

НАУЧНАЯ СТАТЬЯ / RESEARCH PAPER

УДК 624.042.41

DOI: 10.22227/1997-0935.2025.3.381-393

Применение методов машинного обучения для прогнозирования аэродинамических коэффициентов давления на здания и сооружения прямоугольных форм

Сергей Гургенович Саиян, Вероника Борисовна Шелепина

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

АННОТАЦИЯ

Введение. Ветровые воздействия являются одним из ключевых факторов при расчете зданий и сооружений. Нормативные расчеты, физическое и численное моделирование, а также натурные измерения имеют ряд ограничений в применении. Использование технологий машинного обучения (ML) открывает новые возможности для оперативного и точного прогнозирования ветровых нагрузок. Рассматривается применение ML-моделей для оценки распределения аэродинамических коэффициентов давления на здания прямоугольных форм, что позволяет не только вычислять интегральные характеристики (силы, моменты), но и детально анализировать распределение нагрузок по фасадам.

Материалы и методы. Для обучения моделей использовалась база данных Токийского политехнического университета, в которой представлены результаты испытаний в аэродинамической трубе на моделях зданий различной высоты и ширины. Произведена аугментация данных, что увеличило исходный объем выборки и повысило способность ML-моделей обобщать различные геометрические конфигурации. В ходе обработки признаков учитывались разные углы атаки ветра, а также анализировалась корреляция признаков с целью устранения мультиколлинеарности. Основными методами прогнозирования выступили линейная регрессия, дерево решений и градиентный бустинг (CatBoost).

Результаты. Проведенные расчеты показали, что наилучший баланс между точностью предсказаний и сохранением физической интерпретируемости обеспечил градиентный бустинг над решающим деревом (CatBoost), снизив среднюю взвешенную ошибку до 16–18 %. Дополнительно выполнено сопоставление с результатами аэродинамических испытаний, что подтвердило адекватность предложенного подхода.

Выводы. Применение методов машинного обучения, в частности градиентного бустинга, дает возможность надежно прогнозировать аэродинамические коэффициенты давления на различные габаритные формы зданий при широком диапазоне углов ветровой атаки. Полученные результаты демонстрируют перспективность использования ML-моделей для ускорения и удешевления этапов оценки ветровых воздействий.

КЛЮЧЕВЫЕ СЛОВА: ветровая нагрузка, машинное обучение (ML), аугментация данных, дерево решений, градиентный бустинг, аэродинамический коэффициент, здания и сооружения

ДЛЯ ЦИТИРОВАНИЯ: Саиян С.Г., Шелепина В.Б. Применение методов машинного обучения для прогнозирования аэродинамических коэффициентов давления на здания и сооружения прямоугольных форм // Вестник МГСУ. 2025. Т. 20. Вып. 3. С. 381–393. DOI: 10.22227/1997-0935.2025.3.381-393

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

Application of machine learning methods to predict aerodynamic pressure coefficients on rectangular buildings and structures

Sergey G. Saiyan, Veronica B. Shelepina

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

ABSTRACT

Introduction. Wind effects are one of the key factors in the design of buildings and structures. Normative calculations, physical and numerical modelling, as well as in-situ measurements have a number of limitations in application. The use of machine learning (ML) technologies opens up new opportunities for rapid and accurate prediction of wind loads. The application of ML models to assess the distribution of aerodynamic pressure coefficients on rectangular buildings is considered, which allows not only to calculate integral characteristics (forces, moments), but also to analyze in detail the distribution of loads on facades.

Materials and methods. For model training, the Tokyo Polytechnic University database was used, which presents the results of wind tunnel tests on building models of various heights and widths. Data augmentation was performed, which increased the original example size and increased the ability of ML models to generalize various geometric configurations.

During feature processing, different angles of wind attack were taken into account, and the correlation of features was analyzed in order to eliminate multicollinearity. Linear regression, decision tree and gradient boosting (CatBoost) were the main prediction methods.

Results. The calculations showed that the best balance between the accuracy of predictions and maintaining physical interpretability was provided by gradient boosting over the decision tree (CatBoost), reducing the average weighted error to 16–18 %. In addition, a comparison was made with the results of aerodynamic tests, which confirmed the adequacy of the proposed approach.

Conclusions. The application of machine learning methods, in particular gradient boosting, makes it possible to reliably predict aerodynamic pressure coefficients on various dimensional shapes of buildings at a wide range of wind attack angles. The obtained results demonstrate the promising use of ML models to accelerate and reduce the cost of wind impact assessment stages.

KEYWORDS: wind load, machine learning (ML), data augmentation, decision tree, gradient boosting, aerodynamic coefficient, buildings and structures

FOR CITATION: Saiyan S.G., Shelepina V.B. Application of machine learning methods to predict aerodynamic pressure coefficients on rectangular buildings and structures. *Vestnik MGSU* [Monthly Journal on Construction and Architecture]. 2025; 20(3):381-393. DOI: 10.22227/1997-0935.2025.3.381-393 (rus.).

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

ВВЕДЕНИЕ

Ветровые воздействия — один из ключевых факторов при расчете несущей способности зданий, особенно высотных. Рост этажности и усложнение архитектурных и конструктивных решений требуют совершенствования методов оценки ветровых нагрузок. Сегодня используют четыре основных подхода: нормативные методы, физическое моделирование (экспериментальные исследования) в аэродинамических трубах (АДТ), численное моделирование (CFD), а также мониторинг (натурные замеры). Каждый способ имеет свои преимущества и недостатки.

Нормативные методики [1] хорошо оценивают средние ветровые нагрузки, но не учитывают эффекты вихреобразования и пульсаций, особенно в сложной застройке. Экспериментальные исследования (в градиентных аэродинамических трубах) [2–5] дают детализированную картину распределения давлений, но обходятся дорого и необходима длительная подготовка. CFD-моделирование [6–9] позволяет гибко анализировать обтекание, однако остается вычислительно затратным и нуждается в валидации. Натурные наблюдения [10–13] дают самые достоверные данные о средних и пульсационных нагрузках, но доступны лишь на реальном объекте и требуют значительных затрат.

Активно развиваются методы машинного обучения (ML), изначально применявшиеся в анализе больших данных (Big Data), а сейчас все шире используемые в различных областях науки и техники, в том числе в аэродинамике сооружений. ML-модели способны быстро выдавать прогнозы ветровых нагрузок по заданным входным параметрам, выявлять сложные нелинейные связи и оптимизировать форму здания. Зарубежные исследования [14–19] показывают эффективность ML для расчета аэродинамических коэффициентов, однако в российской литературе таких работ мало. В отдельных отечественных исследованиях [20] авторами были выявлены значительные недостатки: небольшой объем данных, руч-

ная настройка весов, отсутствие учета неопределенности и некорректно выбранные целевые функции.

В работе авторов [21] описан подход с использованием ML и CFD для оценки аэродинамических характеристик закручивающихся высотных зданий, где обучение на 217 численных решениях дало точность до 5 %. В большинстве публикаций фокус направлен на интегральные аэродинамические коэффициенты (силы, моменты), что не предоставляет картины распределения нагрузок по фасадам.

Научная новизна настоящего исследования заключается в анализе распределения аэродинамических коэффициентов давления на гранях зданий с применением ML, а также в методологии выбора оптимального подхода (модели) для прогнозирования.

МАТЕРИАЛЫ И МЕТОДЫ

Для обучения моделей использовалась база данных Токийского политехнического университета¹, представляющая собой результаты испытаний в АДТ для моделей домов прямоугольных форм. Размеры домов варьируются с шагом 0,1 по высоте — от 0,1 до 0,5, по ширине — 0,1 до 0,3, по глубине размер фиксирован — 0,1. В используемой базе данных приведены расчеты для угла ветровой атаки в диапазоне (0, 90) градусов с шагом 5 градусов. Результаты испытаний приведены в виде аэродинамического давления в датчиках (рис. 1), расположенных на гранях домов, для 32 с времени с шагом 0,001. В настоящем исследовании рассматривается определение средних значений аэродинамического коэффициента ветрового давления.

Подготовка данных. Для формирования входных данных значения нестационарных расчетов были сгруппированы по датчикам методом среднего.

¹ Wind Engineering Information Center. TPU Aerodynamic Database URL: <https://wind.arch.t-kougei.ac.jp/system/eng/contents/code/tpu>




Рис. 1. Изополя средних аэродинамических коэффициентов для угла ветровой атаки 0 и 45 градусов

Fig. 1. Isopoles of average aerodynamic coefficients for 0 and 45 degrees wind angle of attack

Координаты датчиков переведены в относительное расстояние от центра грани по формулам:

$$\hat{x} = \frac{x - \left(\frac{side}{2}\right)}{\left(\frac{side}{2}\right)}; \quad \hat{y} = \frac{y - \left(\frac{h}{2}\right)}{\left(\frac{h}{2}\right)}, \quad (1)$$

где x, y — исходные координаты; $side$ — ширина или глубина в зависимости от грани; h — высота.

Полученный датасет содержит 85 500 строк. Учитывая специфику задачи, количество данных является недостаточным для ее решения с допустимой точностью.

Аугментацией данных называется процесс искусственного генерирования данных на основе существующих. Один из методов создания новых сведений — интерполяция.

В исследовании использовался следующий подход:

- каждому дому $id1$ ставится в соответствие каждый другой дом $id2$;
- модель интерполяции $id2$ генерирует значения аэродинамического коэффициента для координат датчиков из $id1$.

Таким образом, в результате аугментации данных конечный датасет содержит 676 400 строк, т.е. количество данных возросло более чем в 7 раз.

Преобразование признаков. Информация об угле ветровой атаки представлена в градусной форме, в то время как для учета периодичности следует использовать тригонометрическую:

$$\sin = \sin\left(\alpha \cdot \frac{\pi}{180}\right); \quad \cos = \cos\left(\alpha \cdot \frac{\pi}{180}\right), \quad (2)$$

где α — угол атаки ветра.

Давление на различных гранях одного дома сильно отличается между собой, однако разделять их на разные модели машинного обучения не следует — они тесно связаны с углом ветровой атаки и являются компонентами одного дома. Для создания такой связи выразим все грани через первую, рассматривая их как расчеты для разных углов ветровой атаки,

в том числе и выходящие за диапазон расчетов. С целью учета периодичности воспользуемся приведенной выше формулой и переведем угол в тригонометрический вид.

Отбор признаков. Корреляция между признаками и целевой переменной играет важную роль в задачах регрессии. Кроме того, что подобная оценка позволяет убрать из модели признаки с нулевой корреляцией, она дает возможность выявить взаимосвязи между признаками. Использование признаков с сильной корреляцией (мультиколлинеарностью) может привести к следующим проблемам: нестабильность оценки модели, переобучение, потеря информации за счет обработки избыточных признаков.

В случаях мультиколлинеарности признаков применяют различные методы, в исследовании авторов применялось удаление одного из признаков. По приведенной матрице на рис. 2, а можно заметить сильную корреляцию между координатой датчика и ее относительным расстоянием, оставив один из этих признаков, мы не только сохраним, но и улучшим точность, снизив при этом время обработки и обучения моделей. На рис. 2, б представлена матрица корреляции для признаков, которые участвуют в итоговом обучении модели, и целевой переменной (коэффициент).

Линейная регрессия. Основной задачей линейной регрессии является нахождение линейных связей между признаками и целевой переменной. Для случая множественной регрессии, когда функция зависит от нескольких переменных, формула имеет вид:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon, \quad (3)$$

где $x_1, x_2, \dots, x_n$ — независимые переменные (признаки); $\beta_1, \beta_2, \dots, \beta_n$ — коэффициенты, соответствующие каждому из признаков; ϵ — отклонение фактического значения от предсказанного.

Дерево решений. Дерево решений в задачах регрессии разбивает данные, основываясь на выборе признаков и значений, которые минимизируют ошибку. Математически этот процесс можно описать как разбиение данных на две части так, чтобы




Рис. 2. Матрица корреляции для исходных данных (a) и матрица корреляции для признаков, отобранных для обучения (b)
Fig. 2. The correlation matrix for the initial data (a) and the correlation matrix for the features selected for training (b)

снизить выбранную ошибку (обычно MSE). Предсказания значений получаются из листовых узлов, которыми называют концы ветвей дерева решений, и рассчитываются как среднее значение целевой переменной в этом узле.

Градиентный бустинг. Градиентный бустинг — это ансамблевый метод, который последовательно обучает несколько деревьев решений, обучая каждое новое на тех данных, с которыми не справились предыдущие, тем самым улучшая точность и позволяя создать модель с более высокой точностью. Градиентный бустинг пусть и уступает нейросетевым моделям в гибкости, но выигрывает в простоте настройки и служит одним из сильнейших алгоритмов для решения регрессионных задач.

Использованная в работе библиотека *CatBoost* позволяет детально настраивать параметры обучения модели градиентного бустинга над решающим деревом. Некоторые гиперпараметры, такие как: скорость обучения, количество итераций, глубина дерева и минимальное количество листьев определялось с помощью библиотеки *Optuna*. Обучение модели производилось в два этапа: 1000 итераций с шагом обучения 0,1, затем 2500 итераций с шагом обучения 0,05, чтобы достигнуть баланса между производительностью и сложностью модели. Невысокие значения шага обучения делают обучение более стабильным и осторожным, что позволяет избежать резких скачков в весах модели и, как следствие, переобучения.

Прочие гиперпараметры:

1. Метрика оценки — средняя абсолютная ошибка (MAE). Кроме того, что дает возможность моделям лучше справляться с выбросами и подходит для работы с несимметричными распределениями целевых переменных, отображает ошибку того же порядка, как и целевая переменная, что позволяет адекватно оценивать погрешность при работе с данными маленького порядка:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (4)$$

где n — общее количество наблюдений; y_i — истинное значение для i -го наблюдения; $\hat{y}_i$ — предсказанное значение для i -го наблюдения.

2. Глубина дерева — 10. Эта глубина деревьев позволяет улавливать сложные зависимости в данных.

3. Регуляризация $L2$ — 5. Параметр предотвращает переобучение модели, уменьшая вес коэффициентов, что важно при наличии шума в данных.

4. Случайность при выборе данных (*bagging_temperature*) — 0,8. Параметр регулирует разнообразие моделей, которые строятся, добавляя случайность в выборку данных для обучения каждого дерева.

5. Политика выращивания деревьев — *Depthwise*. Этот параметр устанавливает правило разбиения деревьев достижения установленной глубины, что может быть особенно полезно при обучении данных со сложными взаимосвязями.

В результате выбранных параметров на первом этапе обучения (1000 итераций, шаг обучения — 0,1) средняя абсолютная ошибка составила 0,061, следующие 2500 итераций с шагом обучения 0,05 снизили ошибку до 0,056.

Оценки точности. Поскольку целевые значения — это значения маленького порядка, зачастую близкие к нулю, расчет средней абсолютной процентной ошибки в общем виде может приводить к результатам, не отображающим реальную способность модели. В связи с этим оригинальная средняя абсолютная процентная ошибка была дополнена весами для каждого наблюдения. Каждая разность между предсказанием и оригинальным значением умножалась на свое абсолютное значение, что в процентном соотношении позволило снизить влияние процентных ошибок между значениями маленького порядка:

$$WAPE = \frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot w_i}{\sum_{i=1}^n w_i} \cdot 100, \quad (5)$$

где w_i — вес для разницы каждого наблюдения, в настоящем исследовании является абсолютным значением для y_i .

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

В результате обработки данных был получен датасет размером в 676 400 строк, содержащий аэродинамические коэффициенты с разными углами ветровой атаки для домов различных размеров. Для оценки точности полученных моделей из исходной базы данных выбраны дома размерами $0,1 \times 0,1 \times 0,5$ и $0,3 \times 0,1 \times 0,4$. Такой выбор обусловлен граничными значениями высоты в первом случае и ширины во втором; данные, определенные как тестовые, не участвуют в обучении модели и используются только для оценки точности.

Линейная регрессия. На рис. 3 представлены результаты прогнозирования аэродинамического давления методом линейной регрессии для зданий $0,1 \times 0,1 \times 0,5$ при угле ветровой атаки, равном 0. Линейная регрессия в связи с наличием между признаками и целевой переменной нелинейной связи показала результат, непригодный для дальнейшего рассмотрения этого метода.

Дерево решений. На рис. 4 приведены изополы среднего аэродинамического коэффициента, построенные на обученной модели дерева решений, для зданий $0,1 \times 0,1 \times 0,5$ при угле ветровой атаки 0. В табл. 1 представлена средняя взвешенная процентная ошибка для этого метода.

Средняя точность прогнозирования для всех углов ветровой атаки для дома $0,1 \times 0,1 \times 0,5$ составила 20,1 %. Для дома $0,3 \times 0,1 \times 0,4$ — 24 %.

Градиентный бустинг решающего дерева. Результаты предсказаний модели градиентного бустинга показаны на рис. 5. В табл. 2 приведена средняя взвешенная процентная ошибка для данного метода.




Рис. 3. Результаты прогнозирования аэродинамического коэффициента линейной регрессией на здания $0,1 \times 0,1 \times 0,5$
Fig. 3. The results of aerodynamic coefficient prediction by linear regression for buildings $0,1 \times 0,1 \times 0,5$




Рис. 4. Результаты прогнозирования аэродинамического коэффициента решающим деревом на здания $0,1 \times 0,1 \times 0,5$
Fig. 4. The results of aerodynamic coefficient prediction by the decision tree for buildings $0,1 \times 0,1 \times 0,5$

Табл. 1. Средняя взвешенная процентная ошибка для решающего дерева

Table 1. Mean weight absolute percentage error for decision tree

Габариты модели Model dimensions	Ошибка на грани 1, % Error on the facet 1, %	Ошибка на грани 2, % Error on the facet 2, %	Ошибка на грани 3, % Error on the facet 3, %	Ошибка на грани 4, % Error on the facet 4, %	Средняя погрешность Average error
0,1 × 0,1 × 0,5	19,7	6,6	7,3	6,8	10,1
0,3 × 0,1 × 0,4	20,7	19,8	7,7	14,3	15,6





Рис. 5. Результаты прогнозирования аэродинамического коэффициента градиентным бустингом на здания $0,1 \times 0,1 \times 0,5$
Fig. 5. The results of aerodynamic coefficient prediction by the gradient boosting for buildings $0.1 \times 0.1 \times 0.5$

Табл. 2. Средняя взвешенная процентная ошибка для градиентного бустинга
Table 2. Mean weight absolute percentage error for gradient boosting

Габариты модели Model dimensions	Ошибка на грани 1, % Error on the facet 1, %	Ошибка на грани 2, % Error on the facet 2, %	Ошибка на грани 3, % Error on the facet 3, %	Ошибка на грани 4, % Error on the facet 4, %	Средняя погрешность Average error
0,1 × 0,1 × 0,5	9,3	10,9	7,6	9,0	9,2
0,3 × 0,1 × 0,4	13,0	15,5	7,4	13,3	12,3






Рис. 6. Аэродинамические коэффициенты давления, полученные из испытаний в аэродинамической трубе (a); результаты прогнозирования дерева решений (b); результаты прогнозирования градиентного бустинга (c)
Fig. 6. Aerodynamic pressure coefficients obtained from wind tunnel tests (a); the results of decision tree prediction (b); the results of gradient boosting prediction (c)




Рис. 7. Результаты прогнозирования аэродинамического коэффициента давления на дом размерами 60 × 50 × 80 при угле атаки ветра 122,5°
Fig. 7. Prediction results of aerodynamic pressure coefficient for a house with dimensions 60 × 50 × 80 at a wind attack angle of 122.5°




Рис. 8. Средние аэродинамические коэффициенты давления для различных углов атаки ветра: *a* — 0 градусов; *b* — 30 градусов; *c* — 60 градусов; *d* — 90 градусов

Fig. 8. Average aerodynamic pressures coefficients for different angles of the wind attack: *a* — 0 degrees; *b* — 30 degrees; *c* — 60 degrees; *d* — 90 degrees

Табл. 3. Средняя взвешенная процентная погрешность

Table 3. Mean weight absolute percentage error

АДТ/CFD-моделирование Wind Tunnel/CFD-modelling	Угол Angle	Погрешность, % Error, %
NPL Аэродинамическая труба Wind Tunnel	0	45,8
	30	79,8
	60	74,2
	90	34,2
TJ-2 Аэродинамическая труба Wind Tunnel	0	16,5
	30	51,7
	60	53,5
	90	32,0
LBM-LES	30	54,5
	60	44,6
	90	27,7

Средняя точность прогнозирования для всех углов ветровой атаки для дома $0,1 \times 0,1 \times 0,5$ составила 15,6 %, для дома $0,3 \times 0,1 \times 0,4$ — 17,9 %.

Как можно заметить по приведенным выше результатам, решающее дерево является подходящим

методом со стороны средней точности прогнозирования, однако не отражает физические показатели решаемой задачи. На рис. 6 представлены реальные аэродинамические коэффициенты и результаты методов машинного обучения.

Градиентный бустинг не только увеличил точность предсказаний на 5,3 %, но и уловил физические зависимости в решаемой задаче. Кроме того, в результате обработки данных и создания дополнительных признаков стало возможным прогнозирование аэродинамического давления на дома произвольных размеров с различным углом атаки ветра (рис. 7).

Для дополнительной оценки качества результатов, предсказанных на основе ML-методов аэродинамических коэффициентов давления, была проведена валидация с результатами экспериментальных исследований в аэродинамических трубах, представленных в работе Мельбурна [22] (рис. 8). В табл. 3 приведена средняя взвешенная процентная погрешность.

ЗАКЛЮЧЕНИЕ И ОБСУЖДЕНИЕ

Результаты проведенного исследования показывают, что задачи прогнозирования ветровых воздействий на здания и сооружения прямоугольных форм могут успешно решаться с помощью методов машинного обучения, при этом наиболее высокую эффективность продемонстрировали ансамблевые методы (в частности, градиентный бустинг над решающим деревом).

Рассмотренные алгоритмы позволяют учесть нелинейные связи между множеством входных признаков (геометрические параметры здания, угол ветровой атаки, координаты датчиков и др.) и целевыми переменными (средние аэродинамические коэффициенты давления) при широкой вариации исходных данных.

Проанализированы методы формирования расширенной обучающей выборки (за счет аугментации данных методом интерполяции, слияния результатов из различных источников и перевода координат датчиков в относительные величины, что позволило существенно улучшить обобщающую способность моделей). Аугментация данных показала свою эффективность, так как объем исходной базы (около 85 тысяч строк) был увеличен более чем в 7 раз. Благодаря этому модели машинного обучения стали лучше воспринимать различные соотношения между размерами зданий, распределением датчиков по поверхностям и углами ветровой атаки, что особенно важно для прогнозирования нагрузок на случаи «вне» исходных условий.

На основе проведенной серии вычислительных экспериментов по выбору и настройке моделей (линейная регрессия, дерево решений, градиентный бустинг с применением библиотеки CatBoost и оптимизацией гиперпараметров с помощью Optuna) продемонстрировано, что линейная регрессия неспособна адекватно описать все многообразие физических закономерностей, связанных с ветровыми потоками. При этом деревья решений дают более высокую точность, но в ряде случаев искажают пространственное распределение давлений (проблема «кусковой» ап-

проксимации), а также хуже передают плавные физические переходы на поверхности фасадов. Градиентный бустинг над решающим деревом (CatBoost), напротив, показал наилучший компромисс между точностью и физической интерпретируемостью, уловив пространственные закономерности изменения аэродинамических коэффициентов по разным граням здания. Средняя погрешность по сравнению с эталонными данными в отдельных тестовых сценариях уменьшилась до 16–18 %.

Проведенная верификация результатов на моделях с «крайними» размерами (например, $0,1 \times 0,1 \times 0,5$ и $0,3 \times 0,1 \times 0,4$) подтвердила, что для правильной передачи закономерностей необходимо формировать в обучающем датасете как можно более «разнообразные» геометрические конфигурации и сочетания углов ветровой атаки. При этом важно учитывать, что в реальных условиях здания могут иметь дополнительные элементы (балконы, выступающие карнизы, небольшие скругления и т.п.), а также окружающую застройку. Градиентный бустинг, в сравнении с другими алгоритмами машинного обучения, позволяет «дообучать» модель в случае появления новых данных, что является серьезным преимуществом по сравнению с классическими подходами, где для любого существенного изменения геометрии здания приходится заново проводить экспериментальные исследования в аэродинамических трубах, либо проводить CFD-моделирование.

Анализ корреляции признаков и оптимизация их набора доказали, что грамотно проведенная предварительная обработка данных (например, перевод категориальных и угловых характеристик в тригонометрический вид для учета периодичности, удаление признаков с мультиколлинеарностью) помогает повысить устойчивость и точность предсказаний. Это еще раз иллюстрирует необходимость детального рассмотрения физической сути признаков и удаления избыточных или «шумовых» характеристик.

Валидация с результатами экспериментальных исследований в АДТ свидетельствует о том, что градиентный бустинг «распознает» физические аспекты аэродинамики: закономерные переходы от наветренной к подветренной стороне, влияние высоты здания и соотношений сторон. Модель не только количественно приближается к эталонным данным, но и качественно воспроизводит распределение давлений. В практическом смысле это означает, что на основе предсказаний ML можно оценивать как интегральные показатели ветровой нагрузки (силы, моменты), так и локальные значения (особенно важные для расчета фасадных узлов и креплений).

Настоящая статья может послужить исходной точкой для дальнейших разработок, связанных с расширением возможностей прогнозных моделей на статистические характеристики ветровых воздействий на здания и сооружения на основе анализа временных рядов аэродинамических коэффициентов.

СПИСОК ИСТОЧНИКОВ

1. *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
2. *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.
3. *Хазов П.А., Шилов С.С.* Геометрическая оптимизация аэродинамики высотного здания с интегрированными ветрогенераторами // *Вестник Южно-Уральского государственного университета. Серия: Строительство и архитектура*. 2024. Т. 24. № 3. С. 73–82. DOI: 10.14529/build240307. EDN VJYQQC.
4. *Yan B., Li Y., Li X., Zhou X., Wei M., Yang Q. et al.* Wind tunnel investigation of twisted wind effect on a typical super-tall building // *Buildings*. 2022. Vol. 12. Issue 12. P. 2260. DOI: 10.3390/buildings12122260
5. *Sari D.P., Cho K.P.* Performance Comparison of Different Building Shapes Using a Wind Tunnel and a Computational Model // *Buildings*. 2022. Vol. 12. Issue 2. P. 144. DOI: 10.3390/buildings12020144
6. *Potsis T., Tominaga Y., Stathopoulos T.* Computational wind engineering: 30 years of research progress in building structures and environment // *Journal of Wind Engineering and Industrial Aerodynamics*. 2023. Vol. 234. P. 105346. DOI: 10.1016/j.jweia.2023.105346
7. *Саиян С.Г., Васильев А.В.* Численное моделирование динамического отклика башни «Эволюция» при ветровом воздействии с учетом застройки и разрешением турбулентности // *Вестник МГСУ*. 2025. Т. 20. № 2. С. 246–279. DOI: 10.22227/1997-0935.2025.2.246-279
8. *Wijesooriya K., Mohotti D., Lee C.K., Mendis P.* A technical review of computational fluid dynamics (CFD) applications on wind design of tall buildings and structures: Past, present and future // *Journal of Building Engineering*. 2023. Vol. 74. P. 106828. DOI: 10.1016/j.job.2023.106828
9. *Саиян С.Г., Ефимова А.М.* Расчетные аэродинамические исследования комплекса Московского международного делового центра «Москва-Сити» при последовательном возведении зданий // *Вестник МГСУ*. 2024. Т. 19. № 6. С. 906–941. DOI: 10.22227/1997-0935.2024.6.906-941. EDN OKQQFI.
10. *Wang X., Zhang G., Li Y., Kong H., Liu L., Zhang C.* Field Measurements of Wind-Induced Responses of the Shanghai World Financial Center during Super Typhoon Lekima // *Sensors*. 2023. Vol. 23. Issue 14. P. 6519. DOI: 10.3390/s23146519
11. *Cheng X.X., Zhao L., Ge Y.J., Dong J., Peng Y.* Full-Scale/Model Test Comparisons to Validate the Traditional Atmospheric Boundary Layer Wind Tunnel Tests : Literature Review and Personal Perspectives // *Applied Sciences*. 2024. Vol. 14. Issue 2. P. 782. DOI: 10.3390/app14020782
12. *Yi J., Li Q.S.* Wind tunnel and full-scale study of wind effects on a super-tall building // *Journal of Fluids and Structures*. 2015. Vol. 58. Pp. 236–253. DOI: 10.1016/j.jfluidstructs.2015.08.005
13. *Charisi S., Thiis T.K., Aurlien T.* Full-scale measurements of wind-pressure coefficients in twin medium-rise buildings // *Buildings*. 2019. Vol. 9. Issue 3. P. 63. DOI: 10.3390/buildings9030063
14. *Wu T., Snaiki R.* Applications of machine learning to wind engineering // *Frontiers in Built Environment*. 2022. Vol. 8. DOI: 10.3389/fbuil.2022.811460
15. *Alanani M., Elshaer A.* ANN-based optimization framework for the design of wind load resisting system of tall buildings // *Engineering Structures*. 2023. Vol. 285. P. 116032. DOI: 10.1016/j.engstruct.2023.116032
16. *Nikose T.J., Sonparote R.S.* Dynamic along wind response of tall buildings using Artificial Neural Network // *Cluster Computing*. 2019. Vol. 22. Issue S2. Pp. 3231–3246. DOI: 10.1007/s10586-018-2027-0
17. *Ding Y., Ye X.W., Guo Y.* Wind load assessment with the JPDF of wind speed and direction based on SHM data // *Structures*. 2023. Vol. 47. Pp. 2074–2080. DOI: 10.1016/j.istruc.2022.12.028
18. *Oh B.K., Glisic B., Kim Y., Park H.S.* Convolutional neural network-based wind-induced response estimation model for tall buildings // *Computer-Aided Civil and Infrastructure Engineering*. 2019. Vol. 34. No. 10. Pp. 843–858. DOI: 10.1111/mice.12476
19. *Yetkin S., Abuhanieh S., Yigit S.* Investigation on the abilities of different artificial intelligence methods to predict the aerodynamic coefficients // *Expert Systems with Applications*. 2024. Vol. 237. P. 121324. DOI: 10.1016/j.eswa.2023.121324
20. *Захаров Ф.Н., Цянь Ц., Сюй И.* Прогнозирование ветровой нагрузки на высотные здания с использованием ансамблевого метода объединения результатов // *Universum: технические науки*. 2024. № 11–4 (128). С. 66–75. DOI: 10.32743/UniTech.2024.128.11.18607. EDN UKMYTR.
21. *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. № 5. С. 713–728. DOI: 10.22227/1997-0935.2024.5.713-728. EDN HUZBDU.
22. *Melbourne W.H.* Comparison of measurements on the CAARC standard tall building model in simulated model wind flows // *Journal of Wind Engineering and Industrial Aerodynamics*. 1980. Vol. 6. Issue 1–2. Pp. 73–88. DOI: 10.1016/0167-6105(80)90023-9

Поступила в редакцию 24 января 2025 г.

Принята в доработанном виде 25 января 2025 г.

Одобрена для публикации 31 января 2025 г.

ОБ АВТОРАХ: **Сергей Гургенович Саиян** — научный сотрудник Научно-образовательного центра компьютерного моделирования уникальных зданий, сооружений и комплексов им. А.Б. Золотова (НОЦ КМ им. А.Б. Золотова); **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, ResearcherID: AAT-1424-2021; Berformert@gmail.com;

Вероника Борисовна Шелепина — студентка; **Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ)**; 129337, г. Москва, Ярославское шоссе, д. 26; berenikas00@mail.ru.

Вклад авторов:

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

Шелепина В.Б. — концепция исследования, обработка данных, обучение моделей, создание иллюстраций, обработка и анализ результатов исследования, написание текста статьи.

Авторы заявляют об отсутствии конфликта интересов.

REFERENCES

1. 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
2. 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.).
3. Khazov P.A., Shilov S.S. Geometric optimization of the aerodynamics of a high-rise building with a built-in wind generator. *Bulletin of SUSU. Series: Construction Engineering and Architecture*. 2024; 24(3):73-82. DOI: 10.14529/build240307. EDN VJYQQC. (rus.).
4. Yan B., Li Y., Li X., Zhou X., Wei M., Yang Q. et al. Wind tunnel investigation of twisted wind effect on a typical super-tall building. *Buildings*. 2022; 12(12):2260. DOI: 10.3390/buildings12122260
5. Sari D.P., Cho K.P. Performance Comparison of Different Building Shapes Using a Wind Tunnel and a Computational Model. *Buildings*. 2022; 12(2):144. DOI: 10.3390/buildings12020144
6. Potsis T., Tominaga Y., Stathopoulos T. Computational wind engineering: 30 years of research progress in building structures and environment. *Journal of Wind Engineering and Industrial Aerodynamics*. 2023; 234:105346. DOI: 10.1016/j.jweia.2023.105346
7. Saiyan S.G., Vasiliev A.V. Numerical Simulation of the Dynamic Response of the “Evolution” Tower under Wind Action Considering Surrounding Buildings and Turbulence Resolution. *Vestnik MGSU [Monthly Journal on Construction and Architecture]*. 2025; 20(2):246-279. DOI: 10.22227/1997-0935.2025.2.246-279 (rus.).
8. Wijesooriya K., Mohotti D., Lee C.K., Mendis P. A technical review of computational fluid dynamics (CFD) applications on wind design of tall buildings and structures: Past, present and future. *Journal of Building Engineering*. 2023; 74:106828. DOI: 10.1016/j.jobee.2023.106828
9. Saiyan S.G., Efimova A.M. Computational aerodynamic studies of the MIBC “Moscow-city” complex during sequential construction of buildings. *Vestnik MGSU [Monthly Journal on Construction and Architecture]*. 2024; 19(6):906-941. DOI: 10.22227/1997-0935.2024.6.906-941. EDN OKQQFI. (rus.).
10. Wang X., Zhang G., Li Y., Kong H., Liu L., Zhang C. Field Measurements of Wind-Induced Responses of the Shanghai World Financial Center during Super Typhoon Lekima. *Sensors*. 2023; 23(14):6519. DOI: 10.3390/s23146519
11. Cheng X.X., Zhao L., Ge Y.J., Dong J., Peng Y. Full-Scale/Model Test Comparisons to Validate the Traditional Atmospheric Boundary Layer Wind Tunnel Tests : Literature Review and Personal Perspectives. *Applied Sciences*. 2024; 14(2):782. DOI: 10.3390/app14020782
12. Yi J., Li Q.S. Wind tunnel and full-scale study of wind effects on a super-tall building. *Journal of Fluids and Structures*. 2015; 58:236-253. DOI: 10.1016/j.jfluidstructs.2015.08.005
13. Charisi S., Thiis T.K., Aurlen T. Full-scale measurements of wind-pressure coefficients in twin medium-rise buildings. *Buildings*. 2019; 9(3):63. DOI: 10.3390/buildings9030063
14. Wu T., Snaiki R. Applications of machine learning to wind engineering. *Frontiers in Built Environment*. 2022; 8. DOI: 10.3389/fbuil.2022.811460
15. Alanani M., Elshaer A. ANN-based optimization framework for the design of wind load resisting

system of tall buildings. *Engineering Structures*. 2023; 285:116032. DOI: 10.1016/j.engstruct.2023.116032

16. Nikose T.J., Sonparote R.S. Dynamic along wind response of tall buildings using Artificial Neural Network. *Cluster Computing*. 2019; 22(S2):3231-3246. DOI: 10.1007/s10586-018-2027-0

17. Ding Y., Ye X.W., Guo Y. Wind load assessment with the JPDF of wind speed and direction based on SHM data. *Structures*. 2023; 47:2074-2080. DOI: 10.1016/j.istruc.2022.12.028

18. Oh B.K., Glisic B., Kim Y., Park H.S. Convolutional neural network-based wind-induced response estimation model for tall buildings. *Computer-Aided Civil and Infrastructure Engineering*. 2019; 34(10):843-858. DOI: 10.1111/mice.12476

19. Yetkin S., Abuhanieh S., Yigit S. Investigation on the abilities of different artificial intelligence methods to predict the aerodynamic coefficients. *Expert Systems*

with Applications. 2024; 237:121324. DOI: 10.1016/j.eswa.2023.121324

20. Zakharov F., Qian J., Xu Yi. Forecasting wind loads on high-rise buildings using the ensemble method of combining results. *Universum*. 2024; 11-4(128):66-75. DOI: 10.32743/UniTech.2024.128.11.18607. EDN UKMYTR. (rus.).

21. 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. EDN HUZBDU. (rus.).

22. Melbourne W.H. Comparison of measurements on the CAARC standard tall building model in simulated model wind flows. *Journal of Wind Engineering and Industrial Aerodynamics*. 1980; 6(1-2):73-88. DOI: 10.1016/0167-6105(80)90023-9

Received January 24, 2025.

Adopted in revised form on January 25, 2025.

Approved for publication on January 31, 2025.

B I O N O T E S: **Sergey G. Saiyan** — researcher at the Scientific and Educational Center for Computer Modeling of Unique Buildings, Structures and Complexes named after A.B. Zolotova; **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, ResearcherID: AAT-1424-2021; Berformert@gmail.com;

Veronica B. Shelepina — student; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; berenikas00@mail.ru.

Contribution of the authors:

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

Veronica B. Shelepina — research concept, data processing, model training, illustration creation, processing and analysis of research results, writing the text of the article.

The authors declare that there is no conflict of interest.