


СТРОИТЕЛЬНАЯ МЕХАНИКА CONSTRUCTION MECHANICS



УДК 624.04

Оригинальное эмпирическое исследование

<https://doi.org/10.23947/2949-1835-2024-3-3-40-48>

Применение искусственного интеллекта к прогнозированию прочности трубобетонных колонн



EDN: YMWPJW

Т.Н. Кондратьева , А.С. Чепурненко 

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

✉ ktn618@yandex.ru

Аннотация

Введение. Алгоритмы машинного обучения обладают большими перспективами в прогнозировании несущей способности строительных конструкций. Целью настоящей статьи является построение прогнозных моделей для расчета прочности трубобетонных колонн (ТБК), которые могли бы предсказывать с высокой точностью предельную нагрузку для всего возможного диапазона параметров, влияющих на несущую способность внецентренно сжатых колонн.

Материалы и методы. В статье рассматриваются внецентренно сжатые короткие трубобетонные колонны круглого поперечного сечения. Входные параметры модели: внешний диаметр колонны, толщина стенки трубы, предел текучести стали, прочность бетона при сжатии, относительный эксцентриситет. Выходные параметры: предельная нагрузка без учета случайных эксцентриситетов и с учетом случайных эксцентриситетов. Обучение моделей выполнено на синтетических данных, сгенерированных на основе теоретических положений теории предельного равновесия. Построено 2 модели машинного обучения. При обучении первой модели предельные нагрузки определены при заданном эксцентриситете продольной силы без учета дополнительного случайного эксцентриситета. При обучении второй модели учитывается дополнительный случайный эксцентриситет. Оценка влияния признаков на предсказания моделей проводилась с помощью функции Feature Importance. Для подбора гиперпараметров использовался метод Optuna. Модели машинного обучения реализованы в среде Jupyter Notebook, использован метод обучения Gradient Boosting. Общий объем обучающей выборки составил 179 025 образцов.

Результаты исследования. Определена важность признаков, наиболее влияющих на прогнозные значения модели. Важнейшими признаками для обеих моделей являются наружный диаметр колонны и относительный эксцентриситет, что согласуется с опытом проектирования и расчета таких конструкций. Оптимизация гиперпараметров с помощью метода Grid Search позволила получить улучшенные результаты. Высокая точность прогноза подтверждена низкими метриками для модели без учета дополнительного случайного эксцентриситета: MSE = 9,024; MAE = 9,250; MAPE = 0,004; с учетом дополнительного случайного эксцентриситета: MSE = 8,673; MAE = 8,673; MAPE = 0,004.

Обсуждение и заключение. Разработанные модели Gradient Boosting для прогнозирования предельной нагрузки внецентренно сжатых коротких трубобетонных колонн круглого поперечного сечения как без учета, так и с учетом дополнительных случайных эксцентриситетов показали высокую точность и стабильность предсказаний, пригодны для практического применения для оценки прочности колонн при проектировании и строительстве, что позволит сократить время и ресурсы на физические испытания. В будущем планируется расширить данные, включив другие материалы, различные геометрии сечения колонн и параметр гибкости, что может улучшить обобщающие способности модели.

Ключевые слова: трубобетонная колонна, несущая способность, предельное равновесие, машинное обучение, Gradient Boosting

Для цитирования. Кондратьева Т.Н., Чепурненко А.С. Применение искусственного интеллекта к прогнозированию прочности трубобетонных колонн. *Современные тенденции в строительстве, градостроительстве и планировке территорий*. 2024;3(3):40–48. <https://doi.org/10.23947/2949-1835-2024-3-3-40-48>

Prediction of the Strength of the Concrete-Filled Tubular Steel Columns Using the Artificial Intelligence

Tatiana N. Kondratieva  , Anton S. Chepurenko 

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

 ktn618@yandex.ru

Abstract

Introduction. The machine learning algorithms are highly promising for predicting the load-bearing capacity of the building structures. The paper aims at building the predictive models for calculating the strength of the concrete-filled steel tubular (CFST) columns to enable a highly accurate prediction of the ultimate loads for the entire possible range of parameters affecting the load-bearing capacity of the eccentrically compressed columns.

Materials and Methods. The article studies the eccentrically compressed short concrete-filled steel tubular (CFST) columns of circular cross-section. Model input parameters: column outer diameter, pipe wall thickness, yield strength of steel, compressive strength of concrete, relative eccentricity. Output parameters: the ultimate loads without taking into account and taking into account the random eccentricities. The models were trained on synthetic data generated based on the theoretical principles of the limit equilibrium method. Two machine learning models were built. When training the first model, the ultimate loads were determined at a given eccentricity of the longitudinal force without taking into account the additional random eccentricity. When training the second model, the additional random eccentricity was taken into account. The effect of the features on the model predictions was assessed using the Feature Importance function. The Optuna method was used to select the hyperparameters. The machine learning models were implemented in the Jupiter Notebook environment using the Gradient Boosting learning method. The total volume of the training sample was 179 025 samples.

Results. The importance of the features most affecting the predictive values of the model have been determined. For both models, the outer diameter of the column and the relative eccentricity have proved to be the most important features, which is consistent with the existing experience of designing and calculating such structures. Optimisation of the hyperparameters using the Grid Search method enabled getting the improved results. The high accuracy of prediction has been ascertained by the low values of the regression metrics: MSE = 9.024; MAE = 9.250; MAPE = 0.004 — for the model built without taking into account the additional random eccentricity; MSE = 8.673; MAE = 8.673; MAPE = 0.004 — for the model built taking into account the additional random eccentricity.

Discussion and Conclusion. The developed Gradient Boosting models for predicting the ultimate loads of the eccentrically compressed short concrete-filled steel tubular (CFST) columns of circular cross-section, both without taking into account and taking into account the additional random eccentricities, have demonstrated high accuracy and stability of prediction, they can be applied for assessing the strength of the columns during design and construction, which will reduce the time and resources involved in physical testing. In the future, it is planned to expand the data range by including other materials, different cross-section geometries of the columns and a slenderness parameter, which may improve the generalization ability of the model.

Keywords: concrete-filled steel tubular (CFST) column, load-bearing capacity, limit equilibrium, machine learning, Gradient Boosting

For citation. Kondratieva TN, Chepurenko AS. Prediction of the Strength of the Concrete-Filled Tubular Steel Columns Using the Artificial Intelligence. *Modern Trends in Construction, Urban and Territorial Planning*. 2024;3(3):40–48. <https://doi.org/10.23947/2949-1835-2024-3-3-40-48>

Введение. Трубобетонные колонны представляют собой композитные элементы, которые широко используются в высотных зданиях, опорах мостов и других большепролетных сооружений. Сложное взаимодействие между бетоном и стальной трубой приводит к более высокой прочности и более высокой способности поглощения энергии деформации по сравнению с обычными стальными трубами и железобетонными колоннами. Одной из важных задач является корректное прогнозирование несущей способности таких элементов.

На сегодняшний день область применения искусственного интеллекта (ИИ) в инженерии и строительстве включает прогнозирование прочности конструкций и успешно развивается. Начиная с 2020-х годов использование ИИ для расчета прочности трубобетонных колонн вызывает активный интерес. Примером может служить использование такого метода машинного обучения, как искусственные нейронные сети (ИНС) для прогнозирования прочности трубобетонных колонн на основе их геометрических характеристик и свойств материалов [1].

Основой для моделей машинного обучения служит обширная теоретическая и экспериментальная база. Численному и натурному исследованию напряженно-деформированного состояния трубобетонных колонн посвящено значительное количество работ. В работе [2], направленной на изучение механического поведения коротких трубобетонных колонн прямоугольного сечения со стальной оболочкой из холодногнутых профилей, была построена трехмерная твердоэлементная модель их работы при осевом сжатии. На основе построенной модели был проведен параметрический анализ с целью выявления влияния различных факторов на прочность и поведение рассматриваемых конструкций. Факторы включали модели деформирования, принятые для холоднодеформированной стали и бетона, отношение длины к ширине прямоугольного сечения, толщину и ширину стенки, а также прочность бетона и предел текучести холоднодеформированной стали. Эпюра напряжений была обоснованно упрощена в соответствии с предельным состоянием и предложена теоретическая формула с учетом коэффициента запаса для оценки предельной несущей способности трубобетонных колонн прямоугольного сечения с использованием метода суперпозиции. Здесь были проанализированы 144 конечно-элементные модели. Помимо метода конечных элементов были использованы аналитические методы, а также проведен анализ механического поведения колонн при осевом сжатии в условиях ползучести с целью изучения ее влияния на механическое поведение конструкций. В работе [3] при исследовании ползучести трубобетонных колонн были использованы экспериментальные методы. К образцам прикладывалась постоянная во времени осевая сжимающая нагрузка, и проводились замеры деформаций во времени для оценки коэффициента ползучести.

В работе [4] проведено исследование совместной работы бетона и облоймы в трубобетонных колоннах кольцевого сечения с оболочкой из алюминиевого сплава (CFCAT) при осевом сжатии численными методами. Здесь строится мелкоячеистая конечно-элементная трехмерная модель. Для бетона используется модель пластического повреждения, а для алюминиевого сплава принимается модель идеального упругопластического материала. По сравнению с работой [2] для решения поставленной задачи в работе [4] было не только проведено параметрическое исследование с использованием метода конечных элементов, но и построена регрессионная модель. В результате по сравнению с короткими колоннами из стальных труб, наполненных бетоном, трубы из алюминиевого сплава оказывали более слабое ограничивающее воздействие на бетонное ядро из-за более низкого модуля упругости.

В работе [5] исследуется влияние на несущую способность заполнения стальных труб высокопрочным сталефибробетоном в случае осевого сжатия. В результате исследования было установлено, что добавление в бетон стальной фибры сдерживает локальную потерю устойчивости стальной трубы и увеличивает пластичность и способность колонн рассеивать энергию, когда объемная доля стальной фибры составляет не менее 0,8 %.

Применение искусственного интеллекта к расчету прочности трубобетонных колонн было выполнено в работах [6–8]. При исследовании влияния коррозии стальных труб на предельную осевую несущую способность тонкостенных стальных трубчатых элементов круглого сечения, наполненных бетоном, в работе [5] была построена прогнозная нейросетевая модель. В результате проведенных испытаний был определен характер разрушения тонкостенных коротких трубобетонных колонн при наличии очагов коррозии трубы, и установлены отличия разрушения от аналогичных колонн со стальными трубами с обычной толщиной стенки.

Прогнозирование прочности стальных труб прямоугольного сечения, наполненных бетоном, при осевом сжатии с использованием ИИ является предметом исследования в работе [9]. Анализ возможностей нейронной сети прямого распространения для прогнозирования предельной нагрузки показал, что нейронная сеть с такой архитектурой является отличным предсказателем предельной нагрузки со значением коэффициента детерминации R^2 до 0,979. Отмечены преимущества нейронной сети прямого распространения. Метрики качества модели составили: для RMSE — 6,5 %; MAE — 9,7; R^2 — 0,98. Также была исследована эффективность прогнозирования предельной нагрузки в зависимости от структурных параметров, таких как соотношение ширины и высоты сечения, толщина стальной трубы, предел текучести стали, прочность бетона на сжатие и гибкость.

Механическое поведение трубобетонных колонн круглого и прямоугольного сечения, подвергнутых чистому осевому сжатию и комбинированному осевому сжатию с изгибом, исследовалось многими учеными, и их исследования предоставляют ценную информацию, такую как предел прочности и поведение образцов при нагрузке с эксцентриситетом [10–13].

В работе [10] для оптимизации проектирования трубобетонных колонн использованы алгоритмы PSO, GWO и IGWO, реализованные в среде MATLAB. В работе [11] для прогнозирования максимальной несущей способности трубобетонных колонн при осевом сжатии рассмотрены гибридные модели, оптимизированные с помощью природной метаэвристики, с использованием генетических алгоритмов (GA). В работе [12] также

применяются искусственные нейронные сети для прогнозирования предельной осевой нагрузки прямоугольных стальных трубчатых колонн, заполненных бетоном, на основе методов мягких вычислений. В работе [13] ИНС используется для прогнозирования предела прочности прямоугольных и круглых бетононаполненных стальных трубчатых колонн, подвергающихся центральному и внецентренному сжатию. Эмпирические уравнения также выводятся на основе весов и смещений ИНС для прогнозирования предельной прочности трубобетонных колонн. Предложенные эмпирические уравнения можно использовать как для колонн, заполненных бетоном нормальной прочности, так и для колонн из высокопрочного бетона с различными величинами гибкости (короткие и гибкие колонны). Результаты испытаний сравнивались с результатами, предсказанными на основе предложенных эмпирических уравнений, а также положениями американских, европейских и австралийских норм. Сравнительное исследование показывает, что предел прочности, предсказанный по предложенным уравнениям, имеет лучшую согласованность с экспериментальными результатами с наименьшей среднеквадратической ошибкой (MSE). Кроме того, коэффициенты, понижающие прочность, для предложенных уравнений рассчитываются с использованием моделирования методом Монте-Карло (MCS). В результате использование предложенных понижающих коэффициентов обеспечивает надежность трубобетонных колонн, спроектированных по разработанным уравнениям на основе ИНС, поскольку их показатели надежности соответствуют целевому значению 3,0, требуемому американскими нормами, или 3,8, требуемому европейскими и австралийскими нормами.

Искусственные нейронные сети используются при проектировании конструкций [14], при решении различных структурных задач, таких как структурная динамика [15, 16], оценка повреждений [17, 18], прогнозирование прочности бетона на сжатие [19–21], в проблемах устойчивости [22], структурного анализа и проектирования [23], а также оценки надежности конструкций [23–25].

Анализ научной литературы показывает, что популярность анализа с применением искусственного интеллекта в инженерии и строительстве, включая расчет прочности трубобетонных колонн, весьма внушительна как среди зарубежных исследователей, так и среди современных соотечественников. Из проведенного литературного обзора следует, что наиболее распространенным методом машинного обучения, используемым для прогнозирования несущей способности трубобетонных колонн, являются искусственные нейронные сети. Помимо ИНС существуют и другие эффективные методы машинного обучения, в частности алгоритм CatBoost. Преимуществом данного метода является более гибкая настройка и подбор параметров моделей машинного обучения. Целью настоящей статьи является построение прогнозных моделей для определения несущей способности трубобетонных колонн с использованием алгоритма CatBoost.

Материалы и методы. В настоящей статье рассматриваются внецентренно сжатые короткие трубобетонные колонны круглого поперечного сечения. В качестве входных параметров моделей были выбраны следующие величины, наиболее существенно влияющие на несущую способность: внешний диаметр колонны D_p (мм), толщина стенки трубы t_p (мм), предел текучести стали R_y (МПа), предел прочности бетона при сжатии R_b (МПа) и отношение эксцентриситета сжимающей силы к диаметру e/D_p . Формирование синтетических данных для выбранных параметров проводилось с использованием равномерного распределения с условием, что все значения внутри заданного диапазона равновероятны. Данный процесс позволяет создать реалистичные и разнообразные наборы данных, которые разрешают провести углублённый анализ и тестирование во всем возможном диапазоне изменения входных параметров.

Этапы формирования синтетических данных включают в себя следующие действия:

- определение параметров и их диапазонов распределений (для каждого параметра необходимо задать минимальное и максимальное значения);
- выбор числа симуляций;
- генерация синтетических данных;
- анализ и использование данных.

В таблице 1 частично представлен анализируемый массив данных. Общее количество численных экспериментов составило: $N = 179\,025$.

Таблица 1

Таблица исходных данных для обучения модели

№	D_p , мм	t_p , мм	R_y , МПа	R_b , МПа	e/D_p	N_{ult1} , кН	N_{ult2} , кН
1	102	1,8	240	10	0	246,6426693	201,2604182
2	102	1,8	240	10	0,0325	246,6426693	167,9636578
3	102	1,8	240	10	0,065	241,2165306	158,5912364
4	102	1,8	240	10	0,0975	202,0003462	149,7121003
5	102	1,8	240	10	0,13	168,2103005	141,5728922
6	102	1,8	240	10	0,1625	158,5912364	133,9269694
7	102	1,8	240	10	0,195	149,9587429	127,0209747
...							
179021	1420	32	440	65	0,52	55564,69738	55564,69738
179022	1420	32	440	65	0,5525	52487,26799	52487,26799
179023	1420	32	440	65	0,585	49751,7752	49580,8069
179024	1420	32	440	65	0,6175	47187,2507	47016,2824
179025	1420	32	440	65	0,65	44793,69451	44622,72621

Итого набор данных содержит 7 столбцов. В качестве входных параметров модели выступали: внешний диаметр колонны; толщина стенки трубы; предел текучести стали; предел прочности бетона при сжатии; относительный эксцентриситет. В качестве выходных параметров модели выступают: предельная нагрузка, определенная по действующим нормам проектирования сталежелезобетонных конструкций СП 266.1325800.2016 без учета случайных эксцентриситетов (N_{ult1}); предельная нагрузка по действующим нормам проектирования с учетом случайных эксцентриситетов (N_{ult2}).

В таблице 2 представлены статистические характеристики исходных наборов данных по выборке N для N_{ult1} и N_{ult2} .

Таблица 2

Статистические характеристики набора данных для обучения

index	D_p , mm	t_p , mm	R_y , МПа	R_b , МПа	e/D_p	N_{ult1}	N_{ult2}
count	179025	179025	179025	179025	179025	179025	179025
mean	444,1	10,61	340,0	37,5	0,32	9446,33	8777,55
std	361,76	7,44	70,71	19,45	0,2	15885,92	14818,42
min	102,0	1,8	240,0	10,0	0,0	74,98	66,59
max	1420,0	32,0	440,0	65,0	0,65	170968,3	170968,30

Для анализа и прогнозирования несущей способности колонн на основе их геометрических параметров и механических характеристик нами были применены методы машинного обучения, а именно регрессионная модель с использованием Gradient Boosting (CatBoost). Для оценки влияния каждого признака на предсказания модели использована функция Feature importance (важность признаков). При подборе гиперпараметров использован метод Optuna — усовершенствованный метод подбора гиперпараметров, включающий в себя gridsearch, random search и другие. Реализация моделей искусственного интеллекта проводилась в среде Jupyter Notebook.

Для моделей CatBoost Regressor выбраны параметры: iterations; depth; learning rate.

Для оценки качества моделей использовали метрики регрессии: Mean Squared Error (MSE); Mean Absolute Error (MAE); Mean Absolute Percentage Error (MAPE).

Построение моделей CatBoost Regressor проводилось следующим образом: предварительная обработка данных; разделение данных; подбор гиперпараметров с использованием GridSearchCV (таблица 3); обучение модели; оценка модели; оптимизация модели; настройка параметров модели; выбор наилучших значений параметров; использование модели для предсказаний с новыми данными.

Таблица 3

Подбор гиперпараметров модели

№	Параметр	Значение
1	'n_estimators'	[1000, 2000]
2	'learning_rate'	[0,05; 0,1; 0,2; 0,3; 0,5]
3	'max_depth'	[3, 4, 5, 8, 10]

Результаты исследования. Полученные в результате работы алгоритма машинного обучения наилучшие параметры моделей приведены в таблице 4.

Таблица 4

Наилучшие значения параметров моделей

Модель	Параметр	Значение
CatBoost N_{ult1}	iterations	1491
	depth	10
	learning_rate	0,5
CatBoost N_{ult2}	iterations	1443
	depth	10
	learning_rate	0,3

Оценка качества производительности моделей проводилась с помощью метрик: MSE; MAE; MAPE. Учитывая, что максимальное целевое значение составляет около 75 000, ошибка прогноза очень удовлетворительная, средняя абсолютная ошибка MAE = 9,2 для первой модели и MAE = 8,7 — для второй. Средняя ошибка в процентах совпадает по обеим моделям MAPE = 0,004, что говорит об их хорошем качестве. Коэффициенты детерминации в обеих моделях принимают значение близкое к 1 ($R_{1,2}^2 = 0,98$). Результаты расчетов представлены в таблице 5.

Таблица 5

Метрики качества

Метрика/Модель	Catboost N_{ult1}	Catboost N_{ult2}
MSE	9,024	8,673
MAE	9,250	8,673
MAPE (%)	0,004	0,004

На рис. 1, 2 представлены диаграммы, построенные с помощью функции Feature importance, определяющей важные признаки построенных моделей для N_{ult1} и для N_{ult2} соответственно. Наиболее значимыми признаками построенной модели для N_{ult1} являются D_p и e/D_p , менее значимыми — R_b и t_p , слабо влияющий признак — R_y .




Рис. 1. Влияния признаков на предсказания модели для N_{ult1}

Наиболее значимым признаком построенной модели для N_{ult2} также является D_p , остальные признаки распределяются по значимости более равномерно в отличие от модели для N_{ult1} в порядке убывания их влияния: e/D_p , R_b , t_p , R_y .




Рис. 2. Влияния признаков на предсказания модели для N_{ult2}

Построены графики рассеивания: по оси x — предсказанные значения; по оси y — действительные значения (рис. 3, 4).

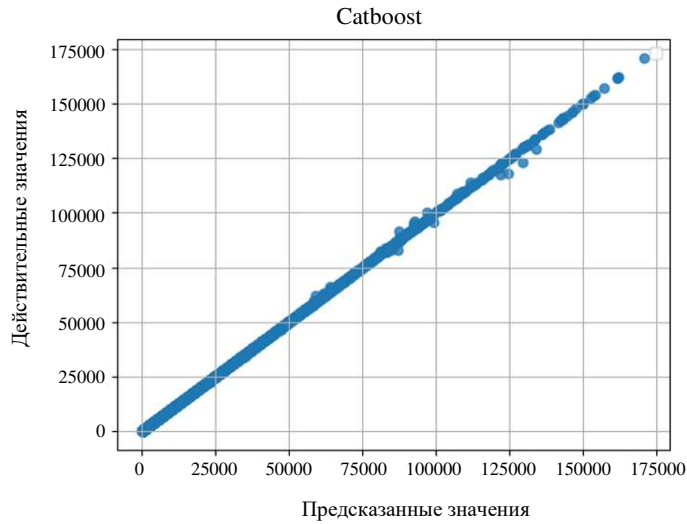


Рис. 3. Ошибка прогноза для N_{ult1}

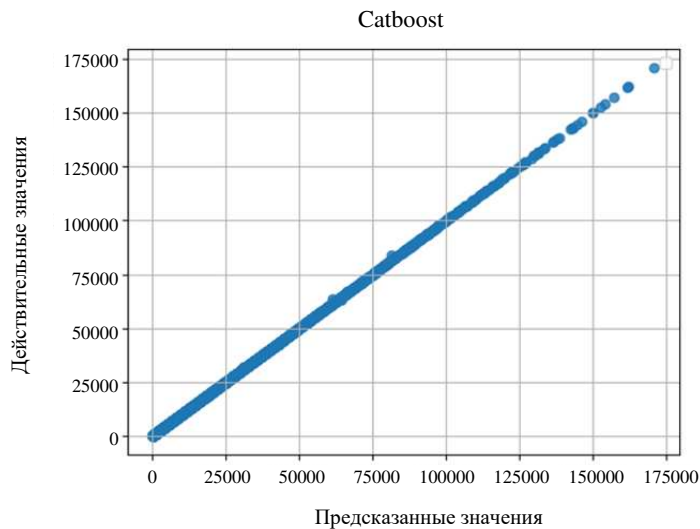


Рис. 4. Ошибка прогноза для N_{ult2}

Обсуждение и заключение. Разработанные модели Gradient Boosting для прогнозирования предельной нагрузки внецентренно сжатых коротких трубобетонных колонн круглого поперечного сечения без учета и с учетом дополнительных случайных эксцентриситетов показали высокую точность и стабильность предсказаний.

В работе определена важность признаков, влияющих на прогнозные значения модели. Важнейшие признаки включают в себя наружный диаметр колонны и относительный эксцентриситет, что, несомненно, согласуется с опытом проектирования и расчета таких конструкций. После оптимизации гиперпараметров с помощью метода Grid Search модель показала лучшие результаты по сравнению с первоначальной моделью. Высокая точность прогноза подтверждена низкой среднеквадратичной ошибкой на тестовой выборке.

Разработанная модель может быть использована для практических целей, таких как оценка прочности колонн в проектировании и строительстве, что позволит сократить время и ресурсные затраты на физические испытания.

В перспективе дальнейших исследований планируется разнообразить данные, включить другие материалы обоймы (стеклопластики и углепластики), геометрии сечения колонн (квадратное, кольцевое) и параметр гибкости, что поможет улучшить обобщающие способности модели.

Список литературы / References

1. Chepurnenko AS, Turina VS, Akopyan VF. Artificial Intelligence Model for Predicting the Load-Bearing Capacity of Eccentrically Compressed Short Concrete Filled Steel Tubular Columns. *Construction Materials and Products*. 2024;7(2):2. <https://doi.org/10.58224/2618-7183-2024-7-2-2>
2. Zhang N, Zheng C, Sun Q. Creep Behavior of Reinforced Concrete-Filled Steel Tubular Columns Under Axial Compression. *PLoS ONE*. 2021;16(9):e0255603. <https://doi.org/10.1371/journal.pone.0255603>
3. Wang L, An Y, Ding F, Kuang Y, Ma Qing, Tan S, et al. Numerical Investigation of Composite Behavior and Strength of Rectangular Concrete-Filled Cold-Formed Steel Tubular Stub Columns. *Materials*. 2021;14(20):6221. <https://doi.org/10.3390/ma14206221>
4. Ding F, Liao C, Wang E, Lyu F, Xu Y, Liu Y, et al. Numerical Investigation of the Composite Action of Axially Compressed Concrete-Filled Circular Aluminum Alloy Tubular Stub Columns. *Materials*. 2021;14(9):2435. <https://doi.org/10.3390/ma14092435>
5. Liu S, Ding X, Li X, Liu Y, Zhao S. Behavior of Rectangular-Sectional Steel Tubular Columns Filled with High-Strength Steel Fiber Reinforced Concrete under Axial Compression. *Materials*. 2019;12(17):2716. <https://doi.org/10.3390/ma12172716>
6. Zhang F, Xia J, Li G, Guo Z, Chang H, Wang K. Degradation of Axial Ultimate Load-Bearing Capacity of Circular Thin-Walled Concrete-Filled Steel Tubular Stub Columns after Corrosion. *Materials*. 2020;13(3):795. <https://doi.org/10.3390/ma13030795>
7. Alashker Y, Raza A. Seismic Performance of Recycled Aggregate Geopolymer Concrete-Filled Double Skin Tubular Columns with Internal Steel and External FRP Tube. *Polymers*. 2022;14(23):5204. <https://doi.org/10.3390/polym14235204>
8. Liu W, Cao W, Zhang J, Wang R, Ren L. Mechanical Behavior of Recycled Aggregate Concrete-Filled Steel Tubular Columns before and After Fire. *Materials*. 2017;10(3):274. <https://doi.org/10.3390/ma10030274>
9. Nguyen HQ, Ly H-B, Tran VQ, Nguyen T-A, Le T-T, Pham BT. Optimization of Artificial Intelligence System by Evolutionary Algorithm for Prediction of Axial Capacity of Rectangular Concrete Filled Steel Tubes under Compression. *Materials*. 2020;13(5):1205. <https://doi.org/10.3390/ma13051205>
10. Zakian P, Ordoubadi B, Alavi E. Optimal Design of Steel Pipe Rack Structures Using PSO, GWO, and IGWO Algorithms. *Advances in Structural Engineering*. 2021;24(11):2529–2541. <https://doi.org/10.1177/13694332211004116>
11. Luat NV, Shin J, Lee K. Hybrid BART-Based Models Optimized by Nature-Inspired Metaheuristics to Predict Ultimate Axial Capacity of CCFST Columns. *Engineering with Computers*. 2022;38:1421–1450. <https://doi.org/10.1007/s00366-020-01115-7>
12. Le TT, Asteris PG, Lemonis ME. Prediction of Axial Load Capacity of Rectangular Concrete-Filled Steel Tube Columns Using Machine Learning Techniques. *Engineering with Computers*. 2022;38(Suppl 4):3283–3316. <https://doi.org/10.1007/s00366-021-01461-0>
13. Zarringol M, Thai H-T, Thai S, Patel V. Application of ANN to the Design of CFST Columns. *Structures*. 2020;28:2203–2220. <https://doi.org/10.1016/j.istruc.2020.10.048>
14. Chojaczyk AA, Teixeira AP, Neves LC, Cardoso JB, Guedes Soares C. Review and Application of Artificial Neural Networks Models in Reliability Analysis of Steel Structures. *Structural Safety*. 2015;52:78–89. <https://doi.org/10.1016/j.strusafe.2014.09.002>
15. Tahir ZuR, Mandal P. Artificial Neural Network Prediction of Buckling Load of Thin Cylindrical Shells under Axial Compression. *Engineering Structures*. 2017;152:843–855. <https://doi.org/10.1016/j.engstruct.2017.09.016>
16. Hajela P, Berke L. Neurobiological Computational Models in Structural Analysis and Design. *Computers & Structures*. 1991;41(4):657–667. [https://doi.org/10.1016/0045-7949\(91\)90178-O](https://doi.org/10.1016/0045-7949(91)90178-O)

17. Stoffel M, Gulakala R, Bamer F, Markert B. Artificial Neural Networks in Structural Dynamics: A New Modular Radial Basis Function Approach vs. Convolutional and Feedforward Topologies. *Computer Methods in Applied Mechanics and Engineering*. 2020;364:112989. <https://doi.org/10.1016/j.cma.2020.112989>
18. Jeyasehar CA, Sumangala K. Damage Assessment of Prestressed Concrete Beams Using Artificial Neural Network (ANN) Approach. *Computers & Structures*. 2006;84(26–27):1709–1718. <https://doi.org/10.1016/j.compstruc.2006.03.005>
19. Lee S-C. Prediction of Concrete Strength Using Artificial Neural Networks. *Engineering Structures*. 2003;25(7):849–857. [https://doi.org/10.1016/S0141-0296\(03\)00004-X](https://doi.org/10.1016/S0141-0296(03)00004-X)
20. Trtnik G, Kavčič F, Turk G. Prediction of Concrete Strength Using Ultrasonic Pulse Velocity and Artificial Neural Networks. *Ultrasonics*. 2009;49(1):53–60. <https://doi.org/10.1016/j.ultras.2008.05.001>
21. Ni H-G, Wang J-Z. Prediction of Compressive Strength of Concrete by Neural Networks. *Cement and Concrete Research*. 2000;30(8):1245–1250. [https://doi.org/10.1016/S0008-8846\(00\)00345-8](https://doi.org/10.1016/S0008-8846(00)00345-8)
22. Silva VP, Carvalho RdA, Rego JHdS, Evangelista F. Machine Learning-Based Prediction of the Compressive Strength of Brazilian Concretes: A Dual-Dataset Study. *Materials*. 2023;16(14):4977. <https://doi.org/10.3390/ma16144977>
23. Chen X, Zhang Y, Ge P. Prediction of Concrete Strength Using Response Surface Function Modified Depth Neural Network. *PLoS ONE*. 2023;18(5):e0285746. <https://doi.org/10.1371/journal.pone.0285746>
24. Raju MR, Rahman M, Hasan MM, Islam MM, Alam MS. Estimation of Concrete Materials Uniaxial Compressive Strength Using Soft Computing Techniques. *Heliyon*. 2023;9(11): e22502. <https://doi.org/10.1016/j.heliyon.2023.e22502>
25. Du G, Bu L, Hou Q, Zhou J, Lu B. Prediction of the Compressive Strength of High-Performance Self-Compacting Concrete by an Ultrasonic-Rebound Method Based on a GA-BP Neural Network. *PLoS ONE*. 2021;16(5):e0250795. <https://doi.org/10.1371/journal.pone.0250795>

Об авторах:

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

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

Заявленный вклад авторов:

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. (Engineering), Associate Professor of the Mathematics and Informatics Department, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [ResearcherID](#), [ScopusID](#), [ORCID](#), ktn618@yandex.ru

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

Claimed Contributorship:

TN Kondratieva: formulating the main concept, aim and objectives of the research, conducting the calculations, analysis of the research results.

AS Chepurnenko: scientific supervision, refining the text, correcting the conclusions.

Conflict of Interest Statement: the authors declare no conflict of interest.

All authors have read and approved the final manuscript.

Поступила в редакцию / Received 08.08.2024

Поступила после рецензирования / Reviewed 28.08.2024

Принята к публикации / Accepted 10.09.2024