)»

Москва, Россия

¹physicorym@gmail.com

²✉shcheglov_ga@bmstu.ru

Аннотация. Исследуется перспектива использования предварительно обученной искусственной нейронной сети в методе вихревых элементов для восстановления поля скоростей на основе известного распределения точечных вихрей. Рассматриваются модели типа ResNet, U-Net и Attention U-Net. Кроме того, рассмотрен метод расчета аэродинамических нагрузок на основе расположения вихрей. Представлены результаты решения тестовой задачи о профиле крыла, обтекаемого плоскопараллельным потоком невязкой несжимаемой среды. Проанализированы преимущества в ускорении вычислений и оценена погрешность полученных результатов. Показано, что использование нейросетевых моделей для

одновременного решения двух взаимосвязанных задач — прогнозирования изображения вихревого следа и прогнозирования аэродинамических нагрузок с использованием общей функции погрешности - привело к значительному повышению точности модели. Такая совместная оптимизация позволяет модели лучше улавливать ключевые зависимости в данных и более эффективно проводить обучение. Прогнозирование вихревого следа улучшает пространственное восприятие динамики потока, в то время как прогнозирование нагрузки помогает модели фиксировать важные закономерности. Использование функции общей ошибки объединяет эти два процесса, что позволяет модели одновременно улучшать свои возможности как в сегментации вихревого следа, так и в прогнозировании аэродинамических нагрузок. В результате модель становится более информативной и точной, поскольку ее можно обучить на дополнительных сигналах и корреляциях, что привело к улучшению показателей RMSE и DICE. Анализ производительности показал, что оптимизированные для OpenVINO модели на процессорах Intel обеспечивают баланс между скоростью и точностью вычислений, сохраняя при этом приемлемое качество прогноза на коротких временных интервалах.

Ключевые слова: метод вихревых элементов, вычислительная гидродинамика, плоскопараллельное течение, профиль крыла, искусственная нейронная сеть, ResNet, U-Net, Attention U-Net.

Для цитирования: Каменев Н.Д., Щеглов Г.А. Расчет аэродинамического нагружения профиля методом вихревых элементов с использованием нейронных сетей // Труды МАИ. 2025. № 144. URL: <https://trudymai.ru/published.php?ID=1863134>

Original article

**AIRFOIL AERODYNAMIC LOADS CALCULATION BY VORTEX ELEMENT
METHOD USING NEURAL NETWORKS**

Nikita Kamenev N.D¹, Shcheglov G.A.^{2✉}

«Bauman Moscow State Technical University»

Moscow, Russia

E-mail: physicorym@gmail.com

¹physicorym@gmail.com

²✉shcheglov_ga@bmstu.ru

Abstract. The prospect of using a pre-trained artificial neural network in vortex element method to reconstruct velocity fields based on the known distribution of point vortices is investigated. Models such as ResNet, U-Net and Attention U-Net are considered. In addition, the method of calculating the aerodynamic loads on the basis of the obtained vortices is considered. The results of the solution of a test problem on the wing profile flowing with a plane-parallel flow of a inviscid incompressible fluid are presented. The advantages in acceleration of calculations are analyzed and the error of the obtained results is estimated. It is shown that the use of neural network models to simultaneously solve two interrelated tasks — predicting the image of vortex wake and predicting aerodynamic loads using a common error function led to a significant improvement in the accuracy of the model. These collaborative optimization allows the model to better capture key

dependencies in the data and learn more efficiently. Vortex wake prediction improves spatial perception of flow dynamics, while load prediction helps the model capture important patterns. The use of a common error function combines these two processes, which allows the model to simultaneously improve its abilities both in segmentation of vortex wake and in predicting aerodynamic loads. As a result, the model becomes more informative and accurate, as it can be trained on additional signals and correlations, which led to improvements in the RMSE and DICE metrics. Performance analysis showed that OpenVINO-optimized models on Intel CPUs provide a balance between computing speed and accuracy, while maintaining acceptable forecast quality over short time intervals.

Keywords: vortex element method, computational fluid dynamics, airfoil, 2D flow, artificial neural network, ResNet, U-Net, Attention U-Net.

For citation: Nikita Kamenev N.D, Shcheglov G.A. Airfoil aerodynamic loads calculation by vortex element method using neural networks // Trudy MAI. 2025. No. 144. (In Russ.)

URL: <https://trudymai.ru/published.php?ID=186314>

Введение

Вихревые методы вычислительной гидродинамики активно используются для определения нестационарных аэрогидродинамических нагрузок при решении инженерных задач, в которых элементы машин взаимодействуют с потоком среды, которую можно условно считать несжимаемой [1]. Подобные задачи возникают при проектировании летательных и подводных аппаратов, энергетических установок [2, 3, 4] а также в рамках развития технологий возобновляемых источников

энергии [5, 6]. Данные методы: метод дискретных вихрей, метод вихревых элементов, метод вихревых петель оказываются весьма удобны для решения задач аэроупругости, поскольку не требуют построения расчетной сетки в области течения [7]. В этих методах, в качестве носителей первичной величины завихренности, используются лагранжевы частицы, вихревые элементы (ВЭ). По известным положению и интенсивности данных частиц в процессе расчета с использованием интеграла Био-Савара и аналога интеграла Коши-Лагранжа восстанавливаются поля скоростей и давления. В ходе вычислений, для удовлетворения граничных условий, производится генерация ВЭ на обтекаемых поверхностях и размерность задачи существенно возрастает, что приводит к большим вычислительным затратам на восстановление полей, которые пропорциональны квадрату числа рассматриваемых ВЭ. Для сокращения объема вычислений в настоящее время разработаны специальные алгоритмы, так называемые «быстрые методы», например, метод Барнса-Хатта, метод мультипольных разложений и др. [8]. Однако актуальной задачей остается поиск новых подходов к ускорению вычислений. В последнее время, в рамках развития технологий Индустрии 4.0 для решения нелинейных задач механики большое развитие получили вычислительные технологии «искусственного интеллекта» на базе искусственных нейронных сетей [9-13]. По сути данные алгоритмы являются интегральными, суммирующими влияние множества вычислительных узлов-нейронов, что близко идеологии вихревых методов.

Был проведен анализ существующих решений в области вихревых методов. В работах [14, 15] авторы предлагают интеграцию физических уравнений и законов в

нейронные сети для улучшения процесса моделирования. Выводы статей указывают на перспективы использования физически обогащенных методов глубокого обучения в моделирование физических полей. Эти методы позволяют улучшить точность, эффективность и интерпретируемость моделей, а также предоставить новые возможности в анализе и оптимизации процессов.

В работе [16] цель исследования состоит в моделировании турбулентных потоков. Авторы предлагают комбинировать нейронные сети и вихревые методы для моделирования потоков над аэродинамическим профилем. Нейронные сети используются для предсказания коэффициентов турбулентной вязкости на основе доступных входных параметров, таких как скорость потока и геометрия профиля. Затем эти предсказания используются в вихревых методах. Авторы проводят численные эксперименты на различных аэродинамических профилях и сравнивают результаты гибридного подхода с традиционными методами. Авторы делают вывод, что данный подход может быть полезным для прогнозирования аэродинамических характеристик профилей, оптимизации дизайна и улучшения понимания физических процессов, связанных с турбулентными потоками в задачах аэродинамики.

В статье [17] авторы представляют решение задачи турбулентного обтекания цилиндра с использованием нейронной сети, основанной на уравнениях Навье-Стокса. Результаты исследования демонстрируют, что разработанная ими нейронная сеть, известная как PNS-PINN, обладает большей эффективностью в определении течений в условиях турбулентности.

1. Сбор данных

Для обучения нейронных сетей необходимо обладать достаточным объемом данных для обучения. В данном контексте была проведена серия расчетов методом вихревых элементов плоскопараллельного обтекания профиля крыла NASA0012. Была использована программа с открытым исходным кодом [VM2D](https://github.com/vortexmethods/VM2D)¹ в которой вязкость среды моделируется при помощи метода вязких вихревых доменов [18]. В ходе расчета варьировались различные входные параметры: угол атаки, изменялся в диапазоне от 0 до 16 градусов, скорость набегающего потока изменялась от 1 до 12 м/с. Всего было рассмотрено 80 различных случаев, которые затем могут быть использованы для обучения модели искусственной нейронной сети. Описание массива данных, полученных в результате расчетов, приведено в таблице 1.

Каждый расчетный случай в данном исследовании описывает переходный режим продолжительностью от 0 до 5 секунд. В течении этого временного интервала для каждой миллисекунды генерируется соответствующий файл результатов в формате [vtk](https://en.wikipedia.org/wiki/VTK)². В каждом из этих файлов для вихревых элементов, формирующих след за профилем содержатся текущие координаты x и y лагранжевых маркеров, а также значения интенсивности Γ . Количество вихревых элементов варьировалось от 1000 до 40000 на один файл [vtk](https://en.wikipedia.org/wiki/VTK). В общей сложности было сформировано 9000 файлов. Кроме этого в результате расчета переходного режима создается текстовый файл, содержащий с шагом в одну миллисекунду действующие на профиль интегральные аэродинамические нагрузки – подъемную силу Y и силу лобового сопротивления X (в данной работе индекс «а» у обозначения сил опущен поскольку другие виды сил не рассматриваются).

¹ <https://github.com/vortexmethods/VM2D>

² <https://github.com/Kitware/ParaView>

Таблица 1. Рассмотренные случаи для обучения модели

Угол атаки, градусов	Наборы скоростей, м/с
0	5,6,7,8
01	1,2,3,4
02	1,2,3,4,5,6,7,8
04	1,2,3,4
05	1,2,3,4
06	1,2,3,4
07	1,2,3,4
08	1,2,3,4,5,6,7,8,9,10,11,12
10	1,2,3,4,5,6,7,8,9,10,11,12
12	1,2,3,4,5,6,7,8
13	1,2,3,4
14	1,2,3,4
16	1,2,3,4
18	1,2,3,4

Далее все vtk-файлы были преобразованы в графический формат и сохранены в виде изображений PNG, каждое из которых представляет состояние потока в конкретный момент времени с шагом в одну миллисекунду. Эти изображения используются для обучения нейронной сети на этапе предсказания вихревых следов и связанных с ними аэродинамических нагрузок.

На рисунке 1 представлены три изображения, иллюстрирующие эволюцию вихревого следа за профилем крыла, сохранённые с временным шагом в одну миллисекунду.




Рисунок 1. Пример визуализации трех последовательных фаз (1, 2, 3) динамики вихревых следов с временным шагом в одну миллисекунду.

На основе полученных изображений планируется обучение двух различных моделей.

Первая модель предназначена для предсказания аэродинамических нагрузок вдоль осей X и Y на основе временных последовательностей изображений вихревых следов. Эта модель принимает на вход последовательности изображений вихревого следа с временным шагом в одну миллисекунду и предсказывает соответствующие аэродинамические нагрузки для каждого временного момента. Основной задачей этой модели является предсказание вектора аэродинамических нагрузок на профиль

крыла на основе текущего состояния вихревого следа. Модель использует временные последовательности изображений для решения задачи регрессии.

Вторая модель представляет собой U-Net, обучающуюся на тех же изображениях для предсказания следующего состояния вихревого следа во времени. Эта модель сегментации позволяет прогнозировать, как будут изменяться вихревые структуры в течение следующих временных шагов на основе текущих данных о потоке. Основной задачей U-Net является захват пространственно-временных зависимостей в структуре вихрей и предсказание их во времени.

Таким образом, обе модели используют одни и те же исходные данные - последовательности изображений вихревых следов, однако решают разные задачи: предсказание аэродинамических нагрузок и прогнозирование дальнейшего развития вихревого следа. Размеры входных и выходных тензоров различных моделей представлены в таблице 2.

Таблица 2. Подача данных.

Номер модели	Размер входного тензора	Размер выходного тензора
1	3x640x260	3x640x260
2	3x640x260	1x640x260
3	6x640x260	3x640x260
4	6x640x260	1x640x260

2. Предсказание нагрузок

Для предсказания аэродинамических нагрузок X и Y были обучены несколько моделей, включая собственную модель с восьмислойной архитектурой, а также предобученные модели ResNet18 и ResNet50 [19]. Каждая из моделей обучалась на основе последовательностей изображений вихревого следа, где на вход подавались два изображения с временным шагом в одну миллисекунду, а на выходе предсказывались нагрузки X и Y для последнего изображения из входной последовательности.

Кроме того, были рассмотрены варианты моделей с подачей на вход двух, трёх и шести изображений. Это позволяло оценить, как увеличение количества входных изображений, отражающих динамику течения за более продолжительный временной интервал, влияет на точность предсказаний.

Для оценки аэродинамических нагрузок X и Y была выбрана функция потерь среднеквадратической ошибки (MSE), которая определяется следующей формулой (1), где: y_i - истинные метки (бинарные маски сегментации), $\hat{y}_i$ - предсказания модели (вероятности принадлежности к классу), N - количество наблюдений:

$$MSE_{Loss}_{force}(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (1)$$

Для оценки погрешности предсказаний аэродинамических нагрузок X и Y используется метрика корня среднеквадратической ошибки (RMSE). RMSE позволяет количественно оценить разницу между истинными значениями и предсказанными моделью значениями. Данная метрика вычисляется по следующей формуле:

$$RMSE(y, \hat{y}) = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (2)$$

Для нормализации значений аэродинамических нагрузок перед расчетом метрики RMSE и вычислением функции потерь используется метод Min-Max нормализации. В частности, максимальные значения в данных составляют 85.8021 для нагрузки по оси X и 19.0298 для нагрузки по оси Y. Расчет проводится по следующей формуле:

$$y_{norm} = \frac{y - \min(Y)}{\max(Y) - \min(Y)} \quad (3)$$

где Y представляет собой все значения нагрузок

В таблице 3 представлены выбранные архитектуры, применяемые для решения задачи регрессии на основе визуальных представлений вихревых следов. Первые три модели представляют из себя разработанные архитектуры состоящие из восьми слоев. Остальные модели представляют из себя архитектуры ResNet.

Таблица 3. Варианты обучаемых моделей для предсказания нагрузок X и Y

Модель	Количество слоев	Количество входных изображений	Функция потерь	Погрешность по метрике RMSE
Собственная модель	8	2	MSE	0.478
Собственная модель	8	3	MSE	0.462
Собственная модель	8	6	MSE	0.458
ResNet18	18	2	MSE	0.347
ResNet18	18	3	MSE	0.344
ResNet18	18	6	MSE	0.335
ResNet50	50	2	MSE	0.342
ResNet50	50	3	MSE	0.34
ResNet50	50	6	MSE	0.336

На рисунках 2 и 3 представлены результаты сравнительного анализа прогнозируемых значений нагрузок по осям X и Y, полученных с использованием глубокой нейронной сети ResNet50, с эталонными данными, рассчитанными в программном комплексе VM2D.




Рисунок 2. Сравнение предсказанных значений нагрузки (модель ResNet50) по оси X с значениями, полученными в программе VM2D.




Рисунок 3. Сравнение предсказанных значений нагрузки (модель ResNet50) по оси Y с значениями, полученными в программе VM2D.

3. Предсказание вихревых следов

За основу нейронной сети для решения задачи предсказания вихревых следов взята архитектура U-Net [20]. Принцип работы сетей такого типа основан на архитектуре энкодер-декодер. Где энкодер служит для извлечения признаков из входного тензора размерностью $(512, 512, N)$, где N — количество изображений в последовательности (от 2 до 6), а декодер восстанавливает пространственную информацию для получения целевой маски.

U-Net обучалась на последовательностях изображений вихревого следа, что позволило более точно предсказывать следующий вихревой след на основе предыдущих состояний потока. Аналогично предсказанию нагрузок, представленному ранее, модель была обучена на наборах данных, содержащих различное количество входных изображений.

Архитектура U-Net была успешно применена в вычислительной гидродинамике (CFD) для предсказания вихревых структур и анализа потока. U-Net показала свою эффективность в задачах сегментации и анализа сложных потоков, включая предсказание вихревых следов и идентификацию потоковых структур [21, 22].

Функция потерь включает компоненты для минимизации ошибки предсказанных координат вихрей, а также компоненты, учитывающие плавность траекторий и соответствие физическим законам.

Метрика Dice, также известная как коэффициент Сёренсена-Дайса, является мерой сходства между двумя множествами и применяется для оценки качества сегментации. Формула для метрики Dice выглядит следующим образом, где: $\hat{y}_i$ -

предсказания модели (вероятности принадлежности к классу), N - количество пикселей, y_i - бинарная маска вихревых следов, сгенерированная в программе VM2D. Бинарная маска представляет собой матрицу размерностью (512, 512), где значение 1 в матрице соответствует зонам с вихревыми структурами, а 0 - фону или областям без вихревого воздействия.

$$DICE(y, \hat{y}) = \frac{2 \sum_{i=1}^N y_i \hat{y}_i}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i} \quad (4)$$

Для оптимизации модели в процессе обучения метрика Dice преобразуется в функцию потерь LDICE = 1 - DICE:

$$LDICE(y, \hat{y}) = 1 - \left(\frac{2 \sum_{i=1}^N y_i \hat{y}_i}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i} \right) \quad (5)$$

Бинарная кросс-энтропия (BCE): Бинарная кросс-энтропия является стандартной функцией потерь для задач бинарной классификации и сегментации. Она измеряет расхождение между предсказаниями модели и истинными метками путем сравнения вероятностных распределений. Формула бинарной кросс-энтропии для сегментации одного пикселя выглядит следующим образом, Где: y_i - истинные метки (бинарные маски), $\hat{y}_i$ - предсказания модели (вероятности принадлежности к классу), N - количество пикселей:

$$BCE(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (6)$$

Комбинированная функция потерь: для обучения модели U-Net часто используется комбинация бинарной кросс-энтропии и метрики Dice. Общая функция потерь может быть определена как взвешенная сумма двух компонент:

$$Loss_{vortex}(y, \hat{y}) = \alpha BCE(y, \hat{y}) + \beta LDICE(y, \hat{y}) \quad (7)$$

где α и β - коэффициенты, позволяющие настраивать вклад каждой составляющей в общую функцию потерь в зависимости от требований к задаче и предпочтений.

Результаты расчета с использованием модели U-Net представлены в таблице 4. На основе представленных данных можно сделать следующие выводы. Модель U-Net демонстрирует умеренные результаты точности по метрике DICE, которые увеличиваются с увеличением количества входных изображений. При использовании двух и трёх изображений на вход точность остается на уровне 0.63, а при увеличении до шести изображений точность возрастает до 0.678, что указывает на влияние большего объема входных данных на качество предсказаний.

Таблица 4. Варианты обучаемых моделей для предсказания нагрузок X и Y с помощью модели U-net.

Модель	Количество слоев	Количество входных изображений	Функция потерь	Точность по метрике DICE
U-net	30	2	$BCE + LDICE$	0.63
U-net	30	3	$BCE + LDICE$	0.63
U-net	30	6	$BCE + LDICE$	0.678

Для решения задач сегментации была предложена архитектура, состоящая из сверточных слоев с остаточными блоками и транспонированных сверток с блоками внимания [23]. Архитектура включает несколько уровней обработки, что позволяет эффективно извлекать признаки и фокусироваться на значимых областях изображения. В отличие от классической U-Net, в данной модели используются остаточные связи и механизмы внимания, что улучшает качество обучения и предсказаний, обеспечивая более детализированные выходные данные.

Как следует из результатов расчета, приведенных в таблице 5, модель Attention U-Net показывает значительно лучшие результаты по сравнению с U-Net. Даже при минимальном количестве входных изображений (2) точность по метрике DICE составляет 0.74, что существенно выше по сравнению с обычной U-Net. С увеличением количества входных изображений до трёх и шести точность продолжает расти, достигая 0.77 при шести изображениях. Это свидетельствует о том, что внимание помогает модели лучше улавливать ключевые особенности данных, что приводит к более точным предсказаниям, особенно при увеличении количества входных изображений.

Таблица 5. Варианты обучаемых моделей для предсказания нагрузок X и Y с помощью модели Attention U-net.

Модель	Количество слоев	Количество входных изображений	Функция потерь	Точность по метрике DICE
Attention U- Net	30	2	$BCE+LDICE$	0.74
Attention U- Net	30	3	$BCE+LDICE$	0.76
Attention U- Net	30	6	$BCE+LDICE$	0.77

Можно сделать вывод, что использование Attention U-Net существенно повышает точность сегментации по сравнению с классической U-Net, особенно при увеличении объёма входных данных.

На рисунке 4 представлен пример предсказания вихревого следа, выполненного моделью Attention U-Net, обученной на шести входных изображениях.




Рисунок 4. Сравнение истинных, рассчитанных в программе VM2D, (зеленый цвет) и предсказанных моделью Attention U-Net (красный цвет) положений вихревых элементов в следе за профилем.

Как следует из рисунка 4, несмотря на улучшение точности предсказаний в модели Attention U-Net, результаты всё ещё далеки от оригинальных вихревых структур. Это говорит о том, что на данном этапе полагаться на предсказания модели для точных вычислений вихревых следов и аэродинамических нагрузок нерационально, и требуется дальнейшая доработка моделей и подходов.

4. Комбинированная модель.

Для достижения более высокой точности в предсказании аэродинамических нагрузок была выбрана модифицированная архитектура U-Net. Основная задача этой модели заключается в предсказании следующего вихревого следа на основе последовательности входных изображений. Однако, помимо стандартной задачи

сегментации, последний слой энкодера модели используется для извлечения эмбеддингов, которые затем применяются для вычисления ошибки регрессии. Эти эмбеддинги вносят вклад в общий лосс-функционал, объединяя задачи сегментации и регрессии, что позволяет модели учитывать влияние вихревых структур на аэродинамические нагрузки и улучшить точность предсказаний.

Общую функцию ошибки представляет комбинация $Loss_{vortex}$ и $Loss_{force}$

$$Loss_{main}(y, \hat{y}) = Loss_{vortex}(y, \hat{y}) + Loss_{force}(y, \hat{y}) \quad (13)$$

На основе результатов, представленных в таблице 6, можно сделать вывод, что модель U-Net показывает улучшение по метрикам RMSE и DICE с увеличением количества входных изображений. Погрешность по метрике RMSE снижается от 0.253 до 0.236, а точность по метрике DICE возрастает с 0.674 до 0.707 при увеличении количества входных изображений с двух до шести. Это указывает на то, что предоставление большего объема данных модели помогает улучшить качество предсказаний. Attention U-Net демонстрирует более высокие показатели по обоим метрикам по сравнению с классической U-Net. Погрешность по RMSE также улучшается при увеличении количества входных изображений, начиная с 0.136 и достигая 0.123, а точность по DICE значительно выше, начиная с 0.743 при двух изображениях и увеличиваясь до 0.784 при шести. Это говорит о том, что механизмы внимания, используемые в модели, позволяют ей лучше анализировать данные и получать более точные предсказания.

Таблица 6. Варианты обучаемых моделей для предсказания нагрузок X и Y с помощью комбинированной модели.

Модель	Количество слоев	Количество входных изображений	Функция потерь	Погрешность по метрике RMSE	Точность по метрике DICE
U-net	30	2	BCE+LDICE+MSE	0.253	0.674
U-net	30	3	BCE+LDICE+MSE	0.251	0.682
U-net	30	6	BCE+LDICE+MSE	0.236	0.707
Attention U-Net	30	2	BCE+LDICE+MSE	0.136	0.743
Attention U-Net	30	3	BCE+LDICE+MSE	0.126	0.772
Attention U-Net	30	6	BCE+LDICE+MSE	0.123	0.784

В сравнении с предыдущими результатами для моделей ResNet и собственной модели, U-Net и Attention U-Net показывают более лучшие результаты по метрике RMSE и превосходят по метрике DICE, что указывает на их большую эффективность для задачи сегментации вихревых следов. На рисунке 5 представлен пример предсказания вихревого следа моделью Attention U-Net. На основе визуального представления наблюдается уменьшение шума предсказанного вихревого следа.




Рисунок 5. Сравнение истинных, рассчитанных в программе VM2D, (зеленый цвет) и предсказанных комбинированной моделью (красный цвет) положений вихревых элементов в следе за профилем.

Также на рисунке 6 и 7 приведены результаты предсказания моделью нагрузок по осям X и Y в сравнении с истинными значениями.




Рисунок 6. Сравнение предсказанных значений нагрузки (комбинированная модель Attention U-Net) по оси X с значениями, полученными в программе VM2D.




Рисунок 7. Сравнение предсказанных значений нагрузки (комбинированная модель Attention U-Net) по оси Y с значениями, полученными в программе VM2D.

5. Анализ вычислительной эффективности моделей

Тестирование производительности проводилось на компьютере с весьма скромными характеристиками производительности, имеющем процессор Intel Core i5 и графическую карту GPU NVIDIA RTX 3060. Использование GPU позволило значительно ускорить процесс обучения моделей за счет параллельных вычислений. Однако, учитывая, что основные расчеты обученных моделей предполагается выполнять на CPU, была проведена оптимизация с использованием таких методов, как квантование и фьюзинг. Квантование позволяет уменьшить размер моделей и ускорить их выполнение за счет снижения точности представления числовых данных. Фьюзинг объединяет несколько последовательных операций в одну.

После оптимизации модели, обученные в формате pt (с использованием torch), были преобразованы в формат ONNX для дальнейшего ускорения вычислений.

Наиболее эффективным оказался фреймворк [OpenVINO](https://github.com/openvinotoolkit/openvino)³. Модели, конвертированные в формат OpenVINO, работают исключительно на процессорах Intel CPU, что обеспечивает высокую вычислительную эффективность.

Сравнение производительности проводилось на GPU RTX 3060 и CPU Intel Core i5. Результаты тестирования показали, что использование OpenVINO на CPU обеспечивает значительное ускорение по сравнению с выполнением вычислений на GPU в рамках рассматриваемых задач. Это связано с оптимизацией OpenVINO для процессоров Intel, что делает его предпочтительным выбором для задач, где основная нагрузка ложится на CPU.

Результаты оценки скорости вычислений стандартным способом с использованием программы VM2D и оптимизированных моделей представлены в таблице 7.

Таблица 7. Скорость вычислений

Способ расчета	CPU, мин	GPU, мин	OPENVINO, мин
VM2D	1390	170	-
U-net	16	2	7
Attention U-Net	19	2	8

Результаты моделирования показали, что нейросетевая модель обеспечивает высокую точность предсказаний вихревых следов на начальном интервале от 0 до 2

³ <https://github.com/openvinotoolkit/openvino>

секунд ($DICE > 0.7$), однако при дальнейшем моделировании наблюдается прогрессирующее накопление ошибки, приводящее к снижению метрики DICE до 0.4-0.6 к 5 секундам.

Таким образом, анализ производительности показал, что оптимизированные с помощью OpenVINO модели на CPU Intel обеспечивают баланс между скоростью вычислений (7-8 минут против 1390 минут у VM2D) и точностью, сохраняя приемлемое качество прогноза на коротких временных интервалах.

Выводы

Применение в методе вихревых элементов нейросетевых моделей для одновременного решения двух взаимосвязанных задач — предсказания изображения вихревых следов и предсказания аэродинамических нагрузок — с использованием общей функции ошибки привело к значительному улучшению точности модели. Это объясняется тем, что такая совместная оптимизация позволяет модели лучше захватывать ключевые зависимости в данных и более эффективно обучаться. Предсказание вихревых следов улучшает пространственное восприятие динамики потока, в то время как предсказание нагрузок помогает модели улавливать важные закономерности. Использование общей функции ошибки объединяет эти два процесса, что позволяет модели одновременно улучшать свои способности как в сегментации вихревых следов, так и в предсказании аэродинамических нагрузок. В результате, модель становится более информативной и точной, так как может обучаться на дополнительных сигналах и корреляциях, что и привело к улучшению метрик RMSE и DICE.

Полученные результаты следует считать первым шагом к применению нейросетевых моделей в методе вихревых элементов. Полученные результаты подчеркивают необходимость дальнейшего совершенствования архитектур нейросетей для повышения устойчивости долгосрочных прогнозов динамики вихревых структур.

Список источников

- [1] Cottet G.-H., Koumoutsakos P.D. *Vortex methods: theory and practice*. 2nd ed. Cambridge University Press, 2000, 328 p.
- [2] Rodionov, N.G. Experimental Studies of Airfoil Cascades with High Velocity Vector Circulation around the Airfoil. *Thermal Engineering*, 2022, Vol. 69, P.42–50. DOI:10.1134/S0040601521110033.
- [3] Varaksin, A.Y., Ryzhkov, S.V. Vortex Flows with Particles and Droplets. *Symmetry*, 2022, Vol. 14, Iss. 10, Paper ID 2016 DOI:10.3390/sym14102016.
- [4] Егоров И.А. Учёт особенностей обтекания дугообразных крыльев на этапе проектирования // Труды МАИ. 2022. № 123. 23 с. URL: <https://trudymai.ru/eng/published.php?ID=165481>
- [5] Klimina L., Dosaev M., Selyutskiy Y. Asymptotic analysis of the mathematical model of a wind-powered vehicle. *Applied Mathematical Modelling*, Vol. 46, 2017, pp. 691-697, DOI: 10.1016/j.apm.2016.06.022.
- [6] Andronov P.R., Dosaev M.Z., Dynnikova G.Y. et al. Modeling of oscillating wind turbine. *J. Mach. Manuf. Reliab.*, 2009, No. 38, P. 383–387. DOI:10.3103/S1052618809040153.

- [7] Kotsur, O.S., Shcheglov, G.A., Marchevsky, I.K. Approximate Weak Solutions to the Vorticity Evolution Equation for a Viscous Incompressible Fluid in the Class of Vortex Filaments. *Russian Journal of Nonlinear Dynamics*, 2022, Vol. 18, Iss. 3, P. 423-439. DOI:10.20537/nd220307
- [8] Ryatina, E., Marchevsky, I., Kolganova, A. Boundary integral equation solving in vortex method using the Barnes-Hut/multipole algorithm. *Proceedings - Ivannikov ISPRAS Open Conference 2022*, P. 74-80.
- [9] Kochoy D., Smith J.A., Alieva A., Hoyer S. Machine learning-accelerated computational fluid dynamics. *PNAS*, 2021, Vol. 118(21), Art.No.e2101784118. DOI: 10.1073/pnas.2101784118.
- [10] Loktev, D.A., Loktev, A.A., Makarov, A.A., Shepelev, D.N. The System Simulating the State of the Objects and the Process of Their Monitoring with the Help of the Convolutional Neural Network. *International Review on Modelling and Simulations* 2022, Vol. 15, Iss. 1, P. 1-9.
- [11] Senthilraj, S., Raja, R., Cao, J., Fardoun, H.M. Dissipativity analysis of stochastic fuzzy neural networks with randomly occurring uncertainties using delay dividing approach. *Nonlinear Analysis: Modelling and Control* 2019, Vol. 24, Iss. 4, P. 561-581. DOI: 10.15388/NA.2019.4.5
- [12] Дорофеев Ф.Е., Василенко Д.А., Дорофеев Е.А. Построение нейросетевого аппроксиматора для определения критического угла полураствора в эффекте смены знака коэффициента подъемной силы для затупленных конических тел // Труды МАИ. 2021. № 119. 17с. URL: <https://trudymai.ru/eng/published.php?ID=159784>

- [13] Соколов Д.Ю. Применение искусственной нейронной сети для решения задач прогнозирования движения наземных объектов // Труды МАИ. 2022. № 123. 32с. URL: <https://trudymai.ru/eng/published.php?ID=165563>
- [14] Xiaowei Jin, Shujin Laima, Hui Li. Physics-enhanced deep learning methods for modelling and simulating flow fields. *Chinese Journal of Theoretical and Applied Mechanics*, 2021, No.53(10) P. 2616-2629. DOI: 10.6052/0459-1879-21-373
- [15] Шон Ф.Т. Моделирование процессов нестационарных колебаний и теплопроводности в слое с применением технологий глубокого машинного обучения // Труды МАИ. 2025. № 140. 42 с. URL: <https://trudymai.ru/eng/published.php?ID=184057>
- [16] Hao Yan, Yangwei Lui, Lipeng Lu. Turbulence anisotropy analysis in a highly loaded linear compressor cascade. *Aerospace Science and Technology*, 2019, Vol. 91, P. 241-254. DOI: 10.1016/j.ast.2019.05.029
- [17] Xiao-Dong Bai, Wei Zhang. Machine learning for vortex induced vibration in turbulent flow. *Computers & Fluids*, 2022, Vol. 235, PaperID 1052666. DOI:10.1016/j.compfluid.2021.105266
- [18] Marchevsky I., Sokol K., Ryatina E., Izmailova Y. The VM2D Open Source Code for Two-Dimensional Incompressible Flow Simulation by Using Fully Lagrangian Vortex Particle Methods. *Axioms*, 2023, No. 12(3), Iss. 248, 33 p. DOI:10.3390/axioms12030248.
- [19] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Deep Residual Learning for Image Recognition. Computer Vision and Pattern Recognition. *Proceedings of 2016 IEEE*

Conference on Computer Vision and Pattern Recognition (CVPR).

DOI:10.1109/CVPR.2016.90

[20] Ronneberger, O., Fischer, P., Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Lecture Notes in Computer Science 2015*, vol 9351. Springer, Cham. DOI: 10.1007/978-3-319-24574-4_28

[21] Hinton G.E., Salakhutdinov R.R. Reducing the dimensionality of data with neural networks. *Science*. 28 Jul 2006. Vol. 313, Iss. 5786, P. 504-507. DOI: 10.1126/science.1127647

[22] Lindemann B., Muller T., Vietz H., Jazdi N., Weyrich M. A survey on long short-term memory networks for time series prediction. *Procedia CIRP*, 2021 Vol. 99, P. 650-655. DOI: 10.1016/j.procir.2021.03.088

[23] Ashish Vaswani, Noam Shazeer. Attention Is All You Need. *Proceedings of 31st Conference on Neural Information Processing Systems (NIPS 2017)*. URL: https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf (дата обращения 23.07.2025)

References

[1] Cottet G.-H., Koumoutsakos P.D. *Vortex methods: theory and practice*. 2nd ed. Cambridge University Press, 2000, 328 p.

[2] Rodionov, N.G. Experimental Studies of Airfoil Cascades with High Velocity Vector Circulation around the Airfoil. *Thermal Engineering*, 2022, Vol. 69, P.42–50. DOI:10.1134/S0040601521110033.

- [3] Varaksin, A.Y., Ryzhkov, S.V. Vortex Flows with Particles and Droplets. *Symmetry*, 2022, Vol. 14, Iss. 10, Paper ID 2016 DOI:10.3390/sym14102016.
- [4] Egorov I.A. Trudy MAI, 2022, no. 123. URL: <https://trudymai.ru/eng/published.php?ID=165481>
- [5] Klimina L., Dosaev M., Selyutskiy Y. Asymptotic analysis of the mathematical model of a wind-powered vehicle. *Applied Mathematical Modelling*, Vol. 46, 2017, pp. 691-697, DOI: 10.1016/j.apm.2016.06.022.
- [6] Andronov P.R., Dosaev M.Z., Dynnikova G.Y. et al. Modeling of oscillating wind turbine. *J. Mach. Manuf. Reliab.*, 2009, No. 38, P. 383–387. DOI:10.3103/S1052618809040153.
- [7] Kotsur, O.S., Shcheglov, G.A., Marchevsky, I.K. Approximate Weak Solutions to the Vorticity Evolution Equation for a Viscous Incompressible Fluid in the Class of Vortex Filaments. *Russian Journal of Nonlinear Dynamics*, 2022, Vol. 18, Iss. 3, P. 423-439. DOI:10.20537/nd220307
- [8] Ryatina, E., Marchevsky, I., Kolganova, A. Boundary integral equation solving in vortex method using the Barnes-Hut/multipole algorithm. *Proceedings - Ivannikov ISPRAS Open Conference 2022*, P. 74-80.
- [9] Kochov D., Smith J.A., Alieva A., Hoyer S. Machine learning-accelerated computational fluid dynamics. *PNAS*, 2021, Vol. 118(21), Art.No.e2101784118. DOI: 10.1073/pnas.2101784118.
- [10] Loktev, D.A., Loktev, A.A., Makarov, A.A., Shepelev, D.N. The System Simulating the State of the Objects and the Process of Their Monitoring with the Help of the

Convolutional Neural Network. *International Review on Modelling and Simulations* 2022, Vol. 15, Iss. 1, P. 1-9.

[11] Senthilraj, S., Raja, R., Cao, J., Fardoun, H.M. Dissipativity analysis of stochastic fuzzy neural networks with randomly occurring uncertainties using delay dividing approach. *Nonlinear Analysis: Modelling and Control* 2019, Vol. 24, Iss. 4, P. 561-581. DOI: 10.15388/NA.2019.4.5

[12] Dorofeev F.E., Vasilenko D.A., Dorofeev E.A. Trudy MAI, 2021, no. 119. URL: <https://trudymai.ru/eng/published.php?ID=159784>

[13] Sokolov D.Y. Trudy MAI, 2022, no. 123. URL: <https://trudymai.ru/eng/published.php?ID=165563>

[14] Xiaowei Jin, Shujin Laima, Hui Li. Physics-enhanced deep learning methods for modelling and simulating flow fields. *Chinese Journal of Theoretical and Applied Mechanics*, 2021, No.53(10) P. 2616-2629. DOI: 10.6052/0459-1879-21-373

[15] Son P.T. Trudy MAI, 2025, no. 140. URL: <https://trudymai.ru/eng/published.php?ID=184057>

[16] Hao Yan, Yangwei Lui, Lipeng Lu. Turbulence anisotropy analysis in a highly loaded linear compressor cascade. *Aerospace Science and Technology*, 2019, Vol. 91, P. 241-254. DOI: 10.1016/j.ast.2019.05.029

[17] Xiao-Dong Bai, Wei Zhang. Machine learning for vortex induced vibration in turbulent flow. *Computers & Fluids*, 2022, Vol. 235, PaperID 1052666. DOI:10.1016/j.compfluid.2021.105266

- [18] Marchevsky I., Sokol K., Ryatina E., Izmailova Y. The VM2D Open Source Code for Two-Dimensional Incompressible Flow Simulation by Using Fully Lagrangian Vortex Particle Methods. *Axioms*, 2023, No. 12(3), Iss. 248, 33 p. DOI:10.3390/axioms12030248.
- [19] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Deep Residual Learning for Image Recognition. Computer Vision and Pattern Recognition. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. DOI:10.1109/CVPR.2016.90
- [20] Ronneberger, O., Fischer, P., Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Lecture Notes in Computer Science* 2015, vol 9351. Springer, Cham. DOI: 10.1007/978-3-319-24574-4_28
- [21] Hinton G.E., Salakhutdinov R.R. Reducing the dimensionality of data with neural networks. *Science*. 28 Jul 2006. Vol. 313, Iss. 5786, P. 504-507. DOI: 10.1126/science.1127647
- [22] Lindemann B., Muller T., Vietz H., Jazdi N., Weyrich M. A survey on long short-term memory networks for time series prediction. *Procedia CIRP*, 2021 Vol. 99, P. 650-655. DOI: 10.1016/j.procir.2021.03.088
- [23] Ashish Vaswani, Noam Shazeer. Attention Is All You Need. *Proceedings of 31st Conference on Neural Information Processing Systems (NIPS 2017)*. URL: https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf (accessed 23.07.2025).