

СТРОИТЕЛЬНЫЕ КОНСТРУКЦИИ, ЗДАНИЯ И СООРУЖЕНИЯ

BUILDING CONSTRUCTIONS, BUILDINGS AND ENGINEERING STRUCTURES



Оригинальное эмпирическое исследование

УДК 624.04

<https://doi.org/10.23947/2949-1835-2025-4-4-44-52>

Прогнозирование несущей способности трубобетонных колонн квадратного сечения при помощи методов машинного обучения

Т.Н. Кондратьева , А.С. Чепурненко 

Донской государственный технический университет, г. Ростов-на-Дону, Российская Федерация

✉ ktn618@yandex.ru



EDN: BCUPRW

Аннотация

Введение. В данной работе рассматривается задача прогнозирования прочности центрально сжатых коротких трубобетонных колонн квадратного сечения с использованием методов машинного обучения. Традиционные методы, такие как метод конечных элементов и теоретико-экспериментальный подход с подбором эмпирических формул, требуют значительных вычислительных ресурсов и времени. В то же время эти методы не всегда способны учитывать сложные нелинейные зависимости между параметрами. Основная цель — разработка высокоточной модели, способной предсказывать несущую способность колонн на основе ключевых параметров.

Материалы и методы. Для исследования была сгенерирована база данных, состоящая из результатов численных экспериментов по расчету несущей способности трубобетонных колонн квадратного поперечного сечения в физически нелинейной постановке. В рамках проведенного исследования построены модели на основе методов машинного обучения, реализованные с использованием интерактивной вычислительной платформы Jupyter Notebook. Основным методом является механизм CatBoost (Gradient Boosting Regressor). Обучение построенных моделей произведено с использованием методов нелинейной оптимизации.

Результаты исследования. В статье проведена оценка степени влияния каждого входного параметра на итоговые предсказания модели. Получены результаты по величине степени влияния для моделей CatBoost и Random Forrest Regressor (RFR). Оценка качества построенных моделей по величине R^2 составила 98 % для CatBoost и 94 % — для RFR.

Обсуждение и заключение. Разработанный подход демонстрирует высокую эффективность в задаче прогнозирования несущей способности трубобетонных колонн, обеспечивая баланс между точностью результатов и вычислительной сложностью.

Ключевые слова: трубобетонные колонны, методы машинного обучения, прогнозирование, несущая способность, искусственный интеллект, искусственные нейронные сети.

Благодарности. Авторы выражают благодарность редакции и рецензентам за внимательное отношение к статье и указанные замечания, которые позволили повысить ее качество.

Для цитирования: Кондратьева Т.Н., Чепурненко А.С. Прогнозирование несущей способности трубобетонных колонн квадратного сечения при помощи методов машинного обучения. *Современные тенденции в строительстве, градостроительстве и планировке территорий*. 2025;4(4):44–52. <https://doi.org/10.23947/2949-1835-2025-4-4-44-52>

Predicting the Load-Bearing Capacity of Square-Section Pipe-Concrete Columns Using Machine Learning Methods

Tatiana N. Kondratieva , Anton S. Chepurnenko 

Don State Technical University, Rostov-on-Don, Russian Federation

 ktn618@yandex.ru

Abstract

Introduction. In this paper, we consider the problem of predicting the strength of square-section centrally compressed short concrete-filled tubular columns using machine learning methods. Traditional methods, such as the finite element method and the theoretical-experimental approach involving selection of empirical formulas require significant computational resources and time. At the same time, these methods are not always capable of accounting for complex nonlinear dependencies between the parameters. The key objective is to develop a high-precision model capable of predicting the load-bearing capacity of columns using the major parameters.

Materials and Methods. For the current study, a database was generated containing the results of numerical experiments on calculating the load-bearing capacity of square-section concrete-filled tubular columns in a physically nonlinear formulation. As part of the study, models based on machine learning methods were designed and implemented using the Jupyter Notebook interactive computing platform. The main method is the CatBoost mechanism (Gradient Boosting Regressor). The resulting models were trained by means of nonlinear optimization methods.

Results. The article evaluates the degree of impact of each of the input parameters on the final predictions of the model. The results on the degree of impact for the CatBoost and Random Forrest Regressor (RFR) models are obtained. The quality of the resulting models evaluated using the R^2 value was 98% for CatBoost and 94% for RFR.

Discussion and Conclusions. The resulting approach has proved to be highly efficient in predicting the load-bearing capacity of concrete-filled tubular columns, providing a balance between the accuracy of the results and computational complexity.

Keywords: concrete-filled tubular columns, machine learning methods, prediction, load-bearing capacity, artificial intelligence, artificial neural networks

Acknowledgements. The authors appreciate the reviewers, whose critical assessment of the submitted materials and suggestions helped to significantly improve the quality of the project.

For citation: Kondratieva TN, Chepurnenko AS. Predicting the Load-Bearing Capacity of Square-Section Pipe-Concrete Columns Using Machine Learning Methods. *Modern Trends in Construction, Urban and Territorial Planning*. 2025;4(4):44–52. <https://doi.org/10.23947/2949-1835-2025-4-4-44-52>

Введение. Оценка технического состояния монолитных железобетонных конструкций в настоящее время остается актуальной и востребованной задачей, особенно с учетом необходимости обеспечения их долговечности и безопасности. Решение такого рода задач можно реализовать не только аналитическими и расчетными методами [1–3], но и более современными хорошо зарекомендовавшими себя методами искусственного интеллекта (ИИ) и машинного обучения (МО) [4–6].

Широко применяемый метод конечных элементов (МКЭ) позволяет учитывать сложные физические процессы, такие как нелинейное поведение материалов, взаимодействие стали и бетона [7], а также влияние различных нагрузок [8]. Однако основным недостатком МКЭ является высокая вычислительная сложность и необходимость в большом количестве параметров для калибровки модели.

Методы МО представляют собой современный инструмент анализа данных, который позволяет выявлять сложные нелинейные зависимости между входными и выходными параметрами [9–11]. В отличие от эмпирических формул машинное обучение позволяет автоматически находить закономерности в больших объемах данных, что делает его более универсальным и эффективным методом прогнозирования.

В работе [12] авторы исследуют образование дефектов в железобетонных конструкциях алгоритмами искусственного интеллекта, такими как случайный лес (RF), метод опорных векторов (SVM), дерево решений (CART) и адаптивное усиление (Gradient Boosting).

В современной практике при прогнозировании прочности железобетонных конструкций все чаще активно используют сверточные нейронные сети (CNN) [13–15]. Например, в работе [13] авторами разработана CNN, способная к двумерному полномасштабному прогнозированию образования трещин на ранних этапах и описа-

нию всего процесса разрушения. Модель, способная предсказывать как инициирование трещин, так и их распространение, предложена в работе [14]. Для мониторинга состояния железобетонных конструкций на сложных объектах строительства авторы статьи [15] используют нейронную сеть полностью сверточного типа (FCN) для сегментации изображений и локализации трещин на бетонных поверхностях с учетом неоднородности свойств бетона. Разработанная FCN-модель минимизирует ложноположительные и ложноотрицательные результаты, обладает высоким качеством, что позволяет сегментировать мелкие и сложные трещины.

В статье [16] разработан автоматизированный классификатор, в функционал которого входит автоматическое определение и классификация трещин в железобетонных колоннах различного уровня сложности методами глубокой CNN (DCNN). Предложенная DCNN-модель анализирует сложные текстуры и шумы, показывает высокую точность при детекции трещин, составляющую 96 %, за счет глубины слоев модели и расширения каждого слоя параллельным образом.

Авторы работы [17] для прогнозирования трещин во времени продвинулись дальше в своих исследованиях и построили гибридную модель объединив DCNN и рекуррентные нейронные сети (RNN).

Таким образом, алгоритмы МО, несомненно, обладают рядом преимуществ, таких как выявление шаблонов в больших объемах данных, обнаружение скрытых закономерностей и зависимостей с учетом многомерности данных, автоматический анализ оценки состояния железобетонных конструкций на основе ключевых параметров, оптимизация алгоритмов МО и параллельные вычисления.

Однако указанные алгоритмы МО все еще имеют недостатки, такие как неточность или слабость, ограниченная способность к обобщению и работа на низкой скорости [18, 19]. Одним из ключевых недостатков является зависимость моделей машинного обучения от качества обучающих данных и их объема.

При обучении большинства моделей искусственного интеллекта для прогнозирования прочности трубобетонных колонн используются данные натурных экспериментов [20–22]. Такие эксперименты, как правило, проводятся на образцах с относительно небольшими по сравнению с реальными конструкциями размерами поперечного сечения. С учетом плохой способности методов машинного обучения к экстраполяции данных при прогнозировании несущей способности реальных конструкций возможны большие погрешности. Выходом из этой ситуации является использование комбинированного подхода, когда данные для обучения формируются путем конечно-элементного расчета конструкций с реальными размерами по методике, прошедшей валидацию на экспериментальных данных.

Целью данного исследования является разработка моделей машинного обучения для прогнозирования прочности центрально сжатых трубобетонных колонн квадратного сечения с использованием данных, полученных описанным выше путем.

Материалы и методы. Для исследования была сгенерирована база данных, представляющая собой результаты численных экспериментов по расчету несущей способности коротких трубобетонных колонн квадратного поперечного сечения по методике, описанной в работе [23]. Эти данные были использованы для разработки и анализа моделей, сочетающих традиционные методы строительной механики и алгоритмы машинного обучения.

Входные параметры, описывающие основные геометрические и физико-механические характеристики колонн, сгенерированы с равномерным шагом в диапазонах, характерных для реальных конструкций, что позволило охватить широкий спектр возможных комбинаций.

Ключевые параметры: a — наружный размер поперечного сечения колонны, мм; t — толщина стенки стальной квадратной трубы, мм; R_y — предел текучести стали, МПа; R_b — прочность бетона при сжатии, МПа.

Выходным параметром является несущая способность трубобетонных колонн N_{ult} , кН. Этот показатель был получен в результате численных экспериментов, выполненных по методике, приведенной в работе [24]. Расчеты учитывали сложное взаимодействие стальной трубы и бетонного сердечника, включая совместную работу материалов и их деформационное поведение.

В таблице 1 частично представлен анализируемый массив данных. Общий объем обучающей выборки составил 22 308 экземпляров.

Для улучшения качества моделей была проведена предобработка данных: нормализация, разделение данных и кросс-валидация. Значения каждого параметра были масштабированы в диапазоне (0–1) для предотвращения доминирования признаков с большими значениями. Сгенерированные данные были разделены на тренировочные (80 %) и тестовые (20 %) массивы для обучения моделей и их оценки.

Для анализа данных и построения моделей прогнозирования прочности центрально сжатых трубобетонных колонн квадратного сечения использовались следующие алгоритмы машинного обучения: Линейная регрессия (Linear Regression), решающее дерево (Decision Tree), градиентный бустинг (Gradient Boosting, XGBoost), переспектор случайного леса (Random Forest Regressor, RFR).

Таблица 1

Таблица сгенерированных данных

№	a , мм	t , мм	R_y , МПа	R_b , МПа	N_{ult} , кН
1	100	3,00	220	10	349,71
2	100	3,45	220	10	385,27
3	100	3,91	220	10	420,72
4	100	4,36	220	10	455,76
5	100	4,82	220	10	490,38
6	100	5,27	220	10	524,59
7	100	5,27	220	10	524,59
8	100	5,73	220	10	558,38
9	100	6,18	220	10	591,76
10	100	6,64	220	10	625,31
11	100	7,09	220	10	657,89
...
22299	500	10,55	840	120	44248,28
22300	500	11,82	840	120	45887,56
22301	500	13,09	840	120	47511,10
22302	500	14,36	840	120	49118,97
22303	500	15,64	840	120	50759,78
22304	500	16,91	840	120	52338,05
22305	500	18,18	840	120	53900,79
22306	500	19,45	840	120	55501,41
22307	500	20,73	840	120	57089,77
22308	500	22,00	840	120	58609,37

При нормализации параметров был применен метод регуляризации, при оптимизации — метод Optuna, при подборе гиперпараметров — GridSearchCV, RandomizedSearchCV. Диапазон значений параметров для модели CatBoost составил: iterations — 1000–1500; depth — 4–8; learning_rate — 0,1–0,6; l2_reg_lambda — 1,9–4,9. Для RFR: n_estimators — 100–250; max_depth — 10–20; min_samples_leaf — 1–4. Поскольку в модели RFR отсутствует опция слежения за итерациями, обучение модели возможно с разным количеством деревьев и анализом средне-квадратичной ошибки (MSE). При малом количестве деревьев модель RFR недообучена и показывает низкую оценку качества, при увеличении количества деревьев оценка MSE стабилизируется, и оценка качества модели становится удовлетворительной.

Для обученных моделей также проводился анализ важности признаков путем оценки степени влияния каждого входного параметра на итоговые предсказания модели. Данный подход позволил определить, насколько сильно изменяются результаты предсказания при изменении значений конкретного признака.

Результаты исследования. Статистические характеристики исходного набора данных приведены в виде таблицы (таблица 2). Основные показатели: размер выборки, среднее выборочное, рассеяние вариантов, экстремумы значений переменных. Совокупность данных показателей помогает провести статистический анализ переменных, определить их разброс относительно своего центра, показать асимметричность распределения, вывести законы распределения данных вариационных рядов.

Таблица 2

Таблица статистических характеристик

Параметр	a , мм	t , мм	R_y , МПа	R_b , МПа	N_{ult} , кН
Количество	22308	22308	22308	22308	22308
Среднее	253,85	9,92	530,00	65,0	10564,50
Стандартное отклонение	128,40	5,06	196,07	34,3	10419,09
min	100,00	3,00	220,00	10,0	349,71
max	500,00	22,00	840,00	120,0	58609,37

На рис. 1 показана корреляция между параметрами модели. Наблюдается сильная корреляция ($0,6 \leq |\rho| \leq 0,9$) между параметрами: наружным размером поперечного сечения колонны и толщиной стенки стальной квадратной трубы ($\rho_{a/t} = 0,7$); наружным размером поперечного сечения колонны и несущей способностью трубобетонных колонн ($\rho_{a/N_{ult}} = 0,88$); толщиной стенки стальной квадратной трубы и несущей способностью трубобетонных колонн ($\rho_{t/N_{ult}} = 0,73$).

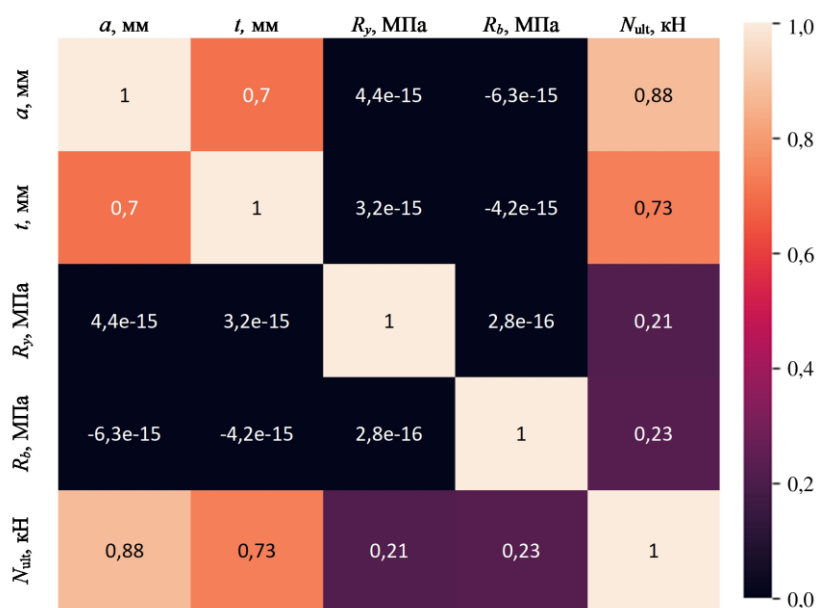


Рис. 1. Корреляционная матрица

В ходе исследования основное внимание было уделено алгоритму градиентного бустинга CatBoost, который показал наилучшие результаты среди протестированных алгоритмов ($R^2 = 0,98$).

Наиболее значимым параметром модели CatBoost является наружный размер поперечного сечения колонны, его значимость составляет — 96 %, доля влияния прочности бетона при сжатии составила — 33 %, предела текучести стали — 28 %, толщины стенки стальной квадратной трубы — 20 %. Наиболее значимые параметры модели RFR и их степени важности распределились следующим образом: наружный размер поперечного сечения колонны — 92 %, прочность бетона при сжатии — 21 %, предел текучести стали — 17 %, толщина стенки стальной квадратной трубы — 14 %. Значимость факторов влияния по обоим моделям совпадает, количественная оценка вклада каждого признака наглядно представлена на рис. 2 и 3 соответственно.




Рис. 2. Оценка важности признаков для CatBoost




Рис. 3. Оценка важности признаков для RFR

Полученные оптимальные значения параметров в процессе обучения моделей представлены в таблице 3.

Таблица 3

Оптимальные значения параметров моделей

Модель	Параметр	Значение
CatBoost	Iterations (число итераций)	1500
	Depth (глубина обучения)	5
	Learning rate (скорость обучения)	0,4
	l2 leaf reg (L2-регуляризация для предотвращения переобучения)	2,8
RFR	N estimators (количество деревьев в ансамбле)	180
	Max depth (максимальная глубина деревьев)	6
	Min samples leaf (минимальное число образцов в листе дерева)	1

Оценка качества моделей представлена в таблице 4.

Таблица 4

Метрики качества модели

Метрика/Модель	CatBoost	RFR
MAE	3,1	7,8
MSE	5,4	4,5
MAPE, %	0,015	0,007
R^2	0,98	0,94

На рис. 4, 5 представлены гистограммы ошибок: по оси ординат фактические значения, по оси абсцисс — предсказанные.

Обсуждение и заключение. Данная работа представляет разносторонний взгляд на существующие методы прогнозирования прочности трубобетонных колонн и подчеркивает преимущества применения машинного обучения в данной области.

Использование методов машинного обучения, в частности CatBoost, позволило выявить точные зависимости между параметрами, превосходя традиционные эмпирические методы. Достоверность прогнозирования по величине R^2 для модели, основанной на алгоритме CatBoost, составила 0,98. Модель, основанная на методе Random Forest Regressor, показала меньшую точность ($R^2 = 0,94$).

Анализ значимости признаков показал, что наружный размер поперечного сечения трубобетонной колонны является ключевым параметром, оказывающим наибольшее влияние на ее несущую способность.

В дальнейших исследованиях планируется расширить спектр параметров модели, основываясь на текущих результатах с учётом дополнительных факторов. В качестве дополнительных параметров могут выступать эксцентриситет продольной силы, гибкость элемента, доля длительных нагрузок в суммарной нагрузке и другие.




Рис. 4. Гистограмма ошибок для CatBoost




Рис. 5. Гистограмма ошибок для RFR

Список литературы/References

1. Abd-El-Nabi E, El-Helloty A, Summra A. Numerical analysis of reinforced concrete buildings subjected to blast load. *Structural Concrete*. 2023;24(3):3727–3743. <https://doi.org/10.1002/suco.202200726>
2. Jianguo Ning, Fanlin Meng, Tianbao Ma, Xiangzhao Xu. Failure analysis of reinforced concrete slab under impact loading using a novel numerical method. *International Journal of Impact Engineering*. 2020;144:103647. <https://doi.org/10.1016/j.ijimpeng.2020.103647>
3. Kumar V, Kartik KV, Iqbal MA. Experimental and numerical investigation of reinforced concrete slabs under blast loading. *Engineering Structures*. 2020;(206):110125. <https://doi.org/10.1016/j.engstruct.2019.110125>
4. Beskopylny AN, Stel'makh SA, Shcherban' EM, Mailyan LR, Meskhi B, Razveeva I. et al. Prediction of the Compressive Strength of Vibrocentrifuged Concrete Using Machine Learning Methods. *Buildings*. 2024;14(377). <https://doi.org/10.3390/buildings14020377>
5. Beskopylny AN, Stel'makh SA, Shcherban' EM, Razveeva I, Kozhakin A, Kondratieva TN et al. Prediction of the Properties of Vibro-Centrifuged Variatropic Concrete in Aggressive Environments Using Machine Learning Methods. *Buildings* 2024;(14):1198. <https://doi.org/10.3390/buildings14051198>
6. Kondratieva TN, Chepurnenko AS. Prediction of Rheological Parameters of Polymers by Machine Learning Methods. *Advanced Engineering Research*. 2024;24(1):36–47. <https://doi.org/10.23947/2687-1653-2024-24-1-36-47>
7. Klemczak B, Żmij A. Insight into thermal stress distribution and required reinforcement reducing early-age cracking in mass foundation slabs. *Materials*. 2021;14(3):477. <https://doi.org/10.3390/ma14030477>
8. Talaat M, Yehia E, Mazek SA, Genidi M, Sherif A. Finite element analysis of RC buildings subjected to blast loading. *Ain Shams engineering journal*. 2022;13(4):101689. <https://doi.org/10.1016/j.asej.2021.101689>
9. Chepurnenko AS, Kondratieva TN, Deberdeev TR, Akopyan VF, Avakov AA. Prediction of Rheological Parameters of Polymers Using the CatBoost Gradient Boosting Algorithm. *Polymer Science, Series D*. 2024;17(1):121–128. <https://doi.org/10.1134/S199542122370020X>
10. Kondratieva TN, Chepurnenko AS, Poliakova KA, Rodionov KA. CatBoost algorithms to predict the load-bearing capacity of centrally compressed short CFST columns of circular cross-section. *E3S Web Conf*. 2024;583:06009. <https://doi.org/10.1051/e3sconf/202458306009>
11. Chepurnenko AS, Kondratieva TN, Al-Wali E. Processing of Polymers Stress Relaxation Curves Using Machine Learning Methods. *Baghdad Science Journal*. 2023;20(6):2488–2488. <https://doi.org/10.21123/bsj.2023.8819>
12. Althoey F, Amin MN, Khan K, Usman MM, Khan MA. Machine learning based computational approach for crack width detection of self-healing concrete. *Case Studies in Construction Materials*. 2022;(17):e01610. <https://doi.org/10.1016/j.cscm.2022.e0161>

13. Koopas RN, Rezaei S, Rauter N, Ostwald R, Lammering R. A spatiotemporal deep learning framework for prediction of crack dynamics in heterogeneous solids: Efficient mapping of concrete microstructures to its fracture properties. *Engineering Fracture Mechanics*. 2025;(314):110675. <https://doi.org/10.1016/j.engfracmech.2024.110675>
14. Ali R, Chuah JH, Talip M, Mokhtar N, Shoaib MA. Structural crack detection using deep convolutional neural networks. *Automation in Construction*. 2022;(133):103989. <https://doi.org/10.1016/j.autcon.2021.103989>
15. Xinyu Ye, Tao Jin, Li ZX, Chen Pengyu, Ma Si Yuan, Yi Ding, Yihong Ou. Structural crack detection from benchmark data sets using pruned fully convolutional networks. *Journal of Structural Engineering*. 2021;147(11):04721008. [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0003140](https://doi.org/10.1061/(ASCE)ST.1943-541X.0003140)
16. Wang Weidong, Hu Wenbo, Wang Wenjuan, Xu Xinyue, Wang Mengdi, Shi Youyin et al. Automated crack severity level detection and classification for ballastless track slab using deep convolutional neural network. *Automation in Construction*. 2021;(124):103484. <https://doi.org/10.1016/j.autcon.2020.103484>
17. Ganesh Kolappan Geetha, Hyun-Jung Yang, Sung-Han Sim. Fast detection of missing thin propagating cracks during deep-learning-based concrete crack/non-crack classification. *Sensors*. 2023;23(3):1419. <https://doi.org/10.3390/s23031419>
18. Qijun Chen, Yuxi Xie, Yu Ao, Tiange Li, Guorong Chen, Shaofei Ren et al. A deep neural network inverse solution to recover pre-crash impact data of car collisions. *Transportation research part C: emerging technologies*. 2021;(126):103009. <https://doi.org/10.1016/j.trc.2021.103009>
19. Guorong Chen, Tiange Li, Qijun Chen, Shaofei Ren, Chao Wang, Shaofan Li. Application of deep learning neural network to identify collision load conditions based on permanent plastic deformation of shell structures. *Computational Mechanics*. 2019;(64):435–449. <https://doi.org/10.1007/s00466-019-01706-2>
20. Viet-Linh Tran, Duc-Kien Thai, Duy-Duan Nguyen. Practical artificial neural network tool for predicting the axial compression capacity of circular concrete-filled steel tube columns with ultra-high-strength concrete. *Thin-Walled Structures*. 2020;(151):106720. <https://doi.org/10.1016/j.tws.2020.106720>
21. Cigdem Avci-Karatas. Artificial neural network (ANN) based prediction of ultimate axial load capacity of concrete-filled steel tube columns (CFSTCs). *International Journal of Steel Structures*. 2022;22(5):1341–1358. <https://doi.org/10.1007/s13296-022-00645-8>
22. Abidhan Bardhan, Rahul Biswas, Navid Kardani, Mudassir Iqbal, Pijush Samui, Singh M.P. et al. A novel integrated approach of augmented grey wolf optimizer and ANN for estimating axial load carrying-capacity of concrete-filled steel tube columns. *Construction and Building Materials*. 2022;(337):127454. <https://doi.org/10.1016/j.conbuildmat.2022.127454>
23. Chepurnenko AS, Yazyev BM, Turina VS, Akopyan VF. Artificial intelligence models for determining the strength of centrally compressed pipe-concrete columns with square cross-section. *Magazine of Civil Engineering*. 2024;17(6):13008. <https://doi.org/10.34910/MCE.130.8>
24. Chepurnenko A, Yazyev B, Meskhi B, Beskopylny A, Khashkhozhhev K, Chepurnenko V. Simplified 2D finite element model for calculation of the bearing capacity of eccentrically compressed concrete-filled steel tubular columns. *Applied Sciences*. 2021;11(24):11645. <https://doi.org/10.3390/app112411645>

Об авторах:

Кондратьева Татьяна Николаевна, кандидат технических наук, доцент, доцент кафедры математики и информатики Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [ORCID](#), [ResearcherID](#), [ScopusID](#), ktn618@yandex.ru

Чепурненко Антон Сергеевич, доктор технических наук, доцент, профессор кафедры строительной механики и теории сооружений Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [ORCID](#), [ResearcherID](#), [ScopusID](#), anton_chepurnenk@mail.ru

Заявленный вклад соавторов:

Т.Н. Кондратьева: формирование основной концепции, цели и задачи исследования, проведение расчетов, анализ результатов исследований;

А.С. Чепурненко: научное руководство доработка текста, корректировка выводов.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Все авторы прочитали и одобрили окончательный вариант рукописи.

About the Authors:

Tatiana N. Kondratieva, Cand.Sci. (Eng.), Associate Professor of the Department of Mathematics and Computer Science at the Don State Technical University (1 Gagarin Square, Rostov-on-Don, 344003, Russian Federation), [ORCID](#), [ResearcherID](#), [ScopusID](#), ktn618@yandex.ru

Anton S. Chepurnenko, Dr.Sci. (Eng.), Associate Professor, Professor of the Department of Structural Mechanics and Theory of Structures at the Don State Technical University, (1 Gagarin Square, Rostov-on-Don, 344003, Russian Federation), [ORCID](#), [ResearcherID](#), [ScopusID](#), anton_chepurnenk@mail.ru

Claimed contributorship:

TN Kondratieva: formation of the basic concept, objectives of the study, calculations, analysis of the research results.

AS Chepurnenko: scientific supervision, revision of the manuscript, correction of the conclusions.

Conflict of interest statement: the authors do not have any conflict of interest.

All authors have read and approved the final version of manuscript.

Поступила в редакцию / Received 06.08.2025

Поступила после рецензирования / Revised 01.09.2025

Принята к публикации / Accepted 07.09.2025