

Использование методов машинного обучения для конвертирования скана в элементы цифровой информационной модели

Н.В. Князева, Д.А. Семенихин, С.Д. Казаков

Московский государственный строительный университет, Москва

Аннотация: В статье рассмотрены методы машинного обучения, сферы их приложения, ограничения и возможности применения. Отдельно выделены достижения в области глубокого обучения, которые позволяют получить точные результаты с оптимальными затратами времени и сил. Также детально описана перспективная на сегодняшний день архитектура нейронных сетей трансформеров. В качестве альтернативного подхода предложено использовать в процессе конвертирования скана в элементы цифровой информационной модели генеративную состязательную сеть.

Ключевые слова: сканирование, облако точек, информационная модель, строительство, объекты, представление, нейронная сеть, машинное обучение

Введение. Архитекторы и геодезисты часто испытывают трудности с поиском точной информации и реальных изображений уже построенных конструкций. Данная ситуация возникает вследствие того, что либо конструктивные элементы повреждены, либо проектные документы отсутствуют, либо определенное механическое, электрическое, сантехническое оборудование труднодоступно [1-3]. Более того, во многих случаях существующие проектные документы не соответствуют реальным условиям. Это создает значительные проблемы при реконструкции или ремонте зданий.

В данном случае на помощь приходят цифровые технологии в области архитектуры, проектирования и строительства, которые стремительно развиваются: прогнозируется, что в период с 2024 по 2026 год объем венчурных инвестиций на поздних стадиях развития строительных инноваций достигнет 14,7 миллиарда долларов, что более чем в три раза превышает объем инвестиций за предыдущие три года [4]. Особого внимания для решения вышеобозначенных проблем заслуживает технология конвертации в цифровые информационные модели (ЦИМ), что обычно называют рабочим процессом конвертации скана в ЦИМ.

Этот рабочий процесс состоит из трех основных этапов, включая сбор данных, обработку данных и ЦИМ-моделирование. Обычно данные (в виде облаков точек) получают с помощью методов фотограмметрии и LiDAR-сканирования, которые оказываются чрезвычайно точными при регистрации сложной геометрии зданий и инфраструктур и позволяют сэкономить время в полевых условиях. После ряда этапов обработки данных, полученных на месте, таких как очистка и регистрация данных, формулируется окончательное облако точек, описывающее отсканированную среду, что позволяет использовать обработанные данные в дальнейшем ЦИМ-моделировании.

Обычной практикой в отрасли является ручная подача данных лазерного сканирования в инструменты ЦИМ-авторинга (например, Autodesk Revit, Bentley, Graphisoft ArchiCAD) и последующее создание ЦИМ. Однако ручной процесс отнимает много времени и приводит к ошибкам, особенно для крупномасштабных проектов с большим количеством элементов здания и сложной геометрией. По данным Национального института стандартов и технологий США, 57% отходов, не связанных с добавленной стоимостью, приходится на неэффективное управление информацией, такое как ручной сбор данных, перевод и документирование [3]. Поэтому исследователи на сегодняшний день сосредоточены на разработке полуавтоматизированных или автоматизированных методов преобразования сканирования в ЦИМ, чтобы заменить ручной подход. Ситуация меняется благодаря искусственному интеллекту (ИИ). Потенциал ИИ в обработке огромных объемов данных, распознавании образов, а также принятии решений дает больше возможностей для сканирования в ЦИМ.

Так, например, одним из наиболее значимых достижений является семантическая сегментация 3D на основе глубоких нейронных сетей (DNN). С использованием публичных и масштабных 3D-данных учеными были

разработаны и обучены DNN, такие как PointNet++ и KPConv, для предсказания семантических категорий каждой точки в 3D-скане интерьера здания, что эквивалентно сегментированию скана на кластеры, принадлежащие различным физическим объектам. Другим основным направлением, которое также нацелено на понимание семантики, является обнаружение 3D-объектов, которое поможет распознать и реконструировать мебель или небольшие объекты в интерьере здания.

Тем не менее, усилия по систематическому определению и обсуждению ключевых этапов и соображений в процессе конвертации скана в ЦИМ с использованием технологий ИИ, в качестве основы для исследований и практической реализации, все еще ограничены. Поэтому необходимость проведения дальнейших изысканий в данном направлении и предопределила выбор темы данной статьи.

Анализ публикаций по теме исследования. Обзор современного состояния рабочего процесса конвертации скана в ЦИМ с детализацией его различных этапов, выделением возможностей и текущих проблем, связанных с интеграцией технологий ИИ, представлен работами Комиссарова А.В., Ремизова А.В., Евтушенко С.И., Феттер М.Г., Liang Zhao, Hong Zhang, Qian Wang, Haining Wang [1,4].

Влияние шумов, выбросов и избыточности данных лазерного сканирования на точность моделей информационного моделирования зданий описывают в своих публикациях Серков В.В., Резванов Д.Х., Гилаев Д.М., Наануа Ю., Васютинская С.И., Markus Ehm, Christian Hesse, Rafika Hajji, Hassane Jarar Oulidi [5,6].

Над формализацией требований к информации, необходимой ЦИМ-приложению, и обоснованием критериев качества данных сканирования для удовлетворения показателей точности ожидаемой модели трудятся Царёва О.С., Добрыневский Н.А., Махутова В.Э., Яценко В.П., Голиков В.И.,

Зинкевич А.В., Heng Sun, Zhe Liu, Yan Wan, Yujia Zhai, Xiaoxiao Wang, Can Cui [4].

Нерешенные части общей проблемы. Несмотря на то, что обработка облаков точек на основе нейронных сетей помогает процессу конвертации скана в ЦИМ в понимании семантики и реконструкции геометрии, запуск полностью автоматического процесса конвертирования сталкивается с определенными проблемами. Так, например, на практике трудно определить допустимое пороговое значение для среднего расстояния между точками. Средние расстояния между точками некоторых отрицательных экземпляров даже меньше, чем у истинно положительных, что затрудняет проведение хорошего различия. Кроме того, существующие крупномасштабные наборы данных для тестирования алгоритмов на основе нейронных сетей значительно проще и меньше тех, которые используются в практике. В результате чего возникает разрыв между заявленной точностью и реальным применением в данном процессе.

Таким образом, с учетом вышеизложенного, **цель статьи** заключается в изучении возможностей использования методов машинного обучения для конвертирования скана в элементы ЦИМ.

Результаты. Прежде всего отметим, что процесс конвертации скана в ЦИМ — это трансформационная технология, которая позволяет преодолеть разрыв между физическим и цифровым миром. Она предполагает преобразование данных трехмерного лазерного сканирования, часто называемых облаками точек, в точные трехмерные информационные модели зданий. Эти модели являются цифровым представлением реальных структур и инфраструктур и содержат всю геометрическую и семантическую информацию об элементах здания [6]. Особую ценность процесс конвертации скана в ЦИМ представляет для анализа труднодоступного оборудования, которое имеет основополагающее значение в процессе

эксплуатации и поддержке эффективности зданий. В процессе конвертации скана в ЦИМ точное представление этих систем имеет важное значение для эффективного проектирования, установки и обслуживания оборудования. К данному оборудованию относятся:

- системы отопления, вентиляции, кондиционирования воздуха;
- сантехника;
- противопожарная защита;
- электрические системы;
- системы передачи данных и связи.

С технической точки зрения процесс конвертации скана в ЦИМ представляет собой набор операций, необходимых для получения модели, и в настоящее время он достаточно детально и подробно описан в литературе. Этот процесс можно разделить на (1) создание облака точек на основе существующей структуры, (2) предварительную обработку данных и (3) создание модели [7]. Более того, сами эти этапы могут быть далее разделены на более детальные элементы, как показано на рисунке 1, включая такие шаги, как сбор и регистрация данных для первого этапа, различные алгоритмы фильтрации для второго, и моделирование геометрии или назначение связей для последнего этапа.

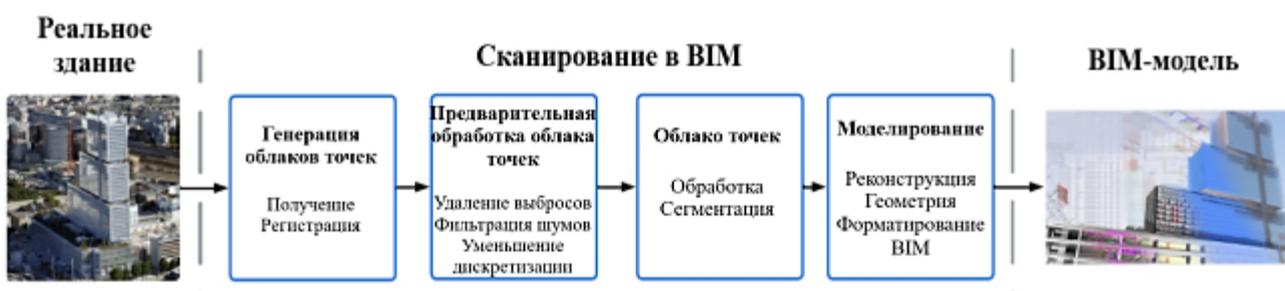


Рис. 1 Различные этапы преобразования скана в ЦИМ

Первые попытки сегментировать инженерные объекты из облаков точек, которые предполагали использование методов машинного обучения, включали в себя метод декомпозиции объёма данных, метод анализа главных

компонент и кластеризации, а также метод выращивания областей. Несмотря на то, что эти подходы демонстрируют высокую производительность в своих приложениях, они часто требуют ручного построения геометрических дескрипторов, адаптированных к конкретным сценариям, что ограничивает их эффективность и универсальность. В последние годы появление глубоких нейронных сетей ознаменовало значительный сдвиг в сторону методов глубокого обучения, которые привлекли к себе значительное внимание благодаря своим широким возможностям в таких задачах, как классификация, обнаружение и семантическая сегментация объектов [8]. В отличие от методов машинного обучения, методы глубокого обучения позволяют автоматически извлекать полезные признаки, которые как описывают объекты, так и адаптируются к различным условиям, предлагая более гибкие решения в зависимости от ситуации. Поэтому сегодня семантическая сегментация облаков точек на основе глубокого обучения нашла свое широкое применение в инфраструктурных и строительных проектах.

Самыми последними работами по конвертации сканов на основе глубокого обучения стали PREDATOR, RGM и PointDSC. PREDATOR обрабатывает парную регистрацию 3D-облаков точек с малым перекрытием. Метод работает по схеме «кодер-декодер» и учится распознавать перекрытие между двумя незарегистрированными облаками точек. RGM использует подход глубокого сопоставления графов для решения проблемы промахов при регистрации облаков точек. В рамках этого подхода из облаков точек строятся графы для извлечения характеристик узлов, а затем разрабатывается модуль - AIS - для установления соответствия между двумя узлами графа. PointDSC — это сеть отбраковки выбросов для регистрации облаков точек, которая явно использует пространственную согласованность, создаваемую евклидовым преобразованием [9].

В таблице 1 приведены характеристики некоторых методов преобразования скана в ЦИМ с использованием глубокого обучения.

Таблица № 1

Методы преобразования скана в ЦИМ на основе глубокого обучения

№ п/п	Метод	Год	Архитектура	Тестовые показатели	Приложения
1	PPFNet	2018	PointNet	3DMatch	В помещении
2	PPF Foldnet	2018	PointNet	3DMatch	В помещении
3	PointNetLK	2019	PointNet	ModelNet40	В помещении
4	PCNet	2019	PointNet	ModelNet40	В помещении
5	3D FeatNet	2018	Siamese CNN	KITTI, ETH, OxfordRobot	На открытом воздухе
6	DCP	2019	DGCNN	ModelNet40	В помещении
7	Deep VCP	2019	CNN	KITTI, Apollo-SouthBay	На открытом воздухе
8	FCGF	2019	ResUNet	KITTI, 3DMatch	В помещении и на открытом воздухе
9	AlignNet-3D	2019	CanonicalNet, MLP	ModelNet40, KITTI	На открытом воздухе
10	D3 FeatNet	2020	KPCONV	KITTI, 3DMatch, ETH	В помещении и на открытом воздухе
11	DeepGMR	2020	PointNet	ModelNet40, ICL-NUIM	В помещении
12	PREDATOR	2020	GNN	3DMatch, DLoMatch,	В помещении

				ModelNet40	
--	--	--	--	------------	--

Особую актуальность на сегодняшний день для задач преобразования скана в ЦИМ приобретают нейронные сети трансформеры, которые достигают высокой производительности в задачах обнаружения аномалий при низком времени вывода. Это дает множество преимуществ, включая возможность улавливать нечеткие зависимости и сложные взаимодействия в данных, что особенно важно в процессе детектирования труднодоступных объектов. На рис. 2 представлена архитектура нейронной сети трансформатора.

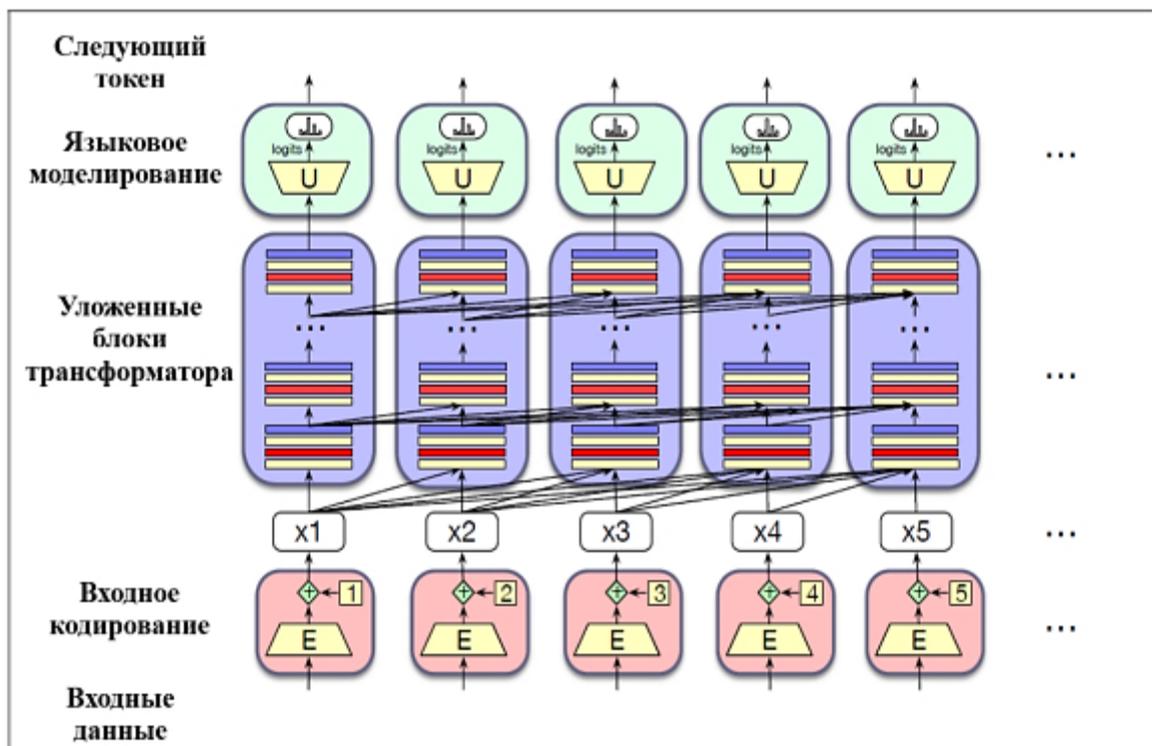


Рис. 2 Архитектура нейронной сети трансформатора [3]

Для применения трансформатора данные должны быть преобразованы в набор или последовательность из N лексем $x_n^{(0)}$ размерности D . Токены можно собрать в матрицу $X^{(0)}$, которая имеет размерность $D \times N^2$.

Трансформатор получает входные данные $X^{(0)}$ и возвращает представление последовательности в терминах другой матрицы $X^{(M)}$, которая

также имеет размер $D \times N$. Срез $x_n = X_{:,n}^{(M)}$ является вектором признаков, представляющих последовательность в месте расположения маркера n . Эти представления могут быть использованы для авторегрессивного предсказания следующего $(n+1)$ -го маркера, глобальной классификации всей последовательности (путем объединения всех представлений), задач предсказания последовательности от последовательности к последовательности или изображения от изображения к изображению и т.д. M обозначает количество слоев в трансформаторе.

Представление входной последовательности создается путем итеративного применения блока трансформации:

$$X^{(m)} = \text{блок трансформации}(X^{(m-1)})$$

Сам блок состоит из двух этапов: один работает с последовательностью, другой - с признаками. На первом этапе каждый признак уточняется независимо, в соответствии с отношениями между лексемами в последовательности, например, насколько два разных пятна изображения, полученные в ходе сканирования, связаны друг с другом. Этот этап действует горизонтально по строкам $X^{(m-1)}$. На втором этапе уточняются признаки, представляющие каждую лексему. Этот этап действует по вертикали через столбец $X^{(m-1)}$. Путем многократного применения блока трансформации представление на маркере n и признаке d может быть сформировано информацией на маркере n' и признаке d' .

Блок кодера состоит из N одинаковых слоев. Каждый слой имеет два подслоя, которые представляют собой слой самовнушения с несколькими элементами и слой с прямой передачей (FF). Слой FF является простой нейронной сетью, состоящей из 2 линейных слоев с полным подключением (FC) и функцией активации между ними. В частности, можно использовать слой FC с функцией активации ReLU:

$$\text{ReLU}(x) = \max(0, x)$$

Затем следует еще один слой FC без функции активации, т.е.

$$FFN(x) = W_2 \cdot ReLU(W_1 \cdot x + b_1) + b_2$$

где W_1 , W_2 , b_1 , b_2 - весовые матрицы и векторы смещения соответственно для слоев FC.

По мнению автора, альтернативой нейронным трансформерам может служить генеративная состязательная сеть (GAN). GANs — это новый тип нейронных сетей, который основан на реализации двух нейронных сетей, конкурирующих в игре с нулевой суммой. Эти нейронные сети устроены так, что одна сеть является генератором, который создает образцы с тем же распределением, что и обучающие данные, а другая сеть является дискриминатором, который определяет, являются ли образцы настоящими или поддельными [10]. На рисунке 3 показана основная структура GAN.

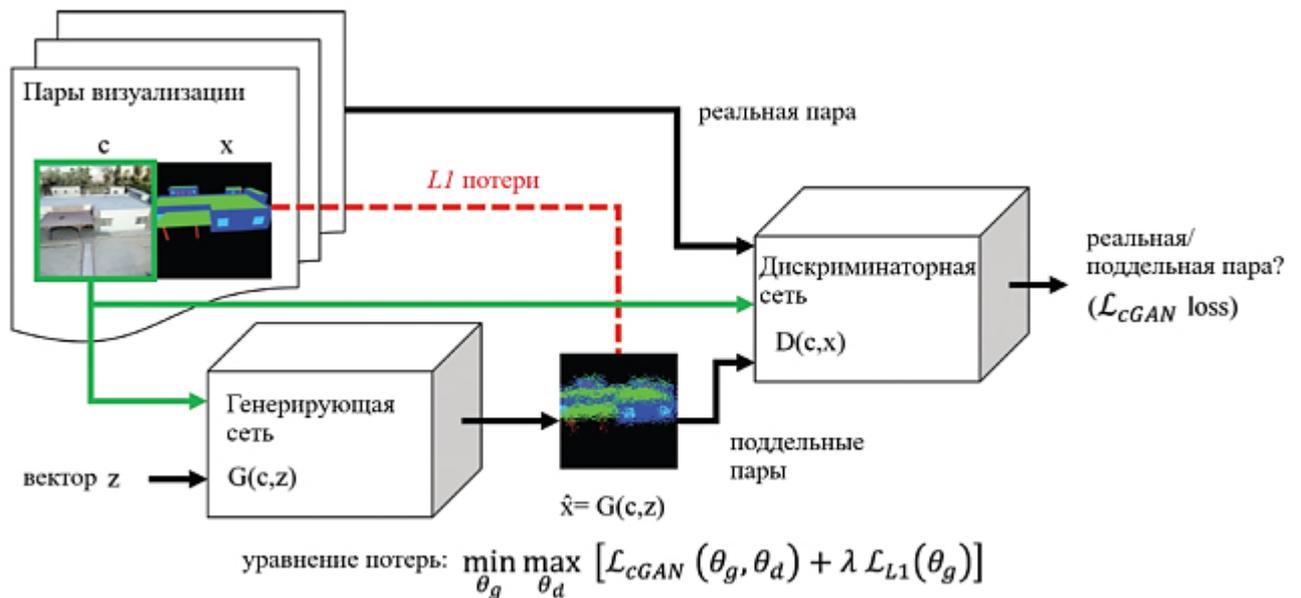


Рис. 3 Архитектура сети GAN [8]

Учитывая латентный вектор z , входную фотореалистичную визуализацию c и выходную цветомаркированную визуализацию x , генерирующая сеть $G(c,z)$ обучается генерировать цветные метки RGB из фотореалистичной визуализации c , чтобы обмануть дискриминаторную сеть $D(c,x)$, в то время как сеть дискриминатора $D(c,x)$ обучается определять

правильные метки x среди ложных. Существует также потеря $L1$, которая представляет собой проблему регрессии между метками генератора и исходными метками x . Потеря $L1$ может быть проигнорирована в других приложениях GAN, но для задач сканирования ЦИМ она считается полезной поэтому была включена в модель.

Заключение. Резюмируя результаты проведенного исследования, можно отметить, что процесс преобразование скана в ЦИМ вносит порядок в энтропию, присущую сфере строительства, где фрагментарные рабочие процессы слишком разрознены, а потребность в цифровых решениях очевидна. Данный процесс позволяет объединять разрозненные пространственные данные, такие как лазерные сканы, облака точек и данные о существующих зданиях, в целостную, унифицированную цифровую 3D-модель, которая отражает нужный физический или строительный актив и взаимозависимости.

В то же время, несмотря на растущий интерес к данному приложению, его использование на практике сопряжено с определенными проблемами. Лазерные сканеры генерируют данные, как правило, в виде больших, неструктурированных облаков точек, что делает их обработку достаточно сложной на практике. В данном случае технологией, которая позволяет упростить процесс преобразования скана в ЦИМ и повысить его эффективность, является машинное обучение. В статье рассмотрены возможности данной технологии, обозначены ее ограничения и преимущества. Отдельное внимание уделено методам глубокого обучения и сферам их приложения. Также детально описана перспективная на сегодняшний день архитектура нейронных сетей трансформеров. В качестве альтернативного подхода предложено использовать в процессе конвертирования скана в элементы ЦИМ-модели генеративную состязательную сеть.

Литература

1. Евтушенко С.И., Феттер М.Г. Методика расчета трудоемкости и стоимости создания 3D-тел при лазерном сканировании при реализации проекта DT- BIM // Строительство и архитектура. 2023. Т. 11. № 1. С. 22.
 2. Петров К.С., Швец Ю.С., Корнилов Б.Д., Шелкоплясов А.О. Применение BIM-технологий при проектировании и реконструкции зданий и сооружений, Инженерный вестник Дона, 2018. №4. URL: ivdon.ru/ru/magazine/archive/n4y2018/5255
 3. Шадрина К.С., Ганиченко Н.А., Коркишко А.Н. Проблемы внедрения BIM – технологий на примере предприятий города Тюмени и Тюменской области, Инженерный вестник Дона, 2020. №5. URL: ivdon.ru/ru/magazine/archive/N5y2020/6461
 4. Heng Sun, Zhe Liu Research on Intelligent Dispatching System Management Platform for Construction Projects Based on Digital Twin and BIM Technology // Advances in Civil Engineering. 2022. Volume 18, Issue 1. P. 12-19.
 5. Chunting Lu The Application of Laser-Scanning-Based BIM Technology in Large Steel Structure Engineering for Environmental Protection // Mathematical Problems in Engineering. 2022. Volume 2022, Issue 1. P. 103-109.
 6. Серков В.В., Резванов Д.Х., Гиляев Д.М. Лазерное сканирование, BIM-моделирование и создание цифровых двойников промышленных объектов // Маркшейдерский вестник. 2023. № 2 (150). С. 46-51.
 7. Царёва О.С., Добрыневский Н.А. Построение BIM-модели линейных объектов по результатам съемки малых БПЛА // Молодежный вестник ИрГТУ. 2023. Т. 13. № 3. С. 450-455.
 8. Carlos Ramonell, Rolando Chacón Open-source terrestrial laser scanner for
-

- the virtualization of geometrical entities in AEC classrooms // Computer Applications in Engineering Education. 2022. Volume 30, Issue 4. P. 41-49.
9. Курбанов О.А. Оценка перспектив применения наземного 3d-лазерного сканирования при строительно-монтажных работах нежилых зданий // Интернаука. 2024. № 20-1 (337). С. 17-23.
10. Wan Yan, Zhai Yujia Evaluation of Indoor Energy-Saving Optimization Design of Green Buildings Based on the Intelligent GANN-BIM Model // Mathematical Problems in Engineering. 2022. Volume 4, Issue 1. P. 56-62.

References

1. Evtushenko S.I., Fetter M.G. Stroitel'stvo i arhitektura. 2023. T. 11. № 1. pp. 22.
2. Petrov K.S., Shvec Ju.S., Kornilov B.D., Shelkopljasov A.O. Inzhenernyj vestnik Dona, 2018, №4. URL: ivdon.ru/ru/magazine/archive/n4y2018/5255
3. Shadrina K.S., Ganichenko N.A., Korkishko A.N Inzhenernyj vestnik Dona, 2020, №5. URL: ivdon.ru/ru/magazine/archive/N5y2020/6461
4. Heng Sun, Zhe Liu Advances in Civil Engineering. 2022. Volume 18, Issue 1. pp. 12-19.
5. Chunting Lu Mathematical Problems in Engineering. 2022. Volume 2022, Issue 1. pp. 103-109.
6. Serkov V.V., Rezvanov D.H., Gilaev D.M. Markshejderskij vestnik. 2023. № 2 (150). pp. 46-51.
7. Carjova O.S., Dobrynevskij N.A. Molodezhnyj vestnik IrGTU. 2023. T. 13. № 3. pp. 450-455.
8. Carlos Ramonell, Rolando Chacón Computer Applications in Engineering Education. 2022. Volume 30, Issue 4. pp. 41-49.
9. Kurbanov O.A. Internauka. 2024. № 20-1 (337). pp. 17-23.
10. Wan Yan, Zhai Yujia Mathematical Problems in Engineering. 2022. Volume 4, Issue 1. pp. 56-62.

Дата поступления: 18.03.2025 Дата публикации: 24.05.2025
