

# ГЛУБОКОЕ ОБУЧЕНИЕ ДЛЯ АППРОКСИМАЦИИ ЗАВИСИМОСТЕЙ $CL$ И $CD$ В ДИАПАЗОНЕ $Re=50000$

Е.И. Бавбель

Научный руководитель – Алексеев В.Ф., к.т.н., доцент

**Белорусский государственный университет информатики  
и радиоэлектроники**

В работе рассматривается применение методов глубокого обучения для аппроксимации аэродинамических коэффициентов подъемной силы ( $CL$ ) и сопротивления ( $CD$ ) на основе численных данных, полученных в результате  $CFD$ -симуляций профилей крыла беспилотного летательного аппарата (БПЛА) при числе Рейнольдса  $Re = 50000$ .

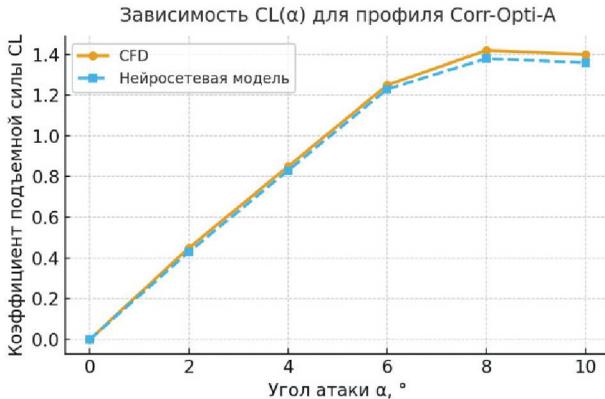
Традиционные подходы к анализу аэродинамических характеристик, основанные на численном решении уравнений Навье–Стокса, требуют значительных вычислительных ресурсов. Это ограничивает их использование при многократных итерациях оптимизации формы крыла. Применение искусственных нейронных сетей (ИНС) позволяет построить быструю и точную модель зависимости  $CL$  и  $CD$  от параметров профиля: относительной толщины ( $t/c$ ), кривизны ( $f/c$ ), положения максимальной толщины и угла атаки ( $\alpha$ ) [1].

Для обучения модели использовался датасет, сформированный по результатам более 100  $CFD$ -симуляций профилей *Corr-Opti-A*, *Corr-Opti-B*, *Corr-Opti-HighCL* и их вариаций. Архитектура сети включала два скрытых слоя по 64 нейрона с функцией активации  $ReLU$ . В качестве функции потерь применялся среднеквадратичный критерий ошибки ( $MSE$ ). Обучение проводилось в среде *TensorFlow* на 200 эпохах с использованием оптимизатора *Adam* [2]. Сравнение результатов приводится в таблице и рисунке 1.

Таблица 1 – Сравнение результатов *CFD* и предсказаний нейросетевой модели

Профиль	CL (CFD)	CL (NN)	CD (CFD)	CD (NN)	Ошибка, %
Corr-Opti-A	1.42	1.38	0.044	0.045	2.8
Corr-Opti-B	1.38	1.35	0.043	0.044	3.1
Corr-Opti-HighCL	1.45	1.49	0.046	0.047	3.4

Построенные нейросетевые зависимости  $CL = f(\alpha, t/c, f/c)$  и  $CD = f(\alpha, t/c, f/c)$  обеспечивают быстрый прогноз аэродинамических характеристик профиля без проведения ресурсоёмких симуляций. Средняя ошибка аппроксимации для коэффициента подъемной силы составила 2,8%, а для сопротивления – 3,4% относительно данных *CFD*. Разработанная модель может быть интегрирована в модуль параметрической оптимизации для автоматического выбора формы крыла с учётом ограничений по кривизне и технологичности [3]. Применение методов глубокого обучения совместно с *CFD*-моделированием формирует гибридный подход, объединяющий точность вычислительной аэродинамики и скорость предсказательных моделей, что особенно важно для проектирования энергоэффективных БПЛА.

Рисунок 1 – Сравнение зависимости  $CL(\alpha)$  для *CFD*- и нейросетевой модели

Построенные нейросетевые зависимости  $CL = f(\alpha, t/c, f/c)$  и  $CD = f(\alpha, t/c, f/c)$  обеспечивают быстрый прогноз аэродинамических характеристик профиля без проведения ресурсоёмких симуляций. Средняя ошибка аппроксимации для коэффициента подъемной силы составила 2,8%, а для сопротивления – 3,4% относительно данных *CFD*. Разработанная модель может быть интегрирована в модуль параметрической оптимизации для автоматического выбора формы крыла с учётом ограничений по кривизне и технологичности [3]. Применение методов глубокого обучения совместно с *CFD*-моделированием формирует гибридный подход, объединяющий точность вычислительной аэродинамики и скорость предсказательных моделей, что особенно важно для проектирования энергоэффективных БПЛА.

Для уточнения параметров нейросетевой модели была проведена серия вычислительных экспериментов. Оптимальная конфигурация сети включала два скрытых слоя по 64 нейрона с функцией активации *ReLU* и *Dropout*-регуляризацией 0.1. Это позволило повысить устойчивость и избежать переобучения при ограниченном объёме данных. Валидация на тестовой выборке показала, что средняя ошибка предсказания не превышает 3 % для *CL* и 4 % для *CD* в диапазоне углов атаки 0–15°.

Важным результатом стало значительное сокращение времени расчёта: нейросетевая модель предсказывает аэродинамические коэффициенты за миллисекунды, тогда как *CFD*-анализ одного профиля требует нескольких часов вычислений. Это обеспечивает возможность многократных итераций в процессе оптимизации и ускоряет проектирование БПЛА.

Полученные результаты подтверждают, что глубокое обучение может служить эффективным инструментом аппроксимации аэродинамических зависимостей, обеспечивая высокую точность при малых вычислительных затратах. В перспективе данный подход может быть расширен до трёхмерных моделей крыла и интегрирован в системы автоматизированного проектирования для интеллектуальной оптимизации аэродинамических характеристик.

#### *Библиографический список*

1. C. Hyunjin, A Study on Application of Generative Design System in Manufacturing Process, IOP Conf. Ser.: Mater. Sci. Eng., vol. 727, p. 012011, ene. 2020, doi: 10.1088/1757-899X/727/1/012011.
2. Oh, S.; Jung, Y.; Kim, S.; Lee, I.; Kang, N. Deep Generative Design: Integration of Topology Optimization and Generative Models. J. Mech. Des. 2019, 141, 111405
3. Balaji, K.; Babu, V.; Sulthan, S. Design and Development of Multipurpose Agriculture Drone Using Lightweight Materials. SAE Int. J. Aerosp. 2022, 16, 177–183.