

Прогнозирование аэродинамических характеристик низкоскоростных летательных аппаратов различных аэродинамических схем с использованием многослойного персептрона

О. Е. Лукьянов, В. Х. Хоанг, Д. Х. Гуерра Гуерра, Е. В. Куркина

*Самарский национальный исследовательский университет им. академика С. П. Королева, Самара,
Россия*

Поступила в редакцию 12.10.2025 г. Принята 25.10.2025 г.

Аннотация—В этом исследовании основное внимание уделяется выбору гиперпараметров для модели прогнозирования аэродинамических характеристик самолета на основе многослойного персептрона (MLP). Модель самолета включает 22 входные переменные, охватывающие геометрию, условия полета и аэродинамические схемы с двумя несущими поверхностями. Используя метод латинского гиперкуба (LHS), создано 44 000 сочетаний проектных переменных и рассчитаны для них аэродинамические характеристики (коэффициенты подъемной силы, сопротивления и момента тангажа) с помощью метода дискретных вихрей для создания обучающей выборки для MLP. В этой статье рассматривается оптимизация гиперпараметров MLP с использованием алгоритма Integer Encoding Differential Evolution (IEDE) для повышения точности и вычислительной эффективности нейросетевой модели.

КЛЮЧЕВЫЕ СЛОВА: архитектура, гиперпараметр, многослойный персептрон, аэродинамические характеристики, летательный аппарат, суррогатные аэродинамические модели.

DOI: 10.53921/18195822_2025_25_3.1_586

1. ВВЕДЕНИЕ

Применение искусственных нейронных сетей (ИНС) в аэродинамических расчётах приобрело значительную популярность в последние годы. Среди различных архитектур ИНС широко используется многослойный персептрон (MLP) из-за его способности моделировать сложные нелинейные зависимости в аэродинамике летательных аппаратов. Эта возможность особенно полезна для прогнозирования интегральных аэродинамических коэффициентов летательных аппаратов, поскольку традиционные математические модели часто требуют значительных вычислительных ресурсов, а модели на основе нейронных сетей характеризуются высокой производительностью.

Однако большинство исследований были сосредоточены в основном в области прогнозирования аэродинамических характеристик плоских профилей [1, 2] или реже – отдельных изолированных несущих поверхностей летательных аппаратов [3, 4, 5], что ограничивает их применимость ко всему самолету. Эти исследования дают представление об аэродинамике аэродинамического профиля и изолированного крыла, но не могут охватить взаимодействие между несколькими несущими поверхностями и другими частями летательного аппарата. Методики, представленные в [6, 7], рассматривали применение нейросетевых моделей для расчёта планера летательного аппарата в целом, однако они учитывали только два входных параметра

(угол атаки, число Маха) и один выходной параметр. Данное обстоятельство ограничивает способность моделей [6, 7] обобщать более широкий диапазон конструктивных параметров и условий полета. Более того, архитектуры нейросетей во многих известных работах часто predetermined без систематической оптимизации гиперпараметров архитектуры, обычно с использованием фиксированного числа скрытых слоев и нейронов [1, 2]. В нескольких случаях используется один скрытый слой [6], что может недостаточно точно повторять сложные аэродинамические зависимости, даже для стадий предварительного проектирования. Кроме того, большинство существующих исследований используют одну и ту же функцию активации во всех скрытых слоях [1, 5, 8], несмотря на потенциальные преимущества использования разных функций активаций по разным слоям. В [8] была рассмотрена возможность использования различных функций активации, однако пространство поиска параметров не было достаточно проанализировано.

В настоящей работе использованы научные основы из [5] и расширены возможности моделей для исследования полной модели самолета с геометрическими вариациями, условиями полета (угол атаки, скорость полёта) и различными аэродинамическими конфигурациями с двумя несущими поверхностями. В отличие от предыдущих исследований, этот подход включает более полный набор аэродинамических параметров и геометрических вариаций, что позволяет создать более точную и обобщаемую модель аэродинамики. Кроме того, все гиперпараметры MLP, включая количество скрытых слоев, эпох и размеры обучающих партий, систематически оптимизируются, а не назначаются заранее. Для обеспечения надежной оценки модели в различных подмножествах обучающих данных использовалась перекрестная проверка K-Fold. Для оптимизации количества нейронов на слой и выбора функции активации для каждого скрытого слоя использовался алгоритм IEDE [9], что позволяет использовать адаптивные сетевые архитектуры, которые более чувствительны к изменению предсказываемых характеристик.

Это исследование направлено на повышение скорости определения аэродинамических характеристик летательных аппаратов самолётно-го типа и создания более обобщённых моделей аэродинамики за счёт использования нейронных сетей, с возможностью рассмотрения компоновки самолета в целом.

Целью данной работы является разработка метода оперативного определения аэродинамических характеристик летательных аппаратов различной аэродинамической компоновки с использованием многослойного персептрона.

2. МЕТОДИКА

2.1. Геометрическая параметризация модели самолета

Генерация многослойного персептрона осуществляется на основе специальных баз данных. Эти базы данных включают комбинации геометрических параметров интересующей конфигурации самолета и соответствующие этим комбинациям аэродинамические характеристики. Геометрические параметры совместно с аэродинамическими параметрами (угол атаки, скорость полета) рассматривались как входные параметры, а соответствующие аэродинамические характеристики - как выходные параметры для обучаемого персептрона. Каждое такое сочетание параметров в базе данных, по сути представляющее собой конкретную аэродинамическую схему с характеристиками, будем называть индивидом.

Разработка многослойного персептрона проводилась для определения аэродинамических характеристик низкоскоростных самолетов с различными аэродинамическими компоновками с двумя несущими поверхностями.

Геометрия летательных аппаратов описывается с помощью набора входных проектных переменных (22 переменные), включая параметры, определяющие геометрические параметры: удлинение (λ_1, λ_2); стреловидность (χ_1, χ_2); сужение (η_1, η_2); углы установки (δ_1, δ_2) ($^\circ$); относительное расстояние ($\bar{L}_2$) между двумя несущими поверхностями; относительная площадь ($\bar{S}_2 = \frac{S_2}{S_1+S_2}$); удлинение вертикального оперения (AR_3); относительная площадь вертикального оперения ($\bar{S}_3 = \frac{S_3}{S_1+S_2}$); угол геометрической крутки (φ) ($^\circ$) и угол поперечного V (ψ) ($^\circ$) основной несущей поверхности; двугранный угол при V-образной или обратной V-образной конфигурации хвостового оперения (ψ_2) ($^\circ$); относительное положение точки расчёта продольного момента ($\bar{x}_G$); суммарная площадь несущих поверхностей ($S_\Sigma = S_1 + S_2$) (м^2); относительное положение горизонтального оперения относительно вертикального (z); конфигурация фюзеляжа (n_ϕ); тип конфигурации горизонтального оперения (n); и параметры, определяющие условия полета: скорость полета (V) (м/с); угол атаки (α) ($^\circ$). В перечисленных обозначениях индекс 1 и 2 означают принадлежность к передней или задней несущей поверхности соответственно. Основная несущая поверхность — это поверхность с большей площадью.

С использованием метода латинского гиперкуба (LHS) с заданным диапазоном значений входных проектных переменных (таблица 1) было создано 44 000 индивидов, представляющих собой различные аэродинамические компоновки. LHS обеспечивает более равномерное покрытие проектного пространства, чем чисто случайная выборка, тем самым снижая риск кластеризации и улучшая способность обобщения нейросетевой модели. Этот подход особенно актуален для аэродинамического анализа, поскольку нелинейные зависимости между переменными могут существенно влиять на точность прогнозирования. Большой размер набора данных обеспечивает надежный процесс обучения, позволяя нейронной сети эффективно изучать сложные взаимосвязи.

Таблица 1. Диапазон входных параметров

Параметр	Min	Max
Удлинение переднего крыла λ_1	4.0	15.0
Стреловидность переднего крыла $\chi_1, [^\circ]$	0.0	45.0
Сужение переднего крыла η_1	1.0	3.0
Угол установки переднего крыла $\delta_1, [^\circ]$	0.0	5.0
Удлинение заднего крыла λ_2	4.0	15.0
Стреловидность заднего крыла $\chi_2, [^\circ]$	-45.0	45.0
Сужение заднего крыла η_2	1.0	3.0
Угол установки заднего крыла $\delta_2, [^\circ]$	-5.0	5.0
Относительное расстояние между крыльями $\bar{L}_2$	2.0	6.0
Относительная площадь $\bar{S}_2$	0.1	0.9
Удлинение вертикального оперения λ_3	2.0	4.0
Относительная площадь вертикального оперения $\bar{S}_3$	0.05	0.3
Геометрическая крутка $\varphi, [^\circ]$	-5.0	0.0
Угол поперечного V переднего крыла $\psi, [^\circ]$	0.0	10.0
Угол поперечного V оперения $\psi_2, [^\circ]$	30.0	50.0
Относительное положение крыла $\bar{x}_A$	0.0	8.0
Относительная площадь $S_\Sigma, [\text{м}^2]$	1.0	50.0
Относительная координата оперения z	0.0	1.0
Тип фюзеляжа n_F	0.0	1.0
Тип горизонтального оперения n	0.0	1.0
Скорость полёта $V, [\text{м/с}]$	30.0	90.0
Угол атаки $\alpha, [^\circ]$	-10.0	10.0

Относительное положение горизонтального оперения к вертикальному будет следующим: корневая часть $0 \leq z \leq 1/3$; середина $1/3 < z < 2/3$; концевая часть $2/3 \leq z$. Тип конфигурации фюзеляжа: двухфюзеляжный $0 \leq n_\phi \leq 1/3$; один фюзеляж $1/3 < n_\phi < 2/3$; двухбалочный $2/3 \leq n_\phi$. Тип конфигурации горизонтального оперения будет: обычное оперение $0 \leq n \leq 1/3$; V-образное $1/3 < n < 2/3$; обратное V-образное $2/3 \leq n$.

Особенностью данной работы является возможность одновременного рассмотрения множества различных аэродинамических конфигураций на основе возможных комбинаций типа фюзеляжа (1 фюзеляж (а-в, к); двухбалочное (г-е, л); двухфюзеляжное (ж-и, м)) и типа хвостового оперения (обычное хвостовое оперение (а, г, и); V-образное хвостовое оперение (б, д, з); утка (к, л, м); перевернутое V-образное хвостовое оперение (в, е, и)) вместе с соотношением площадей заднего и переднего крыла (нормальное, тандемное, утка) (рис. 1).




Рис. 1. Иллюстрация возможных конфигураций самолета

2.2. Определение аэродинамических характеристик

Для наполнения базы данных аэродинамическими характеристиками было использовано программное обеспечение OpenVSP [10] с открытым исходным кодом на Python. В основе OpenVSP находится метод дискретных вихрей (МДВ), который использует вихревую модель тонкой несущей поверхности, хорошо подходящую для моделирования дозвуковых, невязких и несжимаемых течений. Данная модель обеспечивает рациональный баланс между скоростью и точностью вычислений аэродинамических характеристик летательных аппаратов на начальных стадиях проектирования.

Определяемыми параметрами (3 параметра) являются коэффициенты подъемной силы C_L , сопротивления C_D и момент тангажа C_M , которые рассчитываются для каждого из сгенерированных 44000 индивидов.

Открытый код OpenVSP интегрирован со скриптами Python, что позволяет автоматизировать пакетную обработку данных и обеспечивает возможность массовых вычислений для базы данных. Используются возможности решателя OpenVSP по параллельным вычислениям с целью сокращения времени расчёта. С использованием API OpenVSP в связке с кодом на Python разработана технология быстрой генерации моделей с различной геометрией для последующего расчёта и сохранения в базу данных.

2.3. Подготовка данных

Перед подачей данных в нейросеть для её обучения было применено несколько этапов предварительной обработки для повышения производительности и стабильности модели. В том числе набор данных был переформатирован и структурирован для обеспечения совместимости с фреймворками глубокого обучения. Индивиды были случайным образом перемешаны, чтобы не допустить изучения моделью непреднамеренных закономерностей, связанных с порядком данных. Индивиды с неудачным сочетанием параметров, приводящих к плохим аэродинамическим характеристикам были отсеяны. Их количество составило $\sim 2\%$.

Для поддержания вычислительной стабильности и улучшения скорости сходимости во время обучения все входные переменные были нормированы в диапазоне $[0,1]$ с использованием минимально-максимального масштабирования. Нормировка предотвращает доминирование одних переменных относительно других в процессе обучения, что особенно важно при аэродинамическом моделировании, где такие параметры, как удлинение крыла, угол атаки и скорость полета, могут значительно различаться по масштабу величин.

2.4. Выбор гиперпараметров для многослойного персептрона

MLP построен с использованием библиотек Keras с предопределенными гиперпараметрами с использованием высокоуровневого API для корректного построения и обучения нейронной сети. Базовая архитектура MLP показана на рис. 2.

Для оценки точности модели при её обучении и тестировании использована метрика средней квадратической ошибки (MSE), которая хорошо подходит для задач регрессии. Для разработки архитектуры и выбора гиперпараметров нейросети использован оптимизационный алгоритм Adam, дающий возможность адаптивной скорости обучения и надежной обработки невыпуклых задач оптимизации. Производительность получаемой модели оценивалась с использованием двух ключевых метрик: среднеквадратичной ошибки (RMSE), которая количественно определяет среднюю ошибку прогнозирования, и коэффициента детерминации (R^2), который оценивает долю дисперсии. В процессе оптимизации гиперпараметров различные архитектуры MLP сравнивались на основе средних значений RMSE и R^2 , полученных из перекрестной проверки.




Рис. 2. Иллюстрация архитектуры MLP

Учитывая большую размерность задачи оптимизации гиперпараметров, был выбран размер популяции в 1000 особей. Предварительные исследования показали, что это количество оказалось достаточным для обеспечения баланса между вычислительной трудоёмкостью и требуемой точностью результатов. Шесть оптимизируемых гиперпараметров были систематически исследованы. При этом количество скрытых слоев оценивалось в пяти архитектурах (от 1 до 5 скрытых слоев). В качестве базовой архитектуры сети выбрано 64 нейрона на слой. Для уточнения других гиперпараметров (эпохи, размер выборки и перекрестная проверка k-fold) каждый параметр последовательно изменялся, при этом другие оставались постоянными, что облегчало текущий анализ их индивидуального влияния на производительность модели. С целью ускорения и повышения точности оптимизации архитектуры был выбран алгоритм IEDE для определения оптимального количества нейронов на слой и функций активации для каждого скрытого слоя. IEDE позволяет эффективно обрабатывать целочисленные задачи оптимизации, что имеет важное значение для выбора дискретных параметров архитектуры сети. Для обеспечения бесшовной интеграции в процесс эволюционной оптимизации рассматриваемые функции активации (RELU, ELU, TANH, SIGMOID) были пронумерованы от 1 до 4. Предложенный подход независимого выбора функций активации для каждого из скрытых слоёв позволил лучше адаптировать модель к сложным нелинейным аэродинамическим зависимостям.

В результате оптимизации архитектуры MLP посредством использования алгоритма IEDE и перекрестной проверки K-fold получена нейросетевая модель для прогнозирования аэродинамических характеристик для низкоскоростных летательных аппаратов самолётного типа различных аэродинамических схем. Сочетание структурированной настройки и эволюционной оптимизации гиперпараметров нейросети позволяет повысить обобщаемость модели для различных аэродинамических компоновок летательных аппаратов и их аэродинамических характеристик.

3. РЕЗУЛЬТАТЫ И АНАЛИЗ

Результаты разработки нейросетевой модели представлены в таблицах 2–7, охватывающих процесс выбора скрытых слоев, нейронов, функций активации, значений коэффициента кросс-валидации K-fold, размера обучающей выборки и количества эпох обучения.

3.1. Выбор количества скрытых слоев

Таблица 2 показывает влияние увеличения количества скрытых слоев на точность нейросетевой модели. Первоначальная архитектура с одним скрытым слоем (22-64-6) дала $RMSE = 0,0407$ и значение $R^2 = 0,8494$ для характеристики C_D , что указывает на умеренную точность прогнозирования. По мере увеличения количества скрытых слоев $RMSE$ постепенно уменьшалась, а R^2 увеличивалась, что говорит о том, что более глубокие архитектуры более чувствительны к сложным аэродинамическим зависимостям. Наилучшая производительность и точность модели наблюдалась с пятью скрытыми слоями (22-64-64-64-64-6), достигнув $RMSE 0,0267$ и $R^2 0,9412$ для C_D .

Таблица 2. Выбор количества скрытых слоев

MLP Архитектура	MSE	RMSE	R^2		
			C_D	C_L	C_M
22-64-6	0.0017	0.0407	0.8494	0.9782	0.8813
22-64-64-6	0.0009	0.0299	0.9258	0.9838	0.9452
22-64-64-64-6	0.0009	0.0291	0.9305	0.9835	0.9528
22-64-64-64-64-6	0.0008	0.0278	0.9386	0.9854	0.9613
22-64-64-64-64-64-6	0.0008	0.0267	0.9412	0.9845	0.9603

3.2. Выбор количества нейронов на скрытый слой

Таблица 3 демонстрирует влияние оптимизации распределения нейронов. Полностью оптимизированная архитектура с переменным распределением нейронов (22-512-339-180-297-168-6) значительно превзошла архитектуры с фиксированным одинаковым количеством нейронов на слоях: $RMSE$ снизилась до 0,0185, а значения R^2 превысили 0,98 для всех выходных коэффициентов. Это подтверждает, что настройка распределения количества нейронов на каждом слое повышает способность модели обобщать аэродинамические закономерности.

Таблица 3. Выбор количества скрытых слоев

MLP Архитектура	MSE	RMSE	R^2		
			C_D	C_L	C_M
22-512-339-180-297-168-6	0.0004	0.0185	0.9669	0.9929	0.9838

3.3. Выбор функции активации

В таблице 4 перечислены функции активации, выбранные для каждого скрытого слоя с помощью оптимизации IEDE. Оптимальная конфигурация использовала следующую комбинацию функций активаций ReLU и Sigmoid. Примечательно, что для первых двух слоёв лучше подошла функция ReLU, а для третьего и пятого слоя – Sigmoid. Смешанный подход к подбору функций активации улучшил сходимость процесса обучения.

Таблица 4. Выбор функции активации

HL1	HL2	HL3	HL4	HL5
RELU	RELU	SIGMOID	RELU	SIGMOID

3.4. Выбор значения перекрестной проверки K-fold

В таблице 5 представлены значения коэффициента k при кросс-валидации K-fold. Увеличение k с 6 до 16 привело к снижению значений MSE и RMSE; $k = 16$ достигло наилучшей производительности ($\text{RMSE} = 0,0087$, $R^2 = 0,98915$). Улучшение было более выраженным для более высоких значений k , поскольку они обеспечивают более надежную оценку ошибки обобщения. Дальнейшее увеличение k не дало повышения точности модели, но существенно привело к увеличению вычислительных затрат.

Таблица 5. Выбор значения k в перекрестной проверке k-fold

k	MSE	RMSE	R^2		
			C_D	C_L	C_M
6	0.00033	0.01607	0.97093	0.99412	0.98588
8	0.00022	0.01269	0.98123	0.99629	0.99098
10	0.00019	0.01181	0.98474	0.99648	0.99129
12	0.00018	0.01075	0.98310	0.99734	0.99315
14	0.00014	0.00944	0.98688	0.99764	0.99488
16	0.00013	0.00870	0.98915	0.99810	0.99456

3.5. Выбор размера обучающей выборки

В таблице 6 показаны результаты исследований влияния различных размеров обучающей выборки на производительность модели. Размер выборки 10 обеспечил самое низкое значение RMSE (0,00864) и самое высокое значение R^2 (0,98946 для C_D), однако в итоге был выбран размер обучающей выборки 20 на основе компромисса между точностью и вычислительной эффективностью с учётом остальных метрик. Разница в RMSE между размерами выборки 10, 15 и 20 была минимальной, что указывает на то, что небольшое увеличение размера выборки не приводит к значительному ухудшению производительности. Однако использование меньшего размера выборки требует более частых обновлений, что приводит к более длительному времени обучения на эпоху. С другой стороны, размеры выборки больше 20 снижают эффективность обобщения из-за меньшего количества обновлений на эпоху. Поэтому размер выборки 20 был выбран в качестве наилучшего компромисса, обеспечивающего высокую прогностическую производительность при сохранении приемлемых вычислительных затрат.

Таблица 6. Выбор размера обучающей выборки

Размер выборки	MSE	RMSE	R^2		
			C_D	C_L	C_M
5	0.00017	0.00984	0.98438	0.99558	0.99089
10	0.00013	0.00864	0.98946	0.99791	0.99459
15	0.00014	0.00894	0.98866	0.99792	0.99403
20	0.00013	0.00870	0.98915	0.99810	0.99456
25	0.00014	0.00894	0.98910	0.99803	0.99441

3.6. Выбор количества эпох обучения

В таблице 7 представлено влияние количества эпох обучения на точность модели. Оптимальное количество эпох составило 300, при этом RMSE достигла самого низкого значения (0,00713), а R^2 был максимальным при 0,98979 для коэффициента C_D . После этой точки прирост точности был минимальным, что указывает на то, что дальнейшее увеличение эпох может привести к переобучению и снижению производительности модели.

Таблица 7. Выбор количества эпох

Размер выборки	MSE	RMSE	R^2		
			C_D	C_L	C_M
50	0.00018	0.01134	0.98685	0.99687	0.99305
100	0.00013	0.00870	0.98915	0.99810	0.99456
150	0.00012	0.00832	0.98865	0.99795	0.99480
200	0.00012	0.00795	0.98794	0.99819	0.99486
250	0.00012	0.00776	0.98795	0.99808	0.99487
300	0.00011	0.00713	0.98979	0.99814	0.99502
350	0.00011	0.00717	0.98952	0.99820	0.99539

Результаты оптимизации гиперпараметров нейросети показывают, что использование разного количества нейронов на слоях и использование разных типов функций активации для разных слоёв позволяет существенно повысить точность модели.

Процесс выбора оптимальных значений гиперпараметров архитектуры MLP был выполнен на персональном компьютере с процессором Intel(R) Core(TM) i7-6700 @ 3,40 ГГц, 64 ГБ ОЗУ. Весь процесс занял 77721 секунду (21,6 часа).

На рисунках 3 а-в более подробно представлен регрессионный анализ прогнозирования аэродинамических характеристик, полученный с помощью нейросети с окончательной архитектурой во время фазы тестирования. Горизонтальная ось представляет собой фактическое значение аэродинамических коэффициентов, полученное из базы данных, а вертикальная ось — прогнозируемое значение с помощью полученной модели на основе нейросети.




Рис. 3. Регрессионный анализ итоговой архитектуры MLP на этапе тестирования: (а) коэффициент сопротивления ($R^2=0.993$; $MAE = 0.0008$); (б) коэффициент подъемной силы ($R^2=0.997$; $MAE = 0.0196$); (в) коэффициент момента тангажа ($R^2=0.995$; $MAE = 0.0654$). Р-предсказанное значение; Т-значение из базы данных.

4. ПРОИЗВОДИТЕЛЬНОСТЬ ВЫЧИСЛЕНИЙ

Для оценки точности и скорости MLP были выполнены расчеты на случайных 50 сочетаниях параметров, не входящих в базу данных как с использованием OpenVSP, так и полученной

модели MLP. На рис. 4 сравниваются результаты, показывающие абсолютные средние отклонения 4,786% для C_D , 4,827% для C_L и 4,823% для C_M . Однако модель MLP оказалась значительно быстрее, выполнив задачу за 0,1 секунды по сравнению с 16 минутами OpenVSP.




Рис. 4. Регрессионный анализ итоговой архитектуры MLP на этапе тестирования: (а) коэффициент сопротивления ($R^2=0.993$; $MAE = 0.0008$); (б) коэффициент подъемной силы ($R^2=0.997$; $MAE = 0.0196$); (в) коэффициент момента тангажа ($R^2=0.995$; $MAE = 0.0654$). Р-предсказанное значение; Т-значение из базы данных.

5. ЗАКЛЮЧЕНИЕ

Предложенная в работе методика позволила получить нейросетевую модель аэродинамики низкоскоростных летательных аппаратов на основе MLP для прогнозирования трех основных аэродинамических коэффициентов самолета с высокой точностью (R^2 до 0,993, 0,997 и 0,995 для C_D , C_L и C_M соответственно). Результат обучения показал способность MLP прогнозировать сложные аэродинамические зависимости. Среднее значение MAE прогнозируемых аэродинамических характеристик, полученных с использованием нейронной сети относительно значений базы данных, используемых для обучения, равно 0,028. Прогнозирование характеристик для случайных 50 сочетаний параметров, не включенных в базу данных, дает среднее значение $MAE = 0,026$.

По сравнению с традиционными численными математическими моделями, такими как метод дискретных вихрей или уравнения Навье-Стокса, подход на основе MLP дает значительные преимущества с точки зрения вычислительной производительности. Большинство численных моделей аэродинамики требует итерационного решения систем уравнений для каждой новой исследуемой геометрии летательного аппарата со значительными затратами времени. Правильно обученная нейронная сеть способна предоставлять результаты практически мгновенно. Для сравнения: расчет одной точки на графике аэродинамической зависимости с помощью метода дискретных вихрей выполняется примерно за 19,5 секунд, а с помощью разработанного MLP – за 0,02 секунды. Существенное увеличение скорости вычислений аэродинамических характеристик (на 2-3 порядка) за счёт применения нейросетевых моделей открывает новые

возможности концептуального проектирования летательных аппаратов в части повышения их точности за счёт рассмотрения существенно большего количества проектных переменных при оптимизации.

БЛАГОДАРНОСТИ

Это исследование профинансировано Российским научным фондом, номер проекта 25-29-00762.

СПИСОК ЛИТЕРАТУРЫ

1. Moin H., Khan H.Z.I., Mobeen S., Riaz J. Airfoil's Aerodynamic Coefficients Prediction using Artificial Neural Network. *19th International Bhurban Conference on Applied Sciences and Technology (IBCAST)*, 2022, pp. 175–182.
2. Kensley B., Ruben S., Oubay H., Kenneth M. An application of neural networks to the prediction of aerodynamic coefficients of aerofoils and wings. *Applied Mathematical Modelling*, 2021, vol. 96, pp. 456 – 479.
3. Catalani G., Agarwal S., Bertrand X., Tost F., Bauerheim M., Morlier J. Neural fields for rapid aircraft aerodynamics simulations. *Sci Rep*, 2024, vol. 14.
4. Chen W., Ramamurthy A. Deep Generative Model for Efficient 3D Airfoil Parameterization and Generation. *ArXiv*, *abs/2101.02744*.
5. Espinosa Barcenas O.U., Quijada Pioquinto J.G., Kurkina E., Lukyanov O. Surrogate Aerodynamic Wing Modeling Based on a Multilayer Perceptron. *Aerospace*, 2023, vol. 10(149).
6. Prediction of aerodynamic coefficients for wind tunnel data using a genetic algorithm optimized neural network. Access mode: <https://ntrs.nasa.gov/api/citations/20030107271/downloads/20030107271.pdf> (02.11.2024)
7. Zan B., Han Z., Xu C., Liu M., Wang W. High-dimensional aerodynamic data modeling using a machine learning method based on a convolutional neural network. *Advances in Aerodynamics*, 2022, vol. 4(1), p. 39.
8. Atmaja S.T., Fajar R., Aribowo A. Optimization of deep learning hyperparameters to predict amphibious aircraft aerodynamic coefficients using grid search cross validation. *AIP Conference Proceedings*, 2023, vol. 2941(1), p. 020008.
9. Deng C., Zhao B., Yang Y., Deng A. Integer Encoding Differential Evolution Algorithm for Integer Programming. In *Proceedings of the 2010 2nd International Conference on Information Engineering and Computer Science*, Wuhan, China, 25–26 December 2010, p. 1–4.
10. OpenVSP. - Access mode: <https://openvsp.org/> (12.10.2024)

Predicting the aerodynamic characteristics of low-speed aircraft with different aerodynamic configurations using a multilayer perceptron

O. E. Lukyanov, V. H. Hoang, D. J. Guerra Guerra, E. V. Kurkina

This study focuses on selecting the hyperparameters for a multilayer perceptron (MLP) based prediction model of aircraft aerodynamic characteristics. The aircraft model includes 22 input variables covering geometry, flight conditions, and aerodynamic configurations with two lifting surfaces. Using the Latin Hypercube Sampling (LHS) method, 44,000 aircraft models were generated and analyzed with OpenVSP to obtain aerodynamic characteristics such as lift, drag, and pitch moment coefficients. This paper extends

previous research by optimizing MLP hyperparameters and employing the Integer Encoding Differential Evolution (IEDE) algorithm to improve accuracy and computational efficiency.

KEYWORDS: architecture hyperparameter, multilayer perceptron, aerodynamic characteristic, aircraft, surrogate aerodynamic modeling.