

ПРОЕКТИРОВАНИЕ И КОНСТРУИРОВАНИЕ СТРОИТЕЛЬНЫХ СИСТЕМ. СТРОИТЕЛЬНАЯ МЕХАНИКА. ОСНОВАНИЯ И ФУНДАМЕНТЫ, ПОДЗЕМНЫЕ СООРУЖЕНИЯ

НАУЧНАЯ СТАТЬЯ / RESEARCH PAPER

УДК 624.042.41

DOI: 10.22227/1997-0935.2024.5.713-728

Прогнозирование аэродинамических коэффициентов на закручивающиеся формообразующие зданий и сооружений на базе машинного обучения и CFD-моделирования

Сергей Гургенович Саиян, Вероника Борисовна Шелепина

Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ); г. Москва, Россия

АННОТАЦИЯ

Введение. Проведены исследования по применению машинного обучения с целью прогнозирования аэродинамических коэффициентов на закручивающиеся формообразующие зданий и сооружений. Для обучения использовались данные аэродинамических продувок на базе численного моделирования в ANSYS CFX. Оценивалось качество прогнозов различных моделей машинного обучения по сравнению с численным моделированием. Сделаны выводы, относящиеся к использованию моделей машинного обучения для определения ветровых нагрузок на здания и сооружения.

Материалы и методы. Для анализа полученных результатов и разработки модели машинного обучения применялись язык программирования Python и библиотеки: Pandas, NumPy, Scikit-learn и Matplotlib. Рассматривались четыре метода машинного обучения: линейная регрессия, решающее дерево, метод k -ближайших соседей, случайный лес. Для формирования обучающих данных использовались аэродинамические продувки на основе методов численного моделирования в ANSYS CFX. Точность различных моделей машинного обучения в прогнозировании аэродинамических коэффициентов оценивалась на основе статистической меры соответствия R -квадрат.

Результаты. Составлена база из 217 численных решений для различных углов закручивания формообразующей здания. Эти результаты включают распределение аэродинамических коэффициентов давления по поверхности здания, а также аэродинамические коэффициенты сил и моментов (C_x , C_y , C_{Mz}) в зависимости от высоты. Данные использовались для обучения четырех моделей машинного обучения. Для лучшей модели машинного обучения (случайный лес) проведена верификация модели в сравнении с результатами численного моделирования.

Выводы. Исследованы различные модели машинного обучения для прогнозирования аэродинамических коэффициентов на здания и сооружения. Сделаны выводы о применимости методов машинного обучения в качестве альтернативного подхода к определению ветровых нагрузок.

КЛЮЧЕВЫЕ СЛОВА: машинное обучение, численное моделирование, CFD-моделирование, здания и сооружения с закручивающейся формообразующей, аэродинамические характеристики, аэродинамические коэффициенты, ветровая нагрузка на здания и сооружения

ДЛЯ ЦИТИРОВАНИЯ: Саиян С.Г., Шелепина В.Б. Прогнозирование аэродинамических коэффициентов на закручивающиеся формообразующие зданий и сооружений на базе машинного обучения и CFD-моделирования // Вестник МГСУ. 2024. Т. 19. Вып. 5. С. 713–728. DOI: 10.22227/1997-0935.2024.5.713-728

Автор, ответственный за переписку: Сергей Гургенович Саиян, berformert@gmail.com.

Prediction of aerodynamic coefficients for twisting shapes of buildings and structures based on machine learning and CFD-modelling

Sergey G. Saiyan, Veronika B. Shelepina

Moscow State University of Civil Engineering (National Research University) (MGSU);
Moscow, Russian Federation

ABSTRACT

Introduction. Research was carried out on the application of machine learning to predict aerodynamic coefficients on buildings and structures with twisted form configurations. Data from aerodynamic simulations using numerical modelling

in ANSYS CFX was used for training. The quality of predictions made by various machine learning models was evaluated in comparison to numerical simulations. Conclusions related to the use of machine learning models for determining wind loads on buildings and structures are drawn.

Materials and methods. Python programming language and the following libraries, Pandas, NumPy, Scikit-learn, and Matplotlib were used to analyze the obtained results and to develop the machine learning model. The study considered four machine learning methods: linear regression, decision tree, k -nearest neighbours, and random forest. Aerodynamic simulations based on numerical modelling methods in ANSYS CFX were used to generate the training data. The accuracy of different machine learning models in predicting aerodynamic coefficients was evaluated using the statistical measure of R -squared.

Results. As a result of the research, a database of 217 numerical solutions was compiled for various angles of twist of the building's form. These results include the distribution of aerodynamic pressure coefficients over the building's surface, as well as aerodynamic force and moment coefficients (C_x , C_y , C_{Mz}) as a function of height. The data was used to train four machine learning models. The best-performing machine learning model (random forest) was verified by comparing it to the results of numerical modelling.

Conclusions. Various machine learning models for predicting aerodynamic coefficients on buildings and structures were investigated. Conclusions were drawn regarding the applicability of machine learning methods as an alternative approach to determining wind loads.

KEYWORDS: machine learning, numerical modelling, CFD modelling, buildings and structures with twisting shaping, aerodynamic characteristics, aerodynamic coefficients, wind loads on buildings and structures

FOR CITATION: Saiyan S.G., Shelepina V.B. Prediction of aerodynamic coefficients for twisting shapes of buildings and structures based on machine learning and CFD-modelling. *Vestnik MGSU* [Monthly Journal on Construction and Architecture]. 2024; 19(5):713-728. DOI: 10.22227/1997-0935.2024.5.713-728 (rus.).

Corresponding author: Sergey G. Saiyan, berformert@gmail.com.

ВВЕДЕНИЕ

Аэродинамические характеристики зданий и сооружений играют важную роль в проектировании и эксплуатации, так как они оказывают значительное влияние на несущие и фасадные конструкции, а также на динамическую комфортность верхних этажей. В связи с этим становятся актуальными исследования, направленные на аэродинамическую оптимизацию форм высотных зданий с целью минимизации ветрового воздействия, что позволит рационализировать расходы на строительство. Оптимизация аэродинамической формы для высотных зданий связана с выбором оптимальной формообразующей, которая достигается несколькими способами: выбор аэродинамической формы, геометрическое изменение углов зданий, конические формы, а также геометрические изменения в поперечном сечении формообразующей [1]. Одним из распространенных вариантов подобной оптимизации является использование закручивающейся формообразующей высотного здания, которая снижает ветровое воздействие. Наиболее известные высотные здания с закручивающейся формообразующей: Shanghai Tower (Шанхай, Китай), Сауан Tower (Дубай, ОАЭ), Башня Эволюции (Москва, Россия), The F&F Tower (Панама Сити, Панама), Al Tjaria Tower (Кувейт), United Tower (Манама, Бахрейн), Turning Torso (Мальмё, Швеция) и др. На рис. 1 показаны фотографии высотных зданий с закручивающейся формообразующей.

Существующие способы определения ветровых нагрузок и воздействий на здания и сооружения делятся на четыре основных подхода: инженерные нормативно-аналитические методики¹ [2], испыта-

ния в аэродинамических трубах [3, 4], численное моделирование [5–10], мониторинг и реальные замеры [11, 12]. Вследствие сложных аэродинамических форм высотных зданий и сооружений необходимы современные и более продвинутое методы исследования ветровых воздействий. На настоящий момент наиболее современным методом исследования аэродинамических характеристик зданий и сооружений является численное моделирование задач гидрогазодинамики (вычислительная гидрогазодинамика), позволяющее исследовать различные формообразующие уникальных зданий и сооружений. Однако обработка полученных данных может быть трудоемкой и затратной для последующих многовариантных расчетов, поиска оптимальной формы, а также исследования аэродинамических характеристик зданий и сооружений. Применение методов на основе машинного обучения даст возможность использовать данные об аэродинамических продувках для создания прогнозных математических моделей определения аэродинамических характеристик зданий и сооружений при ветровом воздействии, что значительно упростит процесс аэродинамического анализа и выбор оптимальных вариантов формообразующих.

Машинное обучение имеет широкий спектр приложений в различных отраслях науки и техники: распознавание речи, жестов; техническая и медицинская диагностика; прогнозирование временных рядов; категоризация документов; проектирование изделий и др. Методы машинного обучения могут применяться во многих областях строительства [13]: в сфере проектирования зданий и сооружений [14, 15], планировании и управлении строительными проектами [16], безопасности на строительной площадке [17], мониторинге строительных конструкций [18] и прочих направлениях.

¹ СП 20.13330.2016. Нагрузки и воздействия (с Изменениями № 1, 2, 3). М. : Минрегион России, 2021.



Рис. 1. Высотные здания с закручивающейся формообразующей: *a* — Башня Эволюции (Москва, Россия); *b* — Cayan Tower (Дубай, ОАЭ); *c* — United Tower (Манама, Бахрейн)

Fig. 1. High-rise buildings with a twisting formative structure: *a* — Evolution Tower (Moscow, Russia); *b* — Cayan Tower (Dubai, UAE); *c* — United Tower (Manama, Bahrain)

Для задач аэродинамики рассматриваемый метод может использоваться с целью оптимизации аэродинамической формы благодаря результатам аэродинамических исследований [19–24].

Машинное обучение обычно предоставляет системам возможность учиться и совершенствоваться на основе накопленного опыта автоматически. Для интеллектуального анализа данных и последующей автоматизации ключевым моментом служит изучение алгоритмов. Алгоритмы машинного обучения можно разделить на четыре основных типа [25]:

- обучение с учителем: как правило, является задачей по изучению функции, которая сопоставляет входные данные с выходными на основе выборочных сведений. Обучение с учителем используется, когда определены цели, которые должны быть достигнуты на основе набора входных данных. Наиболее распространенные задачи обучения с учителем — задачи классификации (дискретный выходной параметр) и регрессии (непрерывный выходной параметр);

- обучение без учителя: анализирует неразмеченные данные без вмешательства экспериментатора. Наиболее распространенные задачи обучения без учителя — задачи кластеризации, уменьшения размерности, обнаружения аномалий и т.д.;

- обучение с частичным привлечением учителя: можно определить как гибрид вышеупомянутых методов, поскольку работает как с размеченными данными, так и с неразмеченными. К задачам обучения с частичным привлечением учителя относятся задачи классификации и кластеризации;

- обучение с подкреплением: позволяет испытуемой системе оценивать оптимальное поведение в определенном контексте или среде для повышения ее эффективности. Этот тип обучения основан на вознаграждении или наказании, и его конечная цель состоит в том, чтобы использовать информацию, полученную из контекста, для принятия мер по увеличению вознаграждения или минимизации риска.

Методы машинного обучения могут быть применены для обработки и анализа больших объемов данных, полученных в результате численного моделирования задач CFD (Computational Fluid Dynamics), с целью предсказания аэродинамических коэффициентов на закручивающихся формообразующих зданиях и сооружениях при ветровом воздействии.

В статье представлено описание методологии, алгоритмов применения, а также тестирование различных моделей машинного обучения для прогнозирования аэродинамических коэффициентов на закручивающиеся формообразующие изолированных зданий и сооружений при ветровом воздействии на базе численных продувок по результатам CFD-моделирования в программном комплексе (ПК) ANSYS CFX. Рассмотрены различные модели машинного обучения с целью определения оптимальных подходов, позволяющих наиболее достоверно прогнозировать аэродинамические коэффициенты на закручивающихся формообразующих изолированных зданий и сооружений. На рис. 2 показана блок-схема методики-алгоритма, используемого в настоящей статье для CFD-моделирования, фор-

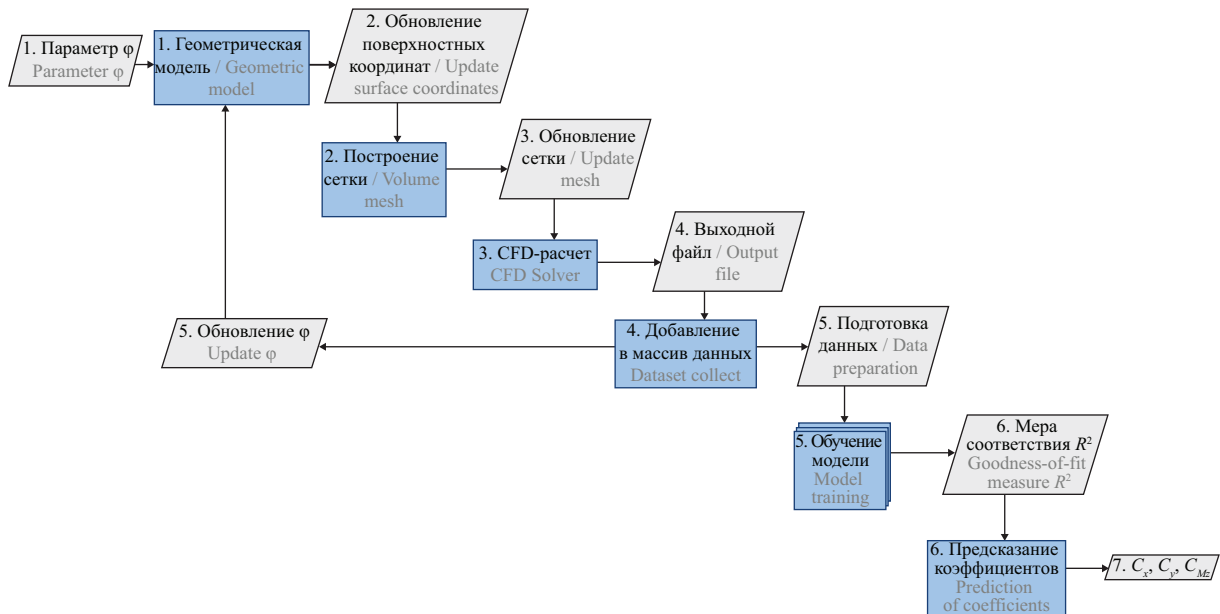


Рис. 2. Алгоритм параметрического CFD-моделирования, формирования базы данных и обучения моделей машинного обучения

Fig. 2. Algorithm of parametric CFD-simulation, database formation and machine learning model training

мирования базы данных и обучения моделей машинного обучения.

МАТЕРИАЛЫ И МЕТОДЫ

Рассматривается высотное здание размерами $40 \times 40 \times 200$ м, для которого в качестве входных параметров варьировался угол поворота формообразующей φ в диапазоне $[0^\circ; 540^\circ]$ с шагом расчета $2,5^\circ$. В виде выходных данных машинного обучения используются аэродинамические коэффициенты сил и моментов (C_x , C_y , C_{Mz}) на 20 различных уровнях высоты в диапазоне $[0; 200]$ м с шагом 10 м. На рис. 3 приведены геометрические модели для закручивающейся формообразующей здания при $\varphi = 25^\circ$ и $\varphi = 156^\circ$.

С целью создания прогнозной математической модели машинного обучения необходимы результаты аэродинамических исследований, которые будут использоваться в качестве обучающих данных. Для их формирования проводились численные аэродинамические исследования высотных изолированных зданий при ветровом воздействии, для которых параметрически изменялись углы закручивания формообразующих вокруг своей оси (рис. 3).

Для аэродинамических исследований необходимо разработать расчетную конечно-объемную модель воздушного пространства вокруг здания. Расчетная область выбрана прямоугольной формы для более устойчивого сочетания используемых граничных условий «течение в канале». Размеры расчетной области составили 2040×3440 м с высотой 1200 м и выбраны в соответствии с рекоменда-

ми². Подобные размеры необходимы для минимизации влияния выбора граничных условий на структуру течения вблизи исследуемого здания вследствие задания искусственных граничных условий атмосферы, используемых в CFD-моделировании.

В областях, где ожидается высокий градиент скоростей ветра и давлений, создается качественная мелкая сетка, в других областях — более грубая. Параметры используемых для расчетов конечно-объемных сеток представлены в таблице. На рис. 4 показан разрез конечно-объемной сетки, а также верхняя конечно-объемная сетка на здании.

Расчетной области присвоен домен Air (Воздух) со следующими физическими параметрами: тип среды — несжимаемый воздух при температуре (25°C) и давление 1 атм (рис. 5). Граничные условия на «входе» в расчетную область (*Inlet*) заданы в виде средней скорости потока ($\bar{U}(z)$) и по форме соответствуют нормативному профилю СП 20.13330.2016¹ согласно ветровому району 1 и типу местности В. Зависимости средней скорости на входе $\bar{U}(z)$ и кинетической энергии турбулентности (*TKE*) от высоты над землей представлены на рис. 5. Масштаб турбулентности принят равным 300 м в соответствии с рекомендациями Eurocode³. На «выходе» из расчетной области (*Outlet*) и на верхней границе области потока назначаются «мягкие» граничные

² Tominaga Y., Mochida A., Yoshie R. et al. AIJ guidelines for practical applications of CFD to pedestrian wind environment around buildings // Journal of Wind Engineering and Industrial Aerodynamics. 2008. No. 96. Pp. 1749–1761. DOI: 10.1016/j.jweia.2008.02.058

³ Eurocode 1: Actions on structures — Part 1–4: General actions — Wind action. CEN, 2010.

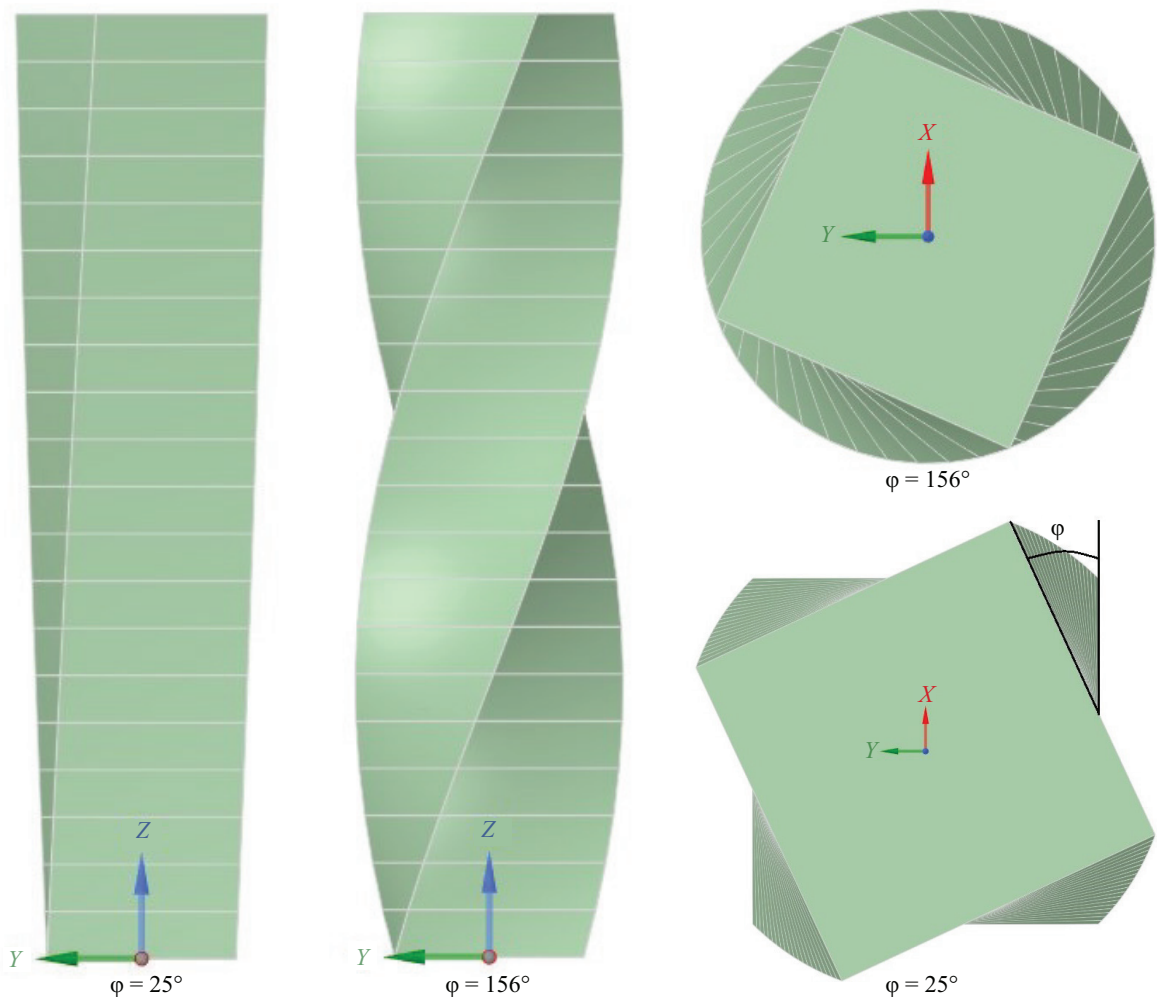


Рис. 3. Геометрия закручивающейся формообразующей здания при $\varphi = 25^\circ$ и $\varphi = 156^\circ$ (вид сбоку и сверху)
 Fig. 3. Geometry of the twisting formative structure of the building at $\varphi = 25^\circ$ and $\varphi = 156^\circ$ (side view and top view)

Параметры конечно-объемной сетки

Parameters of the finite-volume mesh

Местоположение Location	Размер элементов у поверхностей, м Size of elements at surfaces, m	Размер элементов в объеме, м Size of elements in volume, m
В прямоугольном объеме размерами 80×80 м и высотой 260 м In a rectangular volume measuring 80×80 m and 260 m high	3,0	3,0
В прямоугольном объеме размерами 640×1000 м и высотой 600 м In a rectangular volume measuring $640 \times 1,000$ m and 600 m high	8,0	12,0
В прямоугольном объеме размерами 2040×3440 м и высотой 1200 м In a rectangular volume measuring $2,040 \times 3,440$ m and 1,200 m high	25,0	50,0
На поверхности здания On the surface of the building	0,75	—

условия *Opening* с нулевыми дополнительными давлениями и такими же параметрами турбулентности, как и на «входе». На «земле» и на здании задано граничное условие «стенки с прилипанием» (No-Slip

Wall, $U = V = W = 0$ м/с), исключаяющее проникновение вещества через поверхность.

Расчеты ветровых потоков и воздействий на здания и сооружения сводятся в общем случае к чис-




Рис. 4. Сечение конечно-объемной сетки (a) и поверхностная конечно-объемная сетка на здании (b)
 Fig. 4. Finite-volume mesh section (a) and surface finite-volume mesh on the building (b)

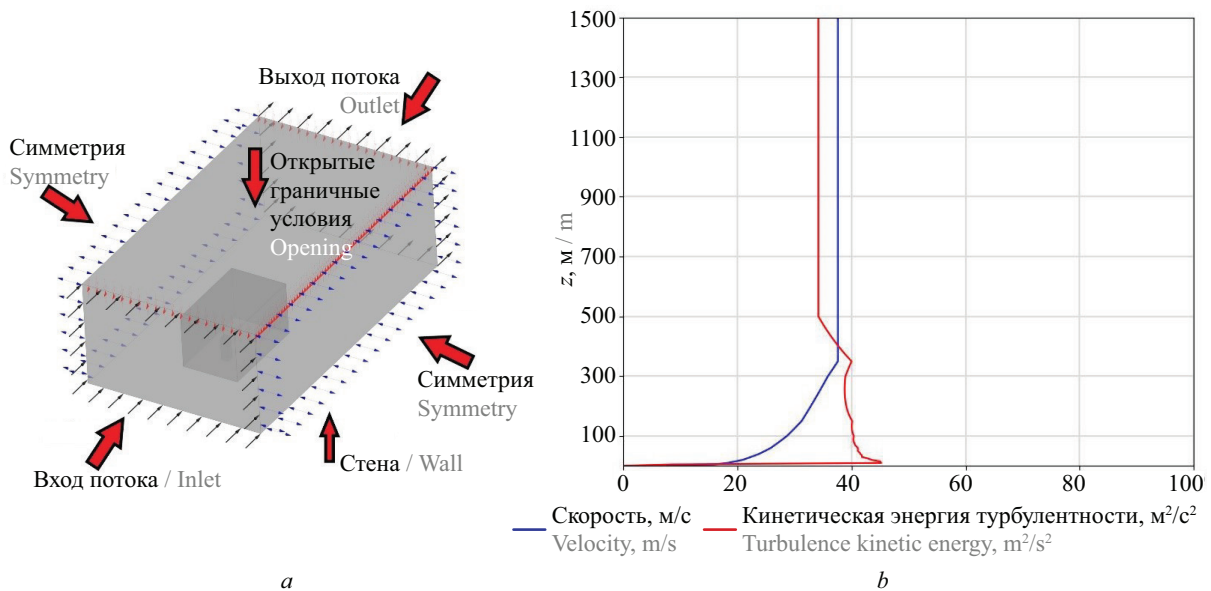


Рис. 5. Расчетная область с указанием граничных условий (a) и ветровой профиль на Inlet (b)
 Fig. 5. Calculation area with indication of boundary conditions (a) and the wind profile on the Inlet (b)

ленному решению системы трехмерных нестационарных нелинейных уравнений Навье – Стокса. В практических задачах определения ветровых нагрузок и воздействия на здания и сооружения с практически обоснованным упрощением ветровые потоки принимаются несжимаемыми ($p = \text{const}$) и изотермическими ($T = \text{const}$), а внешние массовые силы не учитываются. Тогда нестационарные и нелинейные уравнения гидрогазодинамики примут следующий вид⁴:

- уравнения движения (Навье – Стокса):

$$\frac{\partial u}{\partial t} + u \frac{\partial u}{\partial x} + v \frac{\partial u}{\partial y} + w \frac{\partial u}{\partial z} = \dots \quad (1)$$

$$\begin{aligned} &= -\frac{1}{\rho} \frac{\partial p}{\partial x} + \frac{\mu}{\rho} \left[\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} + \frac{\partial^2 u}{\partial z^2} \right]; \\ &\frac{\partial v}{\partial t} + u \frac{\partial v}{\partial x} + v \frac{\partial v}{\partial y} + w \frac{\partial v}{\partial z} = \\ &= -\frac{1}{\rho} \frac{\partial p}{\partial y} + \frac{\mu}{\rho} \left[\frac{\partial^2 v}{\partial x^2} + \frac{\partial^2 v}{\partial y^2} + \frac{\partial^2 v}{\partial z^2} \right]; \\ &\frac{\partial w}{\partial t} + u \frac{\partial w}{\partial x} + v \frac{\partial w}{\partial y} + w \frac{\partial w}{\partial z} = \\ &= -\frac{1}{\rho} \frac{\partial p}{\partial z} + \frac{\mu}{\rho} \left[\frac{\partial^2 w}{\partial x^2} + \frac{\partial^2 w}{\partial y^2} + \frac{\partial^2 w}{\partial z^2} \right]. \end{aligned} \quad (1)$$

- уравнения неразрывности и состояния:

$$\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} + \frac{\partial w}{\partial z} = 0; \quad (2)$$

⁴ Симиу Э., Сканлан Р. Воздействие ветра на здания и сооружения / пер. с англ. Б.Е. Маслова, А.В. Швецово; под ред. Б.Е. Маслова. М. : Стройиздат, 1984. 360 с.

$$p = \text{const}, \quad (3)$$

где u, v, w — искомые компоненты вектора скорости (по осям x, y, z); t — время; μ — динамический коэффициент вязкости для воздуха; p — давление.

Прямое численное моделирование (Direct Numerical Simulation — DNS) (1)–(3) с учетом вихрей всех масштабов при современных возможностях ЭВМ практически реализуемо только для очень малых скоростей потока и чисто исследовательских задач с использованием суперкомпьютеров.

Для практических целей в настоящей статье применяется подход к моделированию турбулентности, основанный на разложении скорости на осредненную во времени и пульсационную составляющие ($u_i(t) = \bar{u}_i + u_i'(t)$), так называемые осредненные по Рейнольдсу уравнения Навье – Стокса (Reynolds Averaged Navier – Stokes — RANS). По совокупности своих качеств одной из оптимальных RANS-моделей турбулентности является модель Ментера (Menter Shear Stress Transport Turbulence Model, сокращенно — SST-модель)^{5, 6}. SST-модель представляет собой комбинацию k - ϵ и k - ω моделей турбулентности, обеспечивающую сочетание лучших качеств этих моделей. Модель k - ϵ хорошо справляется с расчетом струйных и сдвиговых течений, а модель k - ω обеспечивает более точное описание пристеночных пограничных слоев. В модели SST комбинируются k - ϵ и k - ω с помощью сконструированной для этого эмпирической функции (функции

переключателей), которая обеспечивает близость суммарной модели к модели k - ϵ вдали от твердых стенок и к модели k - ω в пристеночной части потока (вблизи здания).

Для анализа полученных результатов и разработки модели машинного обучения был написан программный код, для которого использовался язык программирования Python и библиотеки:

- Pandas — хранение и обработка данных;
- NumPy — численные расчеты и обработка информации;
- Scikit-learn — методы машинного обучения;
- Matplotlib — визуализация информации.

В ходе исследования рассматривались четыре метода машинного обучения: линейная регрессия, решающее дерево, метод k -ближайших соседей, случайный лес. Представленные методы являются популярными методами машинного обучения с учителем, используя алгоритмы линейной (линейная регрессия) и нелинейной (решающее дерево, метод k -ближайших соседей, случайный лес) регрессии⁷.

Линейная регрессия⁸. Это модель зависимости одной переменной y от другой переменной x с линейной функцией зависимости:

$$y_i = \beta_0 + \beta_1 x_i, \quad (4)$$

где y_i — зависимая переменная; β_0, β_1 — параметры модели; x_i — независимая переменная.

Для оценки параметров линейной регрессии применяется метод наименьших квадратов, который находит числовые значения из условий минимизации суммы квадратов отклонений y_i по вертикали от линии регрессии:

$$D = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 = \sum_{i=1}^n \epsilon_i^2. \quad (5)$$

На рис. 6 показана блок-схема алгоритма линейной регрессии.

⁵ Franke J., Hirsch C., Jensen G., Krüis H.W., Schatzmann M., Westbury P.S., Miles S.D., Wisse J.A., Wright N.G. Recommendations on the use of CFD in wind engineering // Proceedings of the International Conference on Urban Wind Engineering and Building Aerodynamics. Van Beeck JPAJ (Ed.), COST Action C14, Impact of Wind and Storm on City Life Built Environment, von Karman Institute, Sint-Genesius-Rode, Belgium, 5–7 May 2004.

⁶ Tominaga Y., Mochida A., Yoshie R., Kataoka H., Nozu T., Yoshikawa M., Shirasawa T. AIJ guidelines for practical applications of CFD to pedestrian wind environment around buildings // Journal of Wind Engineering and Industrial Aerodynamics. 2008. No. 96 (10–11). Pp. 1749–1761.

⁷ 10 Popular Regression Algorithms in Machine Learning of 2022 // UNext.

⁸ Linear Regression // MLU-Explain. URL: <https://mlu-explain.github.io/linear-regression/>

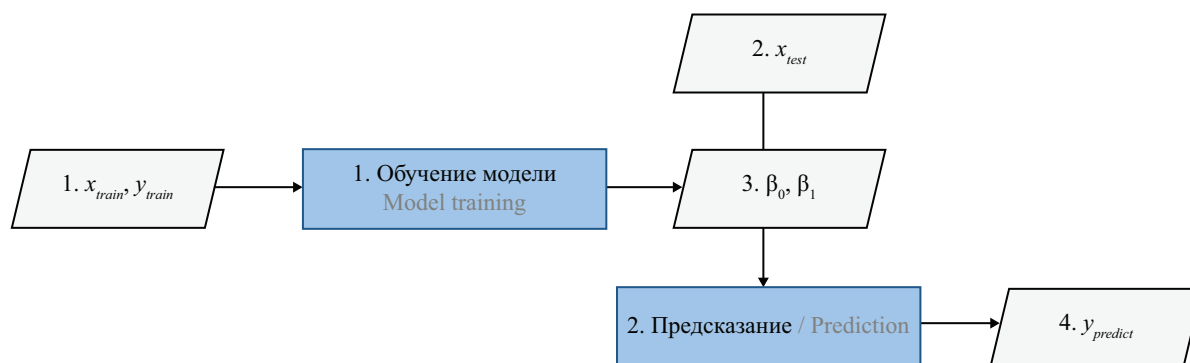


Рис. 6. Алгоритм линейной регрессии⁸

Fig. 6. Linear regression algorithm⁸

Решающее дерево⁹. Решающее дерево (дерево решений) — это непараметрический метод обучения с учителем, работающий как для задач классификации, так и для задач регрессии. На каждой итерации для входного подмножества обучающего множества строится такое разбиение пространства гиперплоскостью, которое минимизировало бы среднюю меру неоднородности двух полученных подмножеств. Данная процедура выполняется рекурсивно для каждого полученного подмножества до тех пор, пока не будут достигнуты критерии остановки. Для задач регрессии мерой неоднородности является среднеквадратическая ошибка (*MSE*):

$$MSE = \frac{1}{l} \sum_{i=1}^l \left(y_i - \frac{1}{l} \sum_{i=1}^l y_i \right)^2, \quad (6)$$

где *l* — число объектов в подмножестве; *y_i* — значение целевого признака.

В настоящем исследовании глубина решающего дерева не ограничивалась.

На рис. 7 показана блок-схема алгоритма решающего дерева.

Метод *k*-ближайших соседей¹⁰. Регрессия *k*-ближайших соседей — это непараметрический метод, который интуитивно аппроксимирует связь между независимыми переменными и непрерывным результатом, усредняя наблюдения в одной и той же

окрестности. Для каждой тестируемой точки необходимо найти такую окрестность, чтобы в ней поместились *k* точек с известными значениями *y*. Тогда прогноз для тестируемой точки можно получить, усредняя значение отклика всех обучающих наблюдений из окрестности:

$$f(x) = \frac{1}{k} \sum_{x_i \in N_k(x)} y_i, \quad (7)$$

где *N_k(x)* — множество ближайших к *x* объектов. В настоящем исследовании количество соседей было принято равным 5.

На рис. 8 представлена блок-схема алгоритма метода *k*-ближайших соседей.

Случайный лес¹¹. Данный метод является расширением к регрессии решающего дерева. Каждое решающее дерево имеет высокую дисперсию, однако при их параллельном объединении результирующая дисперсия невелика, поскольку результат зависит не от одного дерева, а от нескольких. В задачах регрессии конечным результатом случайного леса служит среднее значение всех выходных деревьев решений.

В настоящем исследовании глубина решающих деревьев не ограничивалась, количество деревьев было увеличено до 300 (*n_estimators* = 300). На рис. 9 показана блок-схема алгоритма случайного леса.

⁹ Regression Trees // Medium.

¹⁰ K-nearest Neighbours Regression // Bookdown. URL: https://bookdown.org/tpinto_home/Regression-and-Classification/k-nearest-neighbours-regression.html

¹¹ Random Forest Regression in Python // GeeksforGeeks. URL: <https://www.geeksforgeeks.org/random-forest-regression-in-python/>

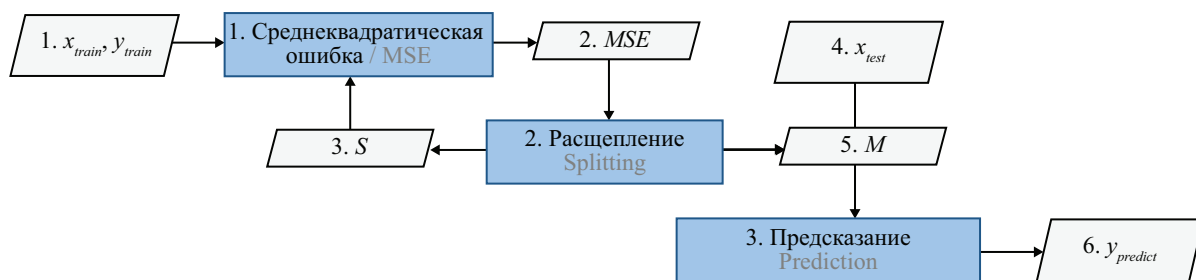


Рис. 7. Алгоритм решающего дерева: *S* — подмножество; *M* — модель⁹

Fig. 7. Decision tree algorithm: *S* — subset; *M* — model⁹

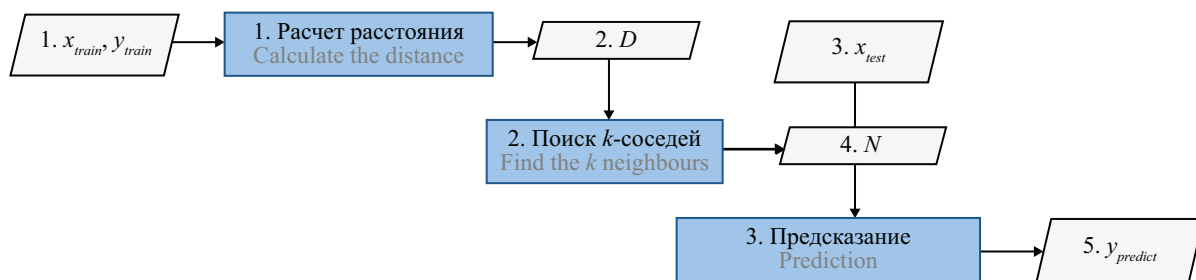


Рис. 8. Алгоритм метода *k*-ближайших соседей: *D* — расстояние между данными; *N* — область, содержащая *k* соседей¹⁰

Fig. 8. K-Nearest Neighbours method algorithm: *D* is the distance between the data; *N* is the area containing *k* neighbours¹⁰

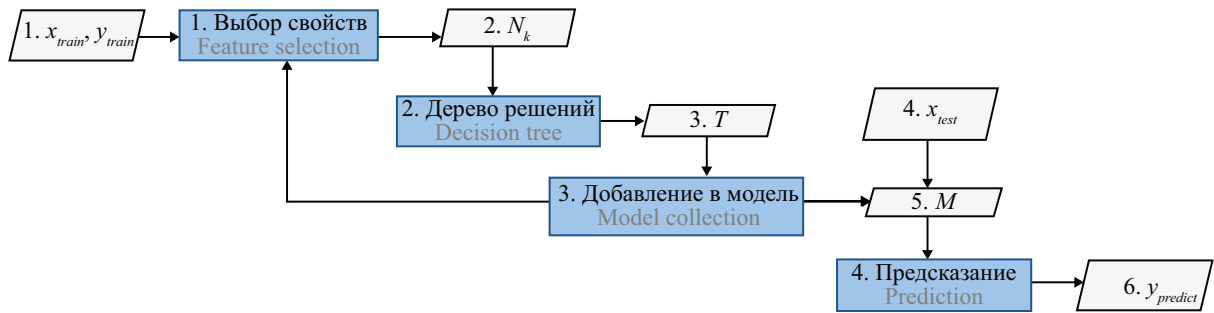


Рис. 9. Алгоритм случайного леса: N_k — случайный выбор k параметров; T — дерево решений; M — модель¹¹

Fig. 9. Random forest algorithm: N_k is a random selection of k parameters; T is a decision tree; M is a model¹¹

Показатель точности. Для оценки точности использовалась статистическая мера соответствия R -квадрат:

$$R^2 = 1 - \frac{\sum (\hat{y}_i - y_i)^2}{\sum (y_i - \bar{y})^2}, \quad (8)$$

где y_i — реальные значения y в каждом наблюдении; \hat{y}_i — значения, предсказанные моделью; \bar{y} — среднее по всем реальным значениям y_i .

В данном исследовании для каждой целевой переменной, представляющей собой аэродинамические коэффициенты сил и моментов (C_x , C_y , C_{Mz}) на 20 различных уровнях высоты, была построена отдельная регрессионная модель.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

На основе результатов, полученных в ходе вычислений, составлена база данных из 217 вариантов

расчетов при различных углах закручивания формообразующей здания φ . Изополя аэродинамических коэффициентов давления на зданиях с разным углом закручивания представлены на рис. 10.

Приведем результаты параметрического исследования изменения аэродинамических коэффициентов сил и моментов (C_x , C_y , C_{Mz}) для всех компонент по высоте в зависимости от параметра угла закручивания формообразующей здания φ на различных уровнях высоты (рис. 11).

С помощью библиотеки Scikit-learn база данных была разделена на тренировочную и тестовую выборки, где тренировочная выборка составила 75 % от всей базы сведений, тестовая — 25 %. В функции `train_test_split` использовался параметр первоначальной перестановки данных `random_state = 42`. Перестановка данных необходима для изучения признаков каждого значения целевой переменной и обеспечивает




Рис. 10. Изополя аэродинамических коэффициентов для зданий с углом закручивания: a — $\varphi = 10^\circ$; b — $\varphi = 180^\circ$; c — $\varphi = 360^\circ$

Fig. 10. Isofields of aerodynamic coefficients for buildings with a twist angle: a — $\varphi = 10^\circ$; b — $\varphi = 180^\circ$; c — $\varphi = 360^\circ$

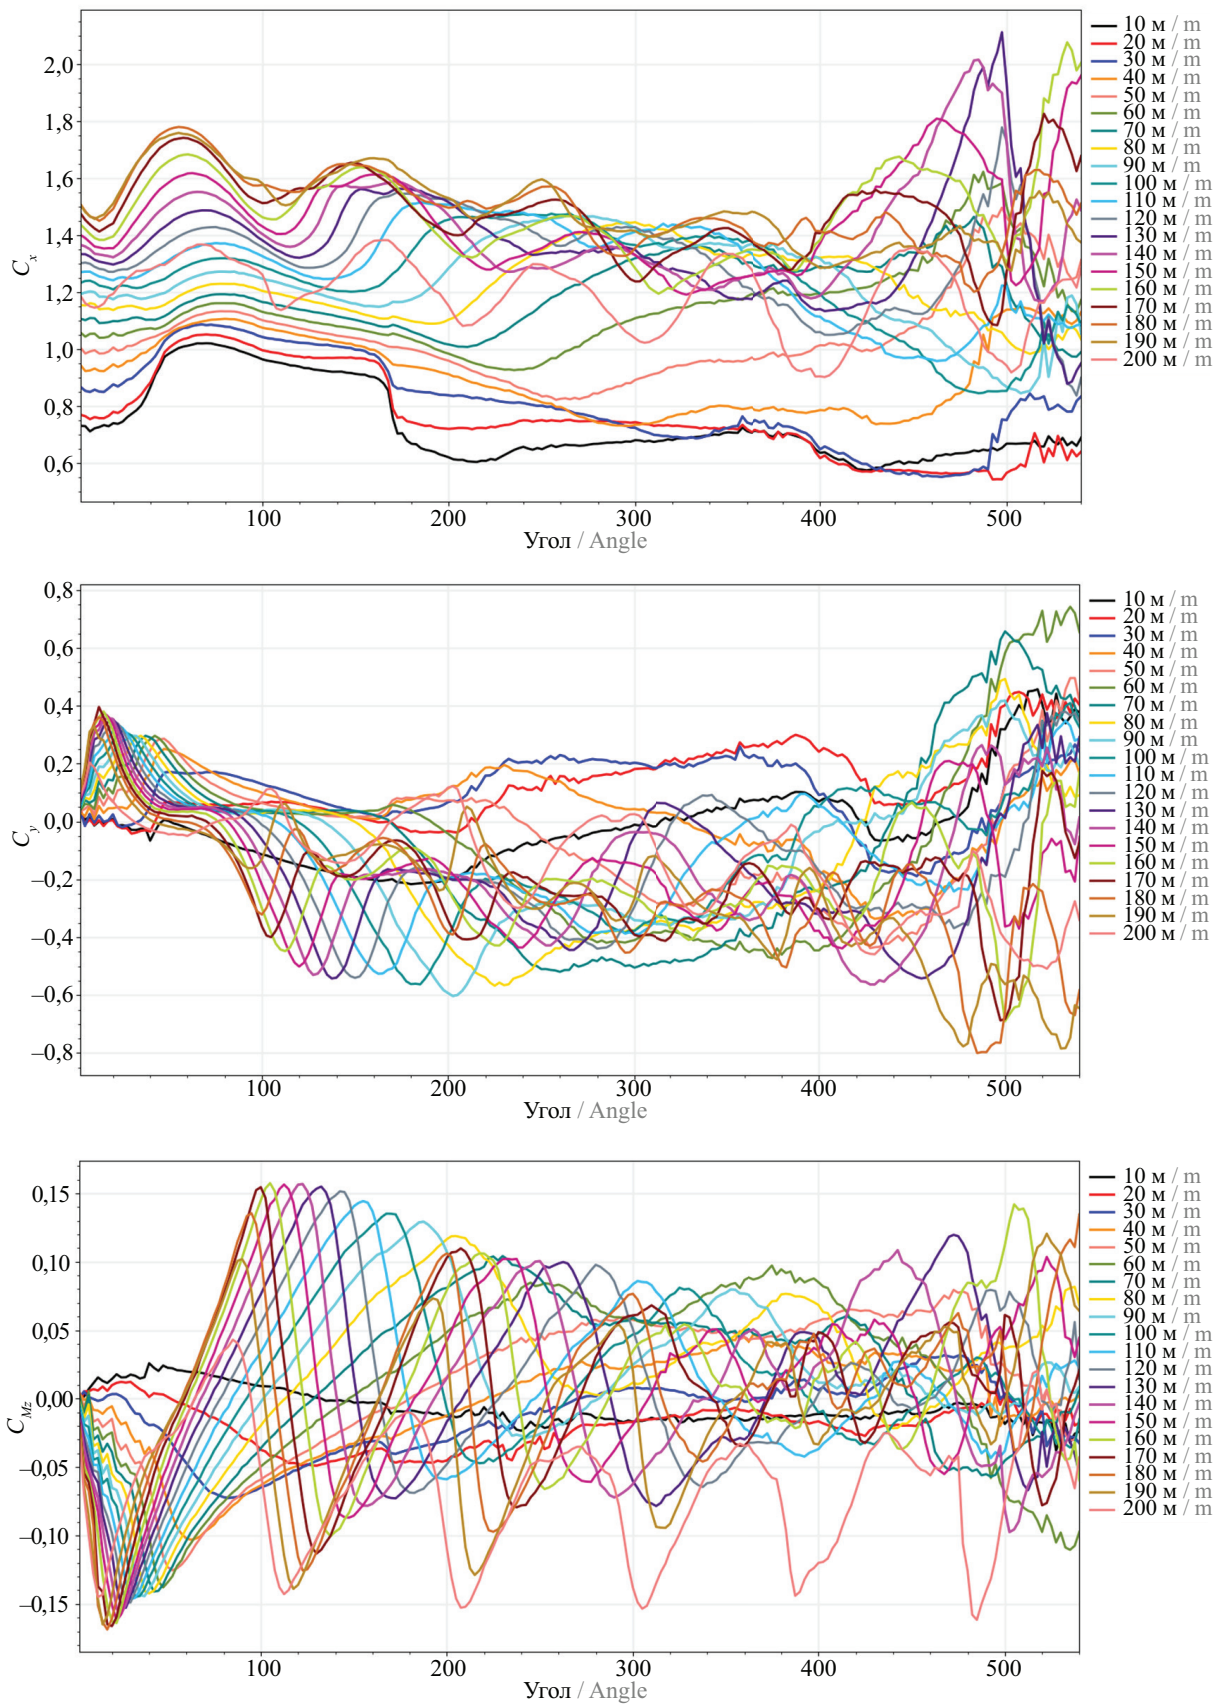


Рис. 11. Графики зависимостей аэродинамических коэффициентов сил и моментов (C_x , C_y , C_{Mz}) для всех компонент по высоте в зависимости от параметра угла закручивания формообразующей здания φ

Fig. 11. Graphs of the dependences in aerodynamic coefficients of forces and moments (C_x , C_y , C_{Mz}) for all components in height, depending on the parameter of the twist angle of the building shape φ

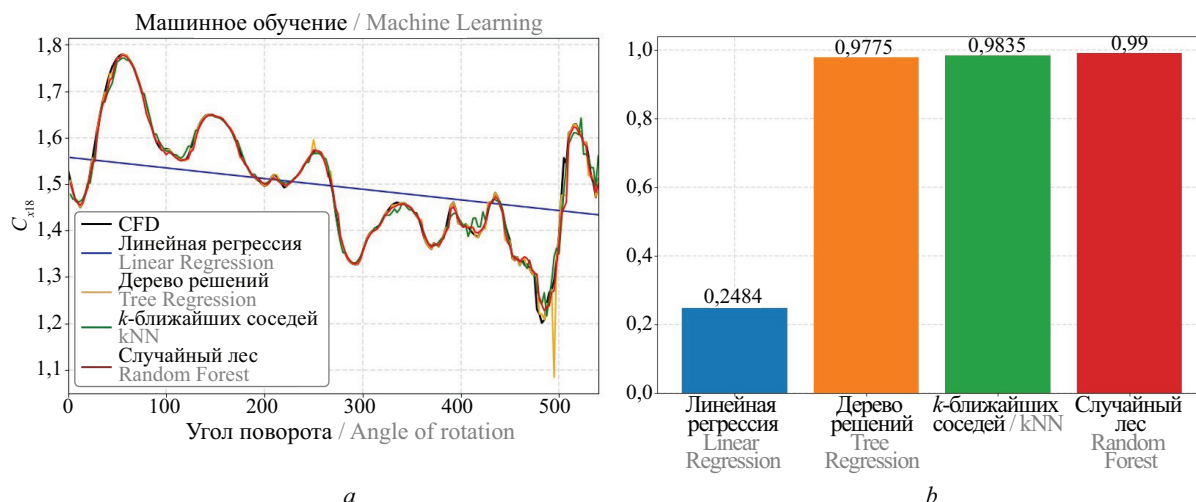


Рис. 12. Графики изменения аэродинамического коэффициента C_x на высоте 170–180 м и предсказания моделей машинного обучения (а); гистограмма коэффициентов детерминации для разных моделей машинного обучения (б)

Fig. 12. Graphs of changes in aerodynamic coefficient C_x at an altitude of 170–180 m and predictions of machine learning models (а); histogram of determination coefficients for different machine learning models (б)

разнообразие данных для обучения модели машинного обучения. При «отключении» первоначальной перестановки данных (shuffle = False) в тренировочную выборку попадают результаты расчетов для высоты здания от 0 до 160 м, а предсказание производится для высоты здания от 160 до 200, из-за чего модель окажется непригодной для тестовой выборки и проверки точности обучения. Для визуализации результатов машинного обучения и сравнения предсказанных значений с реальными была выбрана 18 компонента здания, находящаяся на высоте 170–180 м (рис. 12, а). С целью установления точности вычислений определен коэффициент детерминации R -квадрат для каж-

дой компоненты здания и найдено среднее значение (рис. 12, б).

Оценив точность обученных моделей, можно сделать вывод, что линейная регрессия не подходит для определения аэродинамических коэффициентов. Наибольшую точность показал метод случайный лес, однако такой результат обусловлен и большими временными затратами на обучение (4,63235 с) по сравнению с деревом решений (0,01561 с) и методом k -ближайших соседей (0,015621 с), что является важным показателем для больших задач, где время вычислений значительно.

Для верификации модели случайный лес вычислим аэродинамические коэффициенты для про-

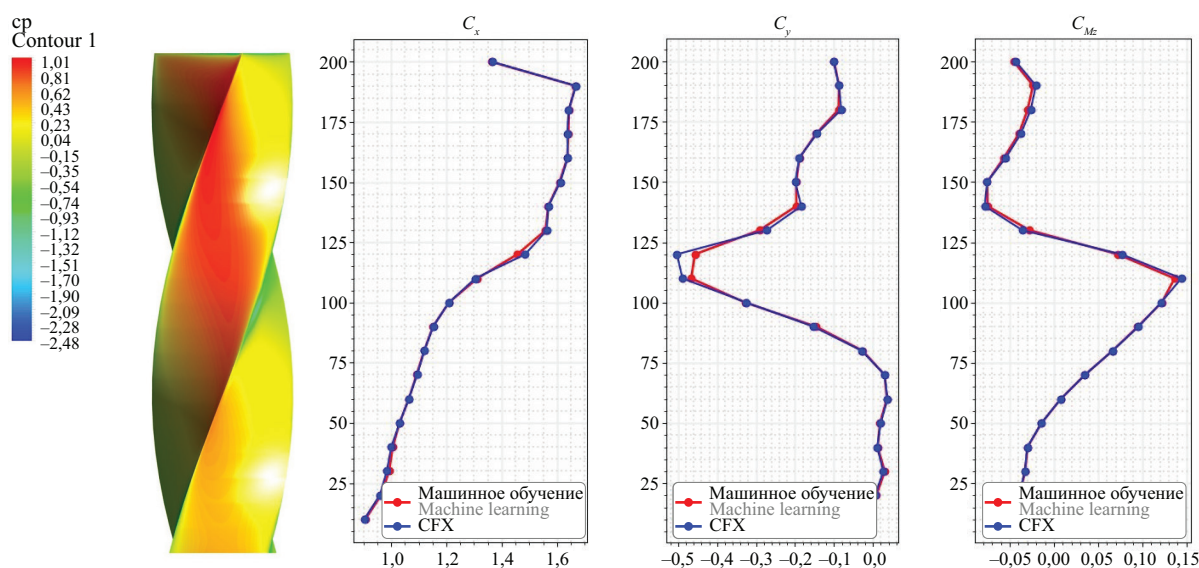


Рис. 13. Графики изменения аэродинамических коэффициентов сил и моментов (C_x , C_y , C_{Me}) по всей высоте здания

Fig. 13. Graphs of changes in aerodynamic coefficients of forces and moments (C_x , C_y , C_{Me}) over the entire height of the building

межуточного варианта закручивания здания с углом закручивания $\varphi = 156^\circ$ (соответствующий углу закручивания башни «Эволюция») как обученной моделью машинного обучения, так и используя ПК ANSYS CFX, и сравним полученные результаты (рис. 13).


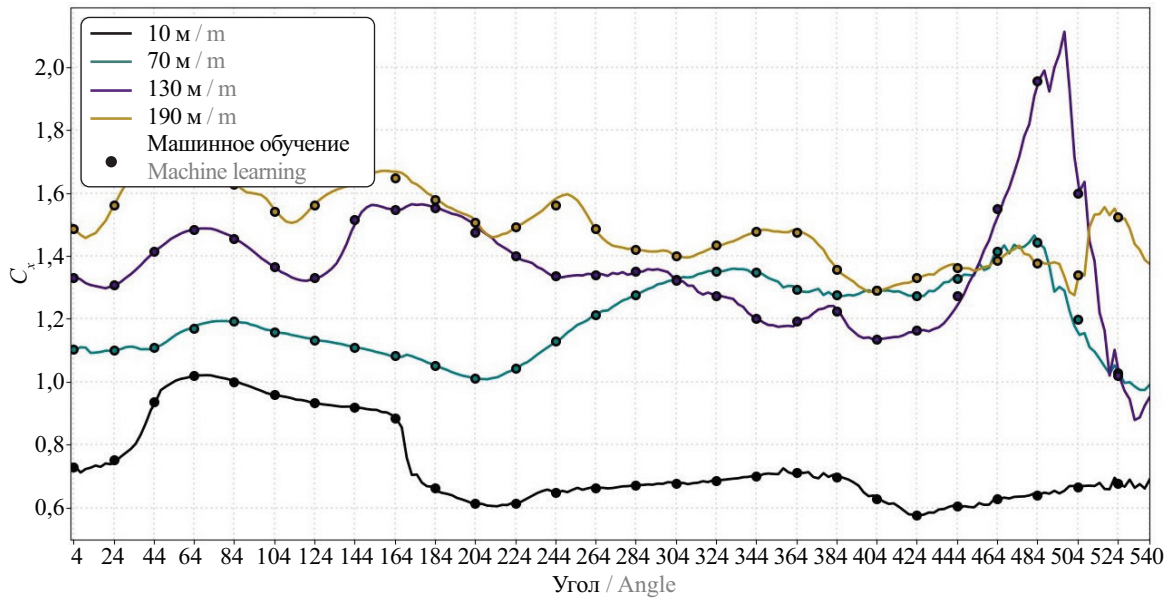
Из результатов сопоставительного анализа видна хорошая корреляция вычислений аэродинамических коэффициентов на основе расчетов CFD-моделирования и прогноза моделей машинного обучения. Приведем более полный сопоставительный анализ для различных компонент по высоте здания в зависимости от угла закручивания формирующей φ (рис. 14, 15). Для оценки точности полученной модели машинного обучения были рассчитаны аэродинамические коэффициенты для промежуточных значений угла закручивания формирующей φ в диапазоне от 4 до 540° с шагом расчета 20° .

Как видно из результатов, погрешности вычислений у модели машинного обучения составляют не более 5%. Основным преимуществом такого подхода служит время расчета по сравнению с численным моделированием в ПК ANSYS CFX.

ЗАКЛЮЧЕНИЕ И ОБСУЖДЕНИЕ

На основании проведенных исследований по прогнозированию аэродинамических коэффициентов на закручивающиеся формообразующие зданий и сооружений с использованием моделей машинного обучения можно сделать следующие выводы.

Проведены аэродинамические исследования зданий и сооружений с закручивающейся формообразующей в ПК ANSYS CFX, на основе которых создана база данных результатов из 217 вариантов для обучения модели машинного обучения. Применение CFD-моделирования позволило получить детальную



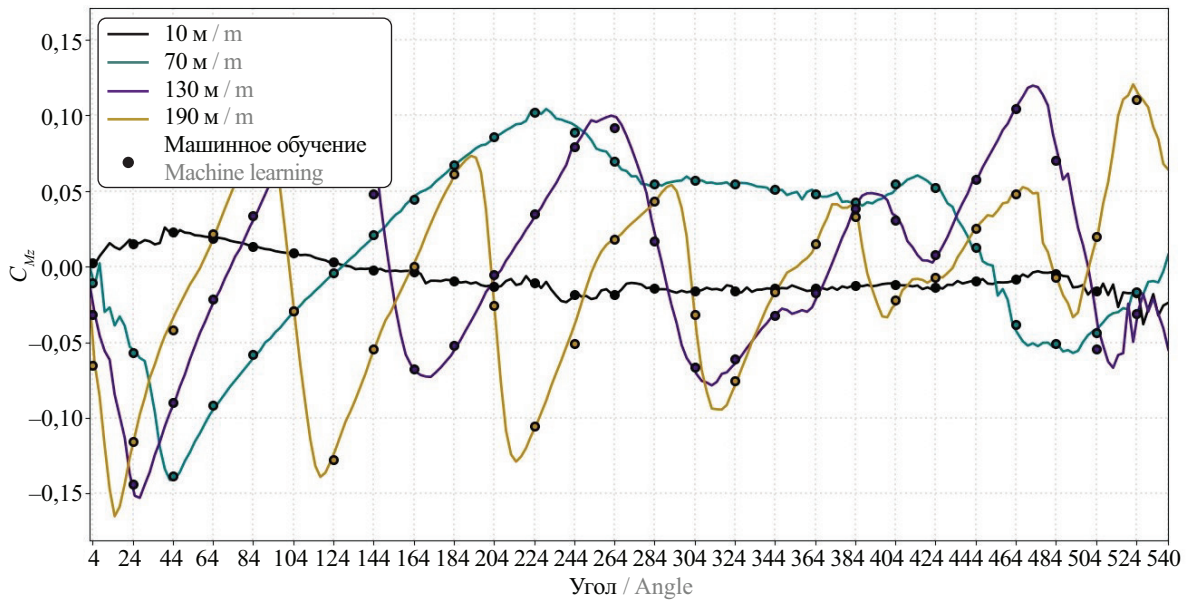


Рис. 14. Сопоставление результатов расчета аэродинамических коэффициентов сил и моментов (C_x , C_y , C_{Me}) от параметра угла закручивания формообразующей здания φ по результатам CFD-моделирования (сплошные линии) и машинного обучения по модели случайный лес (точки)

Fig. 14. Comparison of the results of calculation of aerodynamic coefficients of forces and moments (C_x , C_y , C_{Me}) from the parameter of the twist angle of the building shape φ based on the results of CFD modelling (solid lines) and machine learning based on the random forest model (dots)

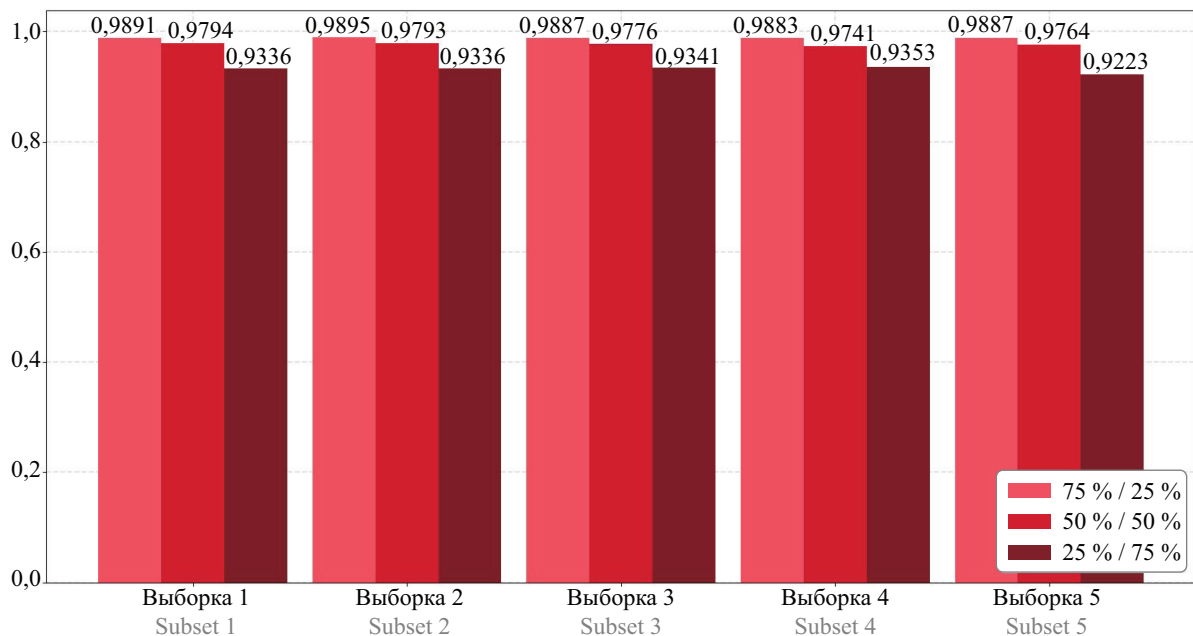


Рис. 15. Сравнение коэффициентов детерминации для различных выборок с различным соотношением тестовой и тренировочной выборок для метода случайный лес

Fig. 15. Comparison of determination coefficients for different specimens with different ratio of test and training specimens for the random forest method

информацию об аэродинамических характеристиках зданий и сооружений и использовать эти данные для обучения моделей машинного обучения.

Протестированы различные модели машинного обучения для прогноза аэродинамических коэффициентов для зданий и сооружений с закручивающейся

формообразующей. В результате исследования было показано, что машинное обучение может быть эффективным инструментом для предсказания аэродинамических характеристик зданий и сооружений. Так, на основе сопоставительного анализа различных моделей установлено, что наилучший прогноз аэродина-

мических коэффициентов из рассмотренных наиболее простых и популярных моделей машинного обучения дает метод случайный лес. Для этого метода проведен сопоставительный анализ результатов расчета аэродинамических коэффициентов сил и моментов (C_x , C_y , C_{Mz}) от параметра угла закручивания формирующей здания ϕ с результатами CFD-моделирования, показав хорошее совпадение результатов с численным решением в ANSYS CFX (с погрешностью до 5 %), что говорит о высокой степени достоверности полученных результатов машинного обучения.

Результаты настоящего исследования подтверждают применимость методов машинного обучения на базе CFD-моделирования для прогнозирования аэродинамических коэффициентов на здания и сооружения с закручивающейся формообразующей.

Данное направление исследования имеет практическую значимость, связанную с проектированием и оптимизацией аэродинамических характеристик зданий и сооружений, посредством подбора рациональных формообразующих, что дает возможность быстрого и эффективного анализа множества различных вариантов формы. Однако для успешного применения машинного обучения требуется качественная подготовка и предварительная обработка данных, а также правильный выбор и обучение моделей. Необходимо также учитывать ограничения и пределы применимости используемых моделей. Требуется дальнейшая работа для определения оптимальных параметров моделей машинного обучения, а также расширения применимости полученных моделей на другие типы формообразующих.

СПИСОК ИСТОЧНИКОВ

1. *Moonoghi M.A., Kargarmoakhar R.* Aerodynamic mitigation and shape optimization of buildings : review // *Journal of Building Engineering*. 2016. Vol. 6. Pp. 225–235. DOI: 10.1016/j.jobe.2016.01.009
2. *Stathopoulos T., Alrawashdeh H.* Wind loads on buildings: A code of practice perspective // *Journal of Wind Engineering and Industrial Aerodynamics*. 2020. Vol. 206. P. 104338. DOI: 10.1016/j.jweia.2020.104338
3. *Сатанов А.А., Васин А.Д.* Экспериментальное исследование распределения ветрового давления на высотное здание уникальной формы // *Приволжский научный журнал*. 2021. № 3 (59). С. 38–46. EDN AANDEZ.
4. *Егорычев О.О., Чурин П.С.* Экспериментальное исследование ветровых нагрузок на высотные здания // *Жилищное строительство*. 2015. № 6. С. 20–22. EDN TZVIWT.
5. *Saiyan S., Andreev V., Paushkin A.* Numerical simulation of accelerations of the upper floors of a high-rise building under wind influence // *Lecture Notes in Civil Engineering*. 2022. Pp. 269–279. DOI: 10.1007/978-3-031-10853-2_25
6. *Belostotsky A., Afanasyeva I., Negrozova I., Goryachevsky O.* Simulation of aerodynamic instability of building structures on the example of a bridge section. Part 2: Solution of the problem in a coupled aeroelastic formulation and comparison with engineering estimates // *International Journal for Computational Civil and Structural Engineering*. 2021. Vol. 17. Issue 3. Pp. 24–38. DOI: 10.22337/2587-9618-2021-17-3-24-38
7. *Zheng X., Montazeri H., Blocken B.* CFD simulations of wind flow and mean surface pressure for buildings with balconies: Comparison of RANS and LES // *Building and Environment*. 2020. Vol. 173. P. 106747. DOI: 10.1016/j.buildenv.2020.106747
8. *Rezaeiha A., Montazeri H., Blocken B.* On the accuracy of turbulence models for CFD simulations of vertical axis wind turbines // *Energy*. 2019. Vol. 180. Pp. 838–857. DOI: 10.1016/j.energy.2019.05.053
9. *Дубинский С.И.* Численное моделирование ветровых воздействий на высотные здания и комплексы : дис. ... канд. тех. наук. М. : МГСУ, 2010. 198 с. EDN QEVMD.
10. *Белостоцкий А.М., Акимов П.А., Афанасьева И.Н.* Вычислительная аэродинамика в задачах строительства : учебное пособие. М. : АСВ, 2017. 720 с.
11. *Zhang F.L., Xiong H.B., Shi W.X., Ou X.* Structural Health Monitoring of shanghai tower during different stages using a Bayesian approach // *Structural Control and Health Monitoring*. 2016. Vol. 23. Issue 11. Pp. 1366–1384. DOI: 10.1002/stc.1840
12. *Lapin V.A., Yezhanov S.Y., Makish N.K.* Monitoring the behavior of a high-rise building under wind loads // *IOP Conference Series: Materials Science and Engineering*. 2020. Vol. 953. Issue 1. P. 012087. DOI: 10.1088/1757-899X/953/1/012087
13. *Колчин В.Н.* Специфика применения технологии «искусственного интеллекта» в строительстве // *Инновации и инвестиции*. 2022. № 3. С. 250–253. EDN JJLECU.
14. *Málaga-Chuquitaype C.* Machine learning in structural design : an opinionated review // *Frontiers in Built Environment*. 2022. Vol. 8. DOI: 10.3389/fbuil.2022.815717
15. *Sun H., Burton H.V., Huang H.* Machine learning applications for building structural design and performance assessment : state-of-the-art review // *Journal of Building Engineering*. 2021. Vol. 33. P. 101816. DOI: 10.1016/j.jobe.2020.101816

16. *Nguyen P.T.* Application machine learning in construction management // TEM Journal. 2021. Pp. 1385–1389. DOI: 10.18421/tem103-48
17. *Lee J., Lee S.* Construction site safety management: A computer vision and deep learning approach // Sensors. 2023. Vol. 23. Issue 2. P. 944. DOI: 10.3390/s23020944
18. *Gomez-Cabrera A., Escamilla-Ambrosio P.J.* Review of machine-learning techniques applied to structural health monitoring systems for building and bridge structures // Applied Sciences. 2022. Vol. 12. Issue 21. P. 10754. DOI: 10.3390/app122110754
19. *Wu T., Snaiki R.* Applications of machine learning to wind engineering // Frontiers in Built Environment. 2022. Vol. 8. DOI: 10.3389/fbuil.2022.811460
20. *Li J., Du X., Martins J.R.R.A.* Machine learning in aerodynamic shape optimization // Progress in Aerospace Sciences. 2022. Vol. 134. P. 100849. DOI: 10.1016/j.paerosci.2022.100849
21. *Peng W., Zhang Y., Laurendeau E., Desmaisons M.C.* Learning aerodynamics with neural network // Scientific Reports. 2022. Vol. 12. Issue 1. DOI: 10.1038/s41598-022-10737-4
22. *Ahmed S., Kamal K., Ratlamwala T.A., Mathavan S., Hussain G., Alkahtani M. et al.* Aerodynamic analyses of airfoils using machine learning as an alternative to RANS simulation // Applied Sciences. 2022. Vol. 12. Issue 10. P. 5194. DOI: 10.3390/app12105194
23. *Zan B.W., Han Z.H., Xu C.Z., Liu M.Q., Wang W.Z.* High-dimensional aerodynamic data modeling using a machine learning method based on a convolutional neural network // Advances in Aerodynamics. 2022. Vol. 4. Issue 1. DOI: 10.1186/s42774-022-00128-8
24. *Yang B.* Wind engineering for high-rise buildings : a review // Wind and Structures. 2021. Vol. 32. Issue 3. Pp. 249–265. DOI: 10.12989/was.2021.32.3.249
25. *Sarker I.H.* Machine learning: algorithms, real-world applications and research directions // SN Computer Science. 2021. Vol. 2. Issue 3. DOI: 10.1007/s42979-021-00592-x

Поступила в редакцию 20 мая 2023 г.

Принята в доработанном виде 9 октября 2023 г.

Одобрена для публикации 7 марта 2024 г.

ОБ АВТОРАХ: **Сергей Гургенович Саиян** — младший научный сотрудник Научно-образовательного центра компьютерного моделирования уникальных зданий, сооружений и комплексов им. А.Б. Золотова (НОЦ КМ им. А.Б. Золотова), аспирант кафедры сопротивления материалов; **Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ)**; 129337, г. Москва, Ярославское шоссе, д. 26; РИНЦ ID: 987238, Scopus: 57195230884, ORCID: 0000-0003-0694-4865; Berformert@gmail.com;

Вероника Борисовна Шелепина — студентка; **Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ)**; 129337, г. Москва, Ярославское шоссе, д. 26; veronika.shel@mail.ru.

Вклад авторов:

Саиян С.Г. — научное руководство, концепция исследования, методология исследования, анализ результатов исследования, написание исходного текста статьи, научное редактирование текста, итоговые выводы.

Шелепина В.Б. — сбор и анализ материалов по ML-исследованиям, проведение CFD-моделирования, создание иллюстраций, тестирование моделей машинного обучения, обработка и анализ результатов исследования.

Авторы заявляют об отсутствии конфликта интересов.

REFERENCES

1. *Mooneghi M.A., Kargarmoakhar R.* Aerodynamic mitigation and shape optimization of buildings : review. *Journal of Building Engineering*. 2016; 6:225-235. DOI: 10.1016/j.jobee.2016.01.009
2. *Stathopoulos T., Alrawashdeh H.* Wind loads on buildings: A code of practice perspective. *Journal of Wind Engineering and Industrial Aerodynamics*. 2020; 206:104338. DOI: 10.1016/j.jweia.2020.104338
3. *Satanov A.A., Vasin A.D.* Experimental study of wind pressure distribution on a unique shape high-rise building. *Privolzhsky Scientific Journal*. 2021; 3(59):38-46. EDN AANDEZ. (rus.).
4. *Egorychev O.O., Churin P.S.* Experimental study of wind loads on high-rise buildings. *Housing Construction*. 2015; 6:20-22. EDN TZVIWT. (rus.).
5. *Saiyan S., Andreev V., Paushkin A.* Numerical simulation of accelerations of the upper floors of a high-rise building under Wind Influence. *Lecture Notes in Civil Engineering*. 2022; 269-279. DOI: 10.1007/978-3-031-10853-2_25
6. *Belostotsky A., Afanasyeva I., Negrozova I., Goryachevsky O.* Simulation of aerodynamic instability of building structures on the example of a bridge section. Part 2: Solution of the problem in a coupled aeroelastic formulation and comparison with engineer-

ing estimates. *International Journal for Computational Civil and Structural Engineering*. 2021; 17(3):24-38. DOI: 10.22337/2587-9618-2021-17-3-24-38

7. Zheng X., Montazeri H., Blocken B. CFD simulations of wind flow and mean surface pressure for buildings with balconies: Comparison of RANS and LES. *Building and Environment*. 2020; 173:106747. DOI: 10.1016/j.buildenv.2020.106747

8. Rezaeiha A., Montazeri H., Blocken B. On the accuracy of turbulence models for CFD simulations of vertical axis wind turbines. *Energy*. 2019; 180:838-857. DOI: 10.1016/j.energy.2019.05.053

9. Dubinskii S.I. *Numerical modeling of wind effects on high-rise buildings : diss. ... Ph.D.* Moscow, MGSU, 2010; 198. EDN QEVMND. (rus.).

10. Belostotskii A.M., Akimov P.A., Afanas'eva I.N. *Computational aerodynamics in construction problems : textbook*. Moscow, ASV Publ., 2017; 720. (rus.).

11. Zhang F.L., Xiong H.B., Shi W.X., Ou X. Structural Health Monitoring of shanghai tower during different stages using a Bayesian approach. *Structural Control and Health Monitoring*. 2016; 23(11):1366-1384. DOI: 10.1002/stc.1840

12. Lapin V.A., Yerzhanov S.Y., Makish N.K. Monitoring the behavior of a high-rise building under wind loads. *IOP Conference Series: Materials Science and Engineering*. 2020; 953(1):012087. DOI: 10.1088/1757-899X/953/1/012087

13. Kolchin V.N. The specifics of the use of "artificial intelligence" technology in construction. *Innovation and Investment*. 2022; 3:250-253. EDN JJLECU. (rus.).

14. Málaga-Chuquitaype C. Machine learning in structural design : an opinionated review. *Frontiers in Built Environment*. 2022; 8. DOI: 10.3389/fbuil.2022.815717

15. Sun H., Burton H.V., Huang H. Machine learning applications for building structural design and performance assessment : state-of-the-art review. *Journal of Building Engineering*. 2021; 33:101816. DOI: 10.1016/j.jobbe.2020.101816

16. Nguyen P.T. Application machine learning in construction management. *TEM Journal*. 2021; 1385-1389. DOI: 10.18421/tem103-48

17. Lee J., Lee S. Construction site safety management: A computer vision and deep learning approach. *Sensors*. 2023; 23(2):944. DOI: 10.3390/s23020944

18. Gomez-Cabrera A., Escamilla-Ambrosio P.J. Review of machine-learning techniques applied to structural health monitoring systems for building and bridge structures. *Applied Sciences*. 2022; 12(21):10754. DOI: 10.3390/app122110754

19. Wu T., Snaiki R. Applications of machine learning to wind engineering. *Frontiers in Built Environment*. 2022; 8. DOI: 10.3389/fbuil.2022.811460

20. Li J., Du X., Martins J.R.R.A. Machine learning in aerodynamic shape optimization. *Progress in Aerospace Sciences*. 2022; 134:100849. DOI: 10.1016/j.paerosci.2022.100849

21. Peng W., Zhang Y., Laurendeau E., Desmarais M.C. Learning aerodynamics with neural network. *Scientific Reports*. 2022; 12(1). DOI: 10.1038/s41598-022-10737-4

22. Ahmed S., Kamal K., Ratlamwala T.A., Mathavan S., Hussain G., Alkahtani M. et al. Aerodynamic analyses of airfoils using machine learning as an alternative to RANS simulation. *Applied Sciences*. 2022; 12(10):5194. DOI: 10.3390/app12105194

23. Zan B.W., Han Z.H., Xu C.Z., Liu M.Q., Wang W.Z. High-dimensional aerodynamic data modeling using a machine learning method based on a convolutional neural network. *Advances in Aerodynamics*. 2022; 4(1). DOI: 10.1186/s42774-022-00128-8

24. Yang B. Wind engineering for high-rise buildings : a review. *Wind and Structures*. 2021; 32(3):249-265. DOI: 10.12989/was.2021.32.3.249

25. Sarker I.H. Machine learning: algorithms, real-world applications and research directions. *SN Computer Science*. 2021; 2(3). DOI: 10.1007/s42979-021-00592-x

Received May 20, 2023.

Adopted in revised form on October 9, 2023.

Approved for publication on March 7, 2024.

BIONOTES: **Sergey G. Saiyan** — junior researcher at the Scientific and Educational Center for Computer Modeling of Unique Buildings, Structures and Complexes named after A.B. Zolotova, postgraduate student of the Department of Strength of Materials; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; ID RSCI: 987238, Scopus: 57195230884, ORCID: 0000-0003-0694-4865; Berformert@gmail.com;

Veronika B. Shelepina — student; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; veronika.shel@mail.ru.

Contribution of the authors:

Sergey G. Saiyan — scientific guidance, research concept, research methodology, analysis of research results, writing the original text of the article, scientific editing of the text, final conclusions.

Veronika B. Shelepina — collection and analysis of ML research materials, conducting CFD modeling, creating illustrations, testing machine learning models, processing and analyzing research results.

The authors declare that there is no conflict of interest.