



Научная статья

УДК 519.6

URL: <https://trudymai.ru/published.php?ID=188278>

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

СТАТИСТИЧЕСКИЙ И ПРОСТРАНСТВЕННЫЙ АНАЛИЗ В ЗАДАЧЕ ГЕНЕРАЦИИ АЭРОДИНАМИЧЕСКИХ ПРОФИЛЕЙ С ПРИМЕНЕНИЕМ ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНЫХ СЕТЕЙ

А.А. Сназин[✉]^{ORCID}, В.И. Шевченко

Военно-космическая академия имени А.Ф. Можайского, г. Санкт-Петербург, Россия

✉ alexandersnzn@mail.ru

Цитирование: Сназин А.А., Шевченко В.И. Статистический и пространственный анализ в задаче генерации аэродинамических профилей с применением генеративно-сопоставительных сетей // Труды МАИ. 2026. № 148. URL: <https://trudymai.ru/published.php?ID=188278>

Аннотация. Генерация аэродинамических профилей с помощью генеративных моделей представляет интерес как инструмент ускорения проектирования, однако её практическая ценность определяется не только визуальной правдоподобностью синтезируемых форм, но и способностью модели воспроизводить структуру распределения реальных профилей. Цель работы состояла в оценке того, насколько генеративно-сопоставительная сеть способна синтезировать профили, сохраняющие ключевые геометрические характеристики обучающей выборки и разнообразие допустимых форм. Для этого использована GAN, обученная на наборе четырёхзначных профилей НАСА, представленных в виде дискретизированных координатных векторов. Качество генерации оценивалось по распределениям максимальной толщины, положения максимальной толщины и площади профиля, а также по метрикам разнообразия, расстоянию Вассерштейна и проекциям данных в пространствах PCA и t-SNE. Установлено, что качество генерации является неравномерным по пространству форм. Модель удовлетворительно воспроизводит центральную область

распределения и основные диапазоны геометрических параметров, однако хуже описывает крайние области пространства форм, сглаживает характерные пики распределений и допускает появление некорректных образцов. Такая закономерность указывает на то, что генератор в основном концентрируется на наиболее типичных усредненных формах, и не учитывает полную геометрическую изменчивость скрытого пространства. Полученные результаты показывают, что при оценке генеративных моделей для аэродинамического проектирования необходимо учитывать не только реалистичность отдельных профилей, но и полноту покрытия пространства допустимых конфигураций.

Ключевые слова: аэродинамический профиль; генеративно-состязательные сети; метод главных компонент.

STATISTICAL AND SPATIAL ANALYSIS IN THE GENERATION OF AERODYNAMIC PROFILES USING GENERATIVE ADVERSARIAL NETWORKS

A.A. Snazin  , V.I. Sevchenko

Mozhaisky Military Space Academy, Saint Petersburg, Russia

 alexandersnzn@mail.ru

Citation: Snazin A.A., Sevchenko V.I. Statistical and spatial analysis in the generation of aerodynamic profiles using generative adversarial networks // Trudy MAI. 2026. No. 148. (In Russ.). URL: <https://trudymai.ru/published.php?ID=188278>

Abstract. The generation of aerodynamic airfoils using generative models is of interest as a means of accelerating the design process; however, its practical value is determined not only by the visual plausibility of the synthesized shapes, but also by the model's ability to reproduce the distributional structure of real airfoils. The aim of this study was to assess the extent to which a generative adversarial network can synthesize airfoils while preserving the key geometric characteristics of the training set and the diversity of admissible shapes. To this end, a GAN was trained on a dataset of four-digit NACA airfoils represented as discretized coordinate vectors. The quality of generation was evaluated using the distributions of maximum thickness, the chordwise position of maximum thickness, and airfoil area, as well as diversity metrics, the Wasserstein distance, and data

projections in the PCA and t-SNE spaces. The results indicate that the quality of generation is nonuniform across the shape space. The model reproduces the central region of the distribution and the principal ranges of geometric parameters with acceptable fidelity; however, it is less successful in describing the extreme regions of the shape space, smooths characteristic peaks in the distributions, and produces a small number of invalid samples. This pattern suggests that the generator primarily concentrates on the most typical averaged shapes and does not fully capture the geometric variability of the latent space. These findings show that the evaluation of generative models for aerodynamic design must take into account not only the realism of individual airfoils, but also the completeness of coverage of the space of admissible configurations.

Keywords: airfoil; generative adversarial networks; principal component analysis.

Введение

Эффективное проектирование аэродинамических профилей является фундаментальной задачей в аэрокосмической и машиностроительной отраслях, напрямую влияя на характеристики подъёмной силы, сопротивления и устойчивости летательных аппаратов, лопастей турбин и других инженерных устройств. Традиционные подходы к созданию профилей включают как аналитические методы (семейство профилей НАСА, использование параметрических уравнений), так и численные методы оптимизации, основанные на многоуровневых вычислениях, эвристических алгоритмах и моделях конечно-элементного анализа.

Существенный прогресс в области глубокого обучения, дал возможность автоматизировать процесс генерации и оптимизации аэродинамических форм, значительно ускоряя процесс проектирования и расширяя пространство возможных решений. Среди таких методов особое место заняли генеративно-сопоставительные сети (Generative Adversarial Networks, GAN) [1], способные обобщать сложные вероятностные распределения и синтезировать новые, достоверные образцы, ранее не встречавшиеся в обучающей выборке.

В исследованиях аэродинамических профилей прослеживаются три основных направления. Первое связано с параметризацией геометрии и классической оптимизацией: сравниваются схемы описания профиля, их выразительность и устойчивость в задачах поиска формы [2–8]. Эти работы хорошо решают задачу управляемого варьирования геометрии, однако качество результата жёстко зависит от выбранной параметризации и часто ограничивает пространство допустимых форм [6,7]. Второе направление ориентировано на обзоры и эмпирические базы, задающие методологический фон для проектирования профилей [9,10]. Третье направление — условные генеративные модели, включая CVAE и cGAN, позволяющие переходить от оптимизации параметров к прямому синтезу профилей с заданными аэродинамическими характеристиками [13,14,17,18]. Тем не менее вопросы устойчивости GAN [1,16], физической согласованности решений [15] и контролируемости генерации для заданного коэффициента подъёмной силы остаются недостаточно проработанными. Настоящее исследование посвящено оценке эффективности подобных моделей с точки зрения разнообразия и полноты покрытия пространства возможных форм.

Постановка задачи

Задача генерации аэродинамических профилей заключается в автоматическом синтезе двумерных форм крыла или иного объекта, отвечающих ряду геометрических и, потенциально, аэродинамических ограничений. Профиль описывается множеством точек (x_i, y_i) , $i = 1, \dots, N$, где x_i и y_i — координаты точек профиля крыла. Обозначим пространство допустимых профилей как $K \subset R^{2N}$. Задача синтеза заключается в построении функции $G: R^d \rightarrow K$, которая по случайному скрытому вектору z ($z \sim N(0, I_d)$) генерирует новый профиль $k_{gen} = G(z)$, неотличимый от реальных профилей k_{real} из обучающего множества.

В формализованном виде задача состоит в аппроксимации истинного распределения реальных профилей $p_{data}(k)$ с помощью параметрического распределения $p_{gen}(k)$, задаваемого генератором GAN. При этом необходимо, чтобы распределение сгенерированных профилей p_{gen} было максимально приближено к

распределению реальных профилей p_{data} по ключевым геометрическим характеристикам. Так же необходимо сохранить разнообразие сгенерированных форм допустимых профилей.

Генеративно-сопоставительная сеть [1] представляет собой структуру из двух нейронных сетей — генератора G и дискриминатора D , обучающихся в сопоставительном режиме (игра с нулевой суммой). Генератор G является функцией, принимающей на вход случайный скрытый вектор $z \in R^d$, преобразующей его в вектор профиля $k \in K$: $k_{gen} = G(z)$. Задача генератора состоит в воспроизведении профиля, который повышает вероятность быть принятым за реальный дискриминатором. Дискриминатор D — функция, принимающая на вход профиль (реальный или сгенерированный), и возвращающая скалярную вероятность «реальности»: $D(k): K \rightarrow [0,1]$. GAN достигают этого путем решения следующей минимаксной задачи:

$$\min_G \max_D V(D, G) = E_{k \sim p_{data}(x)} [\log D(k)] + E_{z \sim p_z} [\log (1 - D(G(z)))]. \quad (1)$$

В процессе обучения параметры генератора G и дискриминатора D последовательно оптимизируются до тех пор, пока дискриминатор не утратит способность надёжно различать синтетические данные и реальные образцы.

Для формирования обучающей выборки аэродинамических профилей был использован датасет четырёхзначных профилей NASA [10]. Данный класс профилей определяется тремя характеристиками: величиной максимального прогиба, положением максимального прогиба по хорде и максимальной толщиной, нормированной относительно длины хорды.

Общее количество профилей, сгенерированных для обучения, составило 5000. Геометрическая форма каждого аэродинамического профиля описывалась дискретным набором точек (рисунок 1). При этом координаты точек x и y объединялись в единый вектор следующего вида:

$$k = (x_1, x_2, \dots, x_n, y_1, y_2, \dots, y_n).$$




Рисунок 1 – Форма представления аэродинамического профиля

Результаты расчетов

В ходе обучения генеративной состязательной сети для синтеза аэродинамических профилей, одним из основных критериев качества генерации является сходство распределения параметров, вычисленных по сгенерированным и реальным профилям. К таким параметрам относятся максимальная толщина профиля $t_{\max}$, положение максимальной толщины вдоль хорды $x_{t\max}$, а также площадь профиля S :

$$t_{\max} = \max_{i=1,\dots,N} (y_{u,i} - y_{l,i}), \quad (2)$$

$$x_{t\max} = \arg \max_{x \in [0,1]} (y_u(x) - y_l(x)), \quad (3)$$

$$S = \int_0^1 (y_u(x) - y_l(x)) dx. \quad (4)$$

Сравнение распределений этих параметров может выявить наличие потери разнообразия форм, проявляющейся в чрезмерной концентрации сгенерированных форм вокруг средних значений, а также недостатке крайних значений, что наблюдается как в распределении толщины, так и площади профиля.

На рисунке 2 представлены гистограммы распределения критериев качества генерации. Распределение максимальной толщины профиля у реальных профилей более равномерно, встречаются значения в диапазоне примерно от 0.05 до 0.42 (рисунок 2а). Сгенерированные профили имеют явный пик вокруг 0.3–0.33

и гораздо чаще принимают эти значения, чем реальные. В то же время в экстремальных значениях (очень толстые профили) GAN практически не генерирует образцы.




Рисунок 2 - Гистограммы распределения критериев качества генерации:

а) максимальная толщина; б) положение максимальной толщины вдоль хорды;
в) площадь профиля

Реальные профили имеют резкий пик около значений 0.33–0.35 положения максимальной толщины вдоль хорды, что характерно для профилей NASA, также имеются небольшие разбросы до 0.5 – 0.6. Полученные с помощью генератора синтетические профили имеют большее распределение в диапазоне от 0.25 - 0.45 и не имеют четких доминирующих пиков. Распределение площади у реальных профилей близко к равномерному между 0 и 0.3. У сгенерированных профилей есть выраженный пик около 0.18–0.21, почти нет профилей с площадью больше 0.22. GAN также генерирует небольшое количество профилей с отрицательной площадью, что является артефактами генерации.

Одной из распространенных проблем GAN является потеря разнообразия форм при генерации. Для количественной оценки оценим долю уникальных сгенерированных объектов:

$$D = \frac{1}{M} \sum_{i=1}^M I[\forall j < i: d(k_i, k_j) > \varepsilon], \quad (5)$$

где M - количество сгенерированных профилей, ε – пороговое значение, I - индикаторная функция, равна 1 если условие в скобках истинно, и 0 иначе.

Другой мерой оценки схожести распределений физических параметров является расстояние Вассерштейна:

$$W_1(p_{\text{real}}, p_{\text{fake}}) = \inf_{\pi \in \Gamma(p_{\text{real}}, p_{\text{fake}})} \mathbb{E}_{(u,v) \sim \pi} [|u - v|]. \quad (6)$$

где p_{real} и p_{fake} – распределения параметра (максимальной толщины) у реальных и сгенерированных профилей, Γ — множество совместных распределений с частными распределениями p_{real} и p_{fake} .

Из рисунка 3 видно, что показатель разнообразия форм сохраняется на уровне единицы практически до конца обучения, затем происходит его снижение. Это указывает на то, что генеративно-состязательная сеть на протяжении практически всего процесса обучения генерировала высокую долю уникальных профилей. Снижение этого показателя к концу обучения свидетельствует о начале процесса потери разнообразия форм.




Рисунок 3 – Зависимости метрик разнообразие форм и расстояния Вассерштейна от количества эпох обучения GAN

Изменение расстояния Вассерштейна происходит более явно, в начале обучения GAN имеет довольно высокое значение, что говорит о том, что сгенерированные профили далеки от реальных. В районе 500-й эпохи обучения наблюдается небольшое плато, что может свидетельствовать о наличии оптимизационных ограничений. По мере дальнейшего обучения происходит быстрое уменьшение расстояния Вассерштейна, что говорит о том, что распределение сгенерированных профилей становится ближе к реальным данным.

Для оценки топологии пространства форм использованы методы понижения размерности — PCA [12] и t-SNE [11].

Проекция методом главных компонент задаётся выражением (7):

$$Z_{PCA} = (X - \bar{X})W_{PCA}, \quad (7)$$

где X — матрица исходных данных профилей размера $n \times d$ (число образцов на размерность признакового пространства); $\bar{X}$ — матрица того же размера, каждый столбец которой содержит среднее значение соответствующего признака, вычитаемое для центрирования данных; W_{PCA} — матрица $d \times k$, составленная из первых k собственных векторов ковариационной матрицы центрированных данных, упорядоченных по убыванию собственных значений ($k = 2$ для двумерной визуализации); Z_{PCA} — результирующая матрица проекций размера $n \times k$, строки которой соответствуют координатам каждого профиля в пространстве главных компонент.

В случае качественного совпадения облака реальных и сгенерированных точек в пространстве главных компонент частично перекрываются.

Метод t-SNE, в свою очередь, минимизирует расхождение Кульбака — Лейблера (8) между распределениями парных расстояний в исходном и низкоразмерном пространствах:

$$KL(P||Q) = \sum_{i \neq j} p_{ij} \log \frac{p_{ij}}{q_{ij}}, \quad (8)$$

где P — распределение вероятностей, моделирующее парное сходство точек в исходном многомерном пространстве: p_{ij} — условная вероятность того, что точка i выберет точку j своим соседом, пропорциональная гауссиану от евклидова расстояния между точками, после чего производится симметризация: $p_{ij} = (p_{j|i} + p_{i|j})/(2n)$; Q — аналогичное распределение в низкоразмерном пространстве проекции (обычно двумерном), где вероятности q_{ij} задаются через t-распределение Стьюдента с одной степенью свободы; i, j — индексы точек (профилей) в наборе данных; суммирование ведётся по всем упорядоченным парам различных точек; $KL(P || Q)$ — асимметричная мера расхождения (дивергенция Кульбака — Лейблера), минимизация которой делает

распределение Q максимально близким к P по метрике информационной энтропии.

На рисунке 4 представлено распределение проекций реальных и сгенерированных профилей в пространстве главных компонент. Как видно из рисунка реальные профили занимают равномерную область, более плотно покрывая весь диапазон. Сгенерированные профили собраны ближе к центру по вертикали и смещены правее. Вытянутый «хвост» к большим значениям первой компоненты, указывает на генерацию аномальных форм.




Рисунок 4 – Распределение проекций реальных и сгенерированных профилей в пространстве главных компонент (а) и в нелинейной проекции t-SNE (б)

Применение метода t-SNE (рисунок 4б) показало, что основная масса сгенерированных профилей проецируется в область, занимаемую реальными профилями в центральной части двумерного пространства отображения, тогда как периферийные зоны этого пространства оказываются охваченными не полностью. Данный факт указывает на недостаточное разнообразие синтезируемых форм и на то, что генератор не в полной мере использует потенциал по порождению нетипичных (периферийных в пространстве признаков) профилей.

Заключение

В работе выполнен анализ возможностей генеративно-состязательной сети для синтеза аэродинамических профилей на основе обучающей выборки, сформированной из четырёхзначных профилей NASA. Основное внимание было

сосредоточено на том, насколько получаемые профили воспроизводят структуру исходного распределения по ключевым геометрическим характеристикам и сохраняют разнообразие допустимых конфигураций.

Проведённое исследование показало, что обученная модель в целом способна корректно воспроизводить центральную область распределения реальных профилей. Это проявляется в приемлемом совпадении диапазонов основных параметров и в частичном перекрытии облаков реальных и сгенерированных данных в пространствах пониженной размерности. Выявлено, что качество генерации оказывается неравномерным по всему множеству форм: по мере удаления от наиболее представленных областей распределения точность снижается, а воспроизведение редких и крайних конфигураций становится менее надёжным. На уровне геометрических параметров это выражается в концентрации части сгенерированных профилей около наиболее типичных значений, сглаживании характерных пиков распределений и появлении отдельных некорректных образцов.

В контексте поставленной задачи полученные результаты показывают, что генеративная модель действительно усваивает статистическую структуру обучающего множества. При этом сеть достаточно уверенно воспроизводит наиболее вероятные формы, но заметно слабее работает в отношении полного охвата пространства допустимых профилей. Тем самым подтверждается, что при оценке подобных моделей одной визуальной правдоподобности недостаточно: необходим анализ распределений параметров, разнообразия выборки и топологии пространства форм.

Дальнейшее развитие работы связано прежде всего с повышением устойчивости генерации на краях распределения и с уменьшением потери разнообразия форм. Таким образом предлагаемая генеративно-состязательная сеть имеет большой потенциал для дальнейшего повышения эффективности оптимизации аэродинамических профилей.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest

The authors declare no conflict of interest.

Список источников

1. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, Generative adversarial networks, Communications of the ACM, vol. 63, no. 11, pp. 139–144, 2020.
2. Selvan, K.M. (2015). On the effect of shape parameterization on aerofoil shape optimization. International Journal of Research in Engineering and Technology.
3. Balu, R. (2017). Recent trends in geometry parameterization strategies for aerodynamic shape optimization. J Astron Aerosp Eng.
4. Wei, X., Wang, X., Chen, S. (2020). Research on parameterization and optimization procedure of low-Reynolds-number airfoils based on genetic algorithm and Bezier curve. Advances in Engineering Software, 149, 102886.
5. Fakhari, S.M., Mrad, H. (2024). Aerodynamic shape optimization of NACA airfoils based on a novel unconstrained conjugate gradient algorithm. Journal of Engineering Research.
6. Masters, D.A., Taylor, N.J., Rendall, T.C.S., Allen, C.B. (2017). Geometric comparison of aerofoil shape parameterization methods. AIAA journal, 55(3), 927-944.
7. Agarwal, D., Sahu, P. (2022). A unified approach for airfoil parameterization using Bezier curves. Computer-Aided Design and Applications, 19(6), 1130-1142.
8. Mukesh, R., Lingadurai, K., Selvakumar, U. (2014). Airfoil shape optimization using non-traditional optimization technique and its validation. Journal of King Saud University.
9. Gupta, B., Pandey, M., Sharma, A.K., Sharma, P. (2021). Recent advancements in optimization methods for wind turbine airfoil design: A review. Materials Today: Proceedings, 47, 4295-4304.
- I. H. Abbot, A. E. von Doenhoff, and L. Stivers, Jr. Summary of Airfoil Data. United States, 1945.
10. Van der Maaten, L.; Hinton, G. Visualizing data using t-SNE. J. Mach. Learn. Res. 2008,9, 2579–2605

A. Gorban, B. Kegl, D. Wunsch, A. Zinovyev (Eds.), *Principal Manifolds for Data Visualisation and Dimension Reduction*, LNCSE 58, Springer, Berlin – Heidelberg – New York, 2007.

11. K. Yonekura, K. Wada, and K. Suzuki, Generating various airfoils with required lift coefficients by combining NACA and Joukowski airfoils using conditional variational autoencoders, *Engineering Applications of Artificial Intelligence*, Vol. 108, 104560, 2022.

12. G. Achour, W. J. Sung, O. J. Pinon-Fischer, and D. N. Mavris, Development of a conditional generative adversarial network for airfoil shape optimization, *AIAA Scitech 2020 Forum*, 2020.

13. M. Raissi, P. Perdikaris, and G.E. Karniadakis, Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations, *Journal of Computational Physics*, Vol. 378, pp. 686–707, 2019.

14. N. Kodali, J. Abernethy, J. Hays, and Z. Kira, On convergence and stability of GANs, *CoRR*, arXiv:1705.07215, 2017.

15. Wang, J.; Li, R.; He, C.; Chen, H.; Cheng, R.; Zhai, C.; Zhang, M. An inverse design method for supercritical airfoil based on conditional generative models. *Chin. J. Aeronaut.* 2022, 35, 62–74.

16. Yonekura, K.; Aoki, R.; Suzuki, K. Quantification and reduction of uncertainty in aerodynamic performance of GAN-generated airfoil shapes using MC dropouts. *Theor. Appl. Mech. Lett.* 2024, 100504.

References

1. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, Generative adversarial networks, *Communications of the ACM*, vol. 63, no. 11, pp. 139–144, 2020.

2. Selvan, K.M. (2015). On the effect of shape parameterization on aerofoil shape optimization. *International Journal of Research in Engineering and Technology*.

3. Balu, R. (2017). Recent trends in geometry parameterization strategies for aerodynamic shape optimization. *J Astron Aerosp Eng*.

4. Wei, X., Wang, X., Chen, S. (2020). Research on parameterization and optimization procedure of low-Reynolds-number airfoils based on genetic algorithm and Bezier curve. *Advances in Engineering Software*, 149, 102886.
5. Fakhari, S.M., Mrad, H. (2024). Aerodynamic shape optimization of NACA airfoils based on a novel unconstrained conjugate gradient algorithm. *Journal of Engineering Research*.
6. Masters, D.A., Taylor, N.J., Rendall, T.C.S., Allen, C.B. (2017). Geometric comparison of aerofoil shape parameterization methods. *AIAA journal*, 55(3), 927-944.
7. Agarwal, D., Sahu, P. (2022). A unified approach for airfoil parameterization using Bezier curves. *Computer-Aided Design and Applications*, 19(6), 1130-1142.
8. Mukesh, R., Lingadurai, K., Selvakumar, U. (2014). Airfoil shape optimization using non-traditional optimization technique and its validation. *Journal of King Saud University*.
9. Gupta, B., Pandey, M., Sharma, A.K., Sharma, P. (2021). Recent advancements in optimization methods for wind turbine airfoil design: A review. *Materials Today: Proceedings*, 47, 4295-4304.
10. H. Abbot, A. E. von Doenhoff, and L. Stivers, Jr. *Summary of Airfoil Data*. United States, 1945.
11. Van der Maaten, L.; Hinton, G. Visualizing data using t-SNE. *J. Mach. Learn. Res.* 2008,9, 2579–2605
12. Gorban, B. Kegl, D. Wunsch, A. Zinovyev (Eds.), *Principal Manifolds for Data Visualisation and Dimension Reduction*, LNCSE 58, Springer, Berlin – Heidelberg – New York, 2007.
13. K. Yonekura, K. Wada, and K. Suzuki, Generating various airfoils with required lift coefficients by combining NACA and Joukowski airfoils using conditional variational autoencoders, *Engineering Applications of Artificial Intelligence*, Vol. 108, 104560, 2022.
14. G. Achour, W. J. Sung, O. J. Pinon-Fischer, and D. N. Mavris, Development of a conditional generative adversarial network for airfoil shape optimization, *AIAA Scitech 2020 Forum*, 2020.

15. M. Raissi, P. Perdikaris, and G.E. Karniadakis, Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations, *Journal of Computational Physics*, Vol. 378, pp. 686–707, 2019.
16. N. Kodali, J. Abernethy, J. Hays, and Z. Kira, On convergence and stability of GANs, *CoRR*, arXiv:1705.07215, 2017.
17. Wang, J.; Li, R.; He, C.; Chen, H.; Cheng, R.; Zhai, C.; Zhang, M. An inverse design method for supercritical airfoil based on conditional generative models. *Chin. J. Aeronaut.* 2022, 35, 62–74.
18. Yonekura, K.; Aoki, R.; Suzuki, K. Quantification and reduction of uncertainty in aerodynamic performance of GAN-generated airfoil shapes using MC dropouts. *Theor. Appl. Mech. Lett.* 2024, 100504.

Информация об авторах

Александр Андреевич Сназин, кандидат технических наук, старший научный сотрудник, Военно-космическая академия имени А.Ф. Можайского, г. Санкт-Петербург, Россия; ORCID: <https://orcid.org/0000-0002-2929-5194>; e-mail: alexandersnzn@mail.ru

Василий Иванович Шевченко, младший научный сотрудник, Военно-космическая академия имени А.Ф. Можайского, г. Санкт-Петербург, Россия.

Information about the authors

Aleksandr A. Snazin, Ph.D, Senior Researcher, Mozhaisky Military Space Academy, Saint Petersburg, Russia; ORCID: <https://orcid.org/0000-0002-2929-5194>; e-mail: alexandersnzn@mail.ru

Vasiliy I. Sevchenko, Junior Researcher, Mozhaisky Military Space Academy, Saint Petersburg, Russia.