

УДК 378.147

DOI: 10.54835/18102883_2025_38_2

ОСОБЕННОСТИ ПРИМЕНЕНИЯ БУДУЩИМИ ИНЖЕНЕРАМИ ТЕХНОЛОГИИ ГЛУБОКОГО ОБУЧЕНИЯ В РЕШЕНИИ ПРАКТИЧЕСКИХ ЗАДАЧ

Наталья Александровна Моисеева,

кандидат педагогических наук, доцент,

доцент кафедры прикладной математики и фундаментальной информатики,

nat_lion@mail.ru

Омский государственный технический университет,
Россия, 625003, г. Омск, пр. Мира, 11

В статье рассматриваются ключевые аспекты и особенности применения технологий глубокого обучения будущими инженерами технического профиля для решения практических задач в различных областях промышленного сектора национальной цифровой экономики. В условиях стремительного развития концепции Industry 4.0 и роста объемов данных, включая промышленные, глубокое обучение становится важным инструментом в арсенале современного инженера. Проведен анализ алгоритмов глубокого обучения, а также представлены примеры интеграции интеллектуальных моделей в реальные производственные процессы. Особое внимание уделяется успешному применению искусственных нейронных сетей для прогнозирования прочности бетона на сжатие. В заключение подчеркивается необходимость формирования у студентов навыков работы с современными инструментами анализа промышленных данных и разработки цифровых моделей, что позволит им эффективно решать сложные аналитические задачи и адаптироваться к быстро меняющимся требованиям современного рынка труда. Статья будет полезна как студентам, так и преподавателям, заинтересованным в технологиях искусственного интеллекта, особенно в области глубокого обучения, в контексте образовательного процесса подготовки будущих инженерных кадров.

Ключевые слова: инженерное образование, инженер, искусственный интеллект, машинное обучение, глубокое обучение, искусственные нейронные сети

Введение

Стратегический курс России на технологический суверенитет, обозначенный президентом В. Путиным, требует кардинального пересмотра подходов к подготовке инженерных кадров. Как отмечают Д. Чернышенко¹ и М. Мишустин², эта задача становится ключевой для национальной безопасности и экономического развития страны. Важнейшую роль в реализации этой задачи играет система высшего инженерного образования, которая служит фундаментом для формирования инженерного потенциала РФ. В этом контексте трансформация стратегических инициатив, особенно в области технологических инноваций, научных исследований и высоких технологий, приобретает особое значение [1]. Приоритетные направления Научно-техниче-

ской инициативы (НТИ) до 2035 г.³ (AeroNet, AutoNet, MariNet, EnergyNet, TechNet) требуют наличия высококвалифицированных инженеров, владеющих сквозными цифровыми технологиями (СЦТ), особенно в сфере искусственного интеллекта (Artificial Intelligence, AI), в частности глубокого обучения (Deep Learning, DL) [2]. Это подчеркивает необходимость интеграции современных технологий AI в образовательные программы.

В России активно проводятся хакатоны⁴, на которых будущие IT-специалисты и студенты инженерно-технических направлений объединяются для решения междисциплинарных проектов с использованием AI в сфере инженерного проектирования. Ярким примером является хакатон «AI в инженерном ПО», где участникам была поставлена задача создания

¹ Первые стратегии инженерных вузов будут готовы к началу марта. URL: <https://объясняем.рф/articles/news/pervye-strategii-inzhenernykh-vuzov-budut-gotovy-k-nachalu-marta/> (дата обращения: 08.02.2025).

² Мишустин рассказал об усилении подготовки инженерных кадров. URL: <https://xn--m1agf.xn--p1ai/events/mishustin-rasskazal-ob-usilenii-podgotovki-inzhenernykh-kadrov/> (дата обращения: 08.02.2025).

³ Рынки НТИ. URL: <https://nti2035.ru/markets/> (дата обращения: 08.02.2025).

⁴ Хакатон (от англ. hackathon – это комбинация слов hacker и marathon) представляет собой инновационный образовательный формат соревнований, в ходе которых междисциплинарные команды специалистов в интенсивном режиме разрабатывают прототипы программного обеспечения или других технологических решений.

CAD-моделей на основе чертежей с применением AI⁵. В феврале 2025 г. Уральский федеральный университет открыл прием заявок на хакатон «Инженерный код» для школьников и студентов, где команды разрабатывали эффективные цифровые инженерные решения для шести предложенных промышленных кейсов⁶. Важно отметить, что идет активная финансовая поддержка национальных стартапов, которые представляют инновационные решения с использованием СЦТ [3]. Одним из примеров является отечественный промышленный стартап в рамках инициативы AutoNet. Этот проект демонстрирует синергию передовых машиностроительных разработок и технологий искусственного интеллекта и направлен на ускорение процесса проектирования автомобилей⁷. Именно технология «инженерного искусственного интеллекта»⁸ сыграла ключевую роль в создании автомобиля.

Тем не менее, несмотря на активное проведение хакатонов и поддержку промышленных стартапов, остается серьезная проблема: фундаментальная подготовка будущих инженеров в области DL все еще недостаточно развита. На сегодняшний день искусственные нейронные сети (Artificial Neural Network, ANN) являются мощным инструментом в машинном обучении (Machine Learning, ML), способным анализировать и моделировать комплексные нелинейные взаимосвязи между входными и выходными данными [6]. В России нейротехнологиям уделяется все большее внимание, и принят ряд нормативно-правовых актов, касающихся их перспективного развития в контексте цифровой экономики и различных отраслей промышленности. В дорожной карте развития СЦТ «Нейротехнологии и искусственный интеллект» выделены семь ключевых субтехнологий [7–9], включая перспективные методы и технологии в AI, рекомендательные системы и интеллектуальные системы поддержки принятия решений, нейроинтерфейсы и др. В Стратегии развития

информационного общества также подчеркивается важность развития информационно-коммуникационных технологий на базе нейросетевых технологий [8].

Современные абитуриенты проявляют значительный интерес к обучению по индустриальным специальностям в технических вузах России. Анализ данных за 2023–2024 учебный год показывает устойчивый рост интереса к инженерным специальностям: 1,35 млн студентов ($\approx 30\%$ от общего числа) обучаются по техническим направлениям [10]. Прирост набора на инженерные программы составил 7 % за 2022–2024 гг., достигнув 41 % от общего приема⁹. В условиях стремительных изменений на рынке труда, вызванных требованиями цифровой экономики и концепцией Industry 4.0, технические университеты, готовящие будущих инженеров, должны оперативно реагировать на актуальные запросы. В частности, студентам необходимо овладеть навыками применения современных технологий AI в своей профессиональной области, чтобы оставаться конкурентоспособными [11]. В настоящее время AI используется в инженерной отрасли больше, чем когда-либо [12], и по данным федерального проекта «Искусственный интеллект» [9], к 2030 г. 95 % российских компаний внедрят AI-технологии. Ожидается, что это внедрение принесет национальной экономике дополнительные 11,2 трлн р. к 2030 г., что подчеркивает важность подготовки инженеров с соответствующими навыками.

Формирование кадрового потенциала инженерно-технических работников в производственных компаниях становится особенно актуальным в свете этих изменений. Нейросетевые технологии играют ключевую роль в этом процессе, и высокий интерес абитуриентов к индустриальным специальностям подчеркивает необходимость своевременного освоения технологий DL будущими инженерами. Важно отметить острую потребность в

5 AI в инженерном ПО. URL: <https://www.xn--80aa3anexr8c.xn--p1acf/t/post/8tk07v57c1-ai-v-inzhenernom-po> (дата обращения: 08.02.2025).

6 Инженерный код. URL: <https://engineer.urfu.ru/> (дата обращения: 08.02.2025).

7 Кораблева В. Революция на дорогах: отечественный стартап представил автомобиль, спроектированный с помощью платформы инженерного ИИ. URL: <https://www.techinsider.ru/science/1671185-revoluuciya-na-dorogah-otechestvennyi-startap-predstavil-avtomobil-sproektirovannyi-s-pomoshchyu-platformy-injenernogo-ii/> (дата обращения: 08.02.2025).

8 Инженерный AI – это область применения технологий AI в инженерных дисциплинах; включает в себя использование алгоритмов и моделей AI для решения различных задач, связанных с проектированием, анализом, оптимизацией и управлением инженерными системами [4, 5].

9 Качество приема в российские вузы: 2024. URL: <https://www.hse.ru/ege2024/> (дата обращения: 08.02.2025).

специалистах, обладающих высоким уровнем навыков в области DL, поскольку инженеры должны уметь эффективно использовать эти технологии для обработки и анализа промышленных данных, а также для создания инновационных цифровых решений в различных отраслях промышленности. Цель данной статьи заключается в анализе специфики использования ANN будущими инженерами для решения практических задач в различных сферах промышленности. Кроме того, исследование направлено на разработку рекомендаций по системной интеграции технологий DL в образовательный процесс подготовки современных специалистов инженерно-технического профиля, соответствующих требованиям эпохи Industry 4.0.

Ход исследования

ANN являются мощным инновационным цифровым инструментом для решения широкого спектра сложных аналитических задач. Принципиальное отличие ANN от традиционных методов анализа заключается в их уникальной способности: 1) выявлять и моделировать нелинейные зависимости¹⁰ в данных; 2) обрабатывать многомерные данные сложной структуры; 3) адаптироваться к изменяющимся условиям входных параметров. В инженерной практике часто встречаются промышленные данные [2], обладающие многомерными, нелинейными и сложными зависимостями, что делает традиционные методы анализа недостаточно эффективными. ANN реализуют нелинейные технологии цифрового моделирования, что позволяет эффективно справляться с задачами, которые сложно или невозможно решить с помощью классических методов и традиционных информационно-коммуникационных технологий. В результате ANN¹¹ становятся ценным дополнением к традиционным методам статистического моделирования во множестве научных дисциплин, включая инженерные области [6].

В своей книге [13] разработчик фреймворков DL (Keras, TensorFlow) Ф. Шолле рассматривает DL как специфическую область ML, представляющую собой новый подход к поиску представления данных. Этот подход акцентирует внимание на изучении последовательных слоев (или уровней), которые обеспечивают все более значимые представления. Количество слоев, на которые разбивается модель данных, обозначается как глубина модели. В DL многослойные структуры реализуются с помощью глубоких нейронных сетей (Deep Neural Networks, DNN), которые представляют собой архитектуру, состоящую из нескольких слоев, включая входной, скрытые и выходной. Эта структура позволяет эффективно извлекать сложные паттерны из больших объемов данных. Каждое скрытое представление в DNN обучается с использованием методов обратного распространения ошибки, что способствует улучшению точности модели. ANN могут моделировать сложные нелинейные зависимости между входными и выходными данными, что делает их подходящими для решения задач, где линейные модели оказываются недостаточно точными.

Технологии DL находят широкое применение в инженерной практике благодаря своей способности эффективно моделировать процессы в таких современных и популярных областях AI, как генеративный AI, компьютерное зрение и обработка естественного языка. В последнее время генеративный AI активно внедряется в промышленное производство, в частности, в процессы технического обслуживания и ремонта оборудования. Системы компьютерного зрения позволяют выявлять дефекты и мониторить состояние агрегатов, а языковые модели способны разрабатывать инструкции по обслуживанию техники, основываясь на ее техническом паспорте¹². Младший научный сотрудник лаборатории композитного AI и исследовательского центра «Сильный ИИ в промышленности» Ю. Борисова исследует эффективность при-

¹⁰ В контексте ANN под нелинейными взаимосвязями подразумеваются зависимости, которые: 1) не могут быть адекватно описаны линейными моделями; 2) требуют учета множества взаимодействующих факторов; 3) демонстрируют изменчивость во временном или пространственном континууме [4, 5].

¹¹ ANN – это общее определение, охватывающее любые нейронные сети, которые имитируют работу человеческого мозга для решения задач, включая классификацию, регрессию и др. ANN могут иметь разнообразную архитектуру, в том числе однослойную или многослойную [4, 13].

¹² Кашапов А. Как нейросети трансформируют техобслуживание и ремонт на производстве. URL: https://axenix.cnews.ru/articles/2024-11-22_utmnyj_remont_kak_genii_menyet_protsessy?erid=LjN8K22o1 (дата обращения: 08.02.2025).



Рис. 1. Основные этапы решения задачи машинного обучения
Fig. 1. The main stages of solving a machine learning problem

менения ANN для прогнозирования морского льда в Арктике¹³. Опыт применения технологии DL также подробно рассматривается в ряде научных исследований. В частности, ANN находят широкое применение в электроэнергетике, включая детекцию и классификацию неисправностей на линиях электропередачи [14, 15]. Кроме того, разрабатываются интеллектуальные реле на основе ANN, что способствует повышению надежности этих линий [16]. Технологии DL также демонстрируют свою эффективность в повышении производительности в промышленном производстве [17, 18] и используются для оптимизации разработки технологических процессов [19].

Аналитический обзор научных трудов и специальной технической литературы [4, 5, 13, 14–33] позволили выделить следующие архитектуры ANN, которые используются для решения прикладных инженерных задач в цифровой промышленности (табл. 1).

Каждая из этих архитектур ANN может быть адаптирована к конкретным задачам и требованиям в инженерной области, что делает их эффективными инструментами для решения разнообразных задач в профессиональной деятельности специалистов инженерно-технического профиля. Например, прогнозирование – одна из ключевых задач ML [5], а прогнозирование прочности бетона на сжатие играет значительную роль в строительстве и материаловедении [34–36]. Бетон – важнейший материал в гражданском строительстве. Следует подчеркнуть, что задача прогнозирования прочности бетона на сжатие относится к категории задач регрессии. Эта задача предлагается на практических занятиях будущим инженерам технического профиля в Омском техническом государственном университете (ОмГТУ) в разделе «Основы глубокого обучения» дисциплины «Машинное обучение» [2]. Рассмотрим особенности решения этой задачи.

На рис. 1 изображены ключевые этапы работы с данными в области ML, включая DL, для задачи регрессии – прогнозирования прочности бетона на сжатие. Данная схема иллюстрирует концепцию, лежащую в основе создания модели ML, в которой данные сначала проходят через этапы предобработки, исследовательского анализа данных (Exploratory Data Analysis, EDA) и визуализации, что способствует повышению качества анализа. После этого к обработанным данным применяются соответствующие алгоритмы ML и DL.

Ниже представлены необходимые цифровые инструменты, включая фреймворки для EDA, ML и DL:

- высококонкурентный язык программирования: Python;
- предобработка данных, EDA: Numpy, Pandas, StatsPy;
- визуализация: Matplotlib, Seaborn;
- машинное обучение: Scikit-learn, SciPy;
- глубокое обучение: Keras, TensorFlow, PyTorch.

В качестве цифровой среды для разработки и работы с моделями ML и DL был выбран облачный специализированный сервис Google Collaboratory. В этой среде был реализован анализ и сравнительная оценка производительности различных моделей регрессии ML, включая DL, для прогнозирования прочности бетона на сжатие. В работе использован датасет¹⁴, состоящий из 1030 образцов прочности на сжатие. Оценка эффективности моделей проводилась с применением линейной корреляции, представленной в табл. 2, с использованием гребневой линейной регрессии (Ridge Regression). Также применялись методы нелинейной корреляции, включающие регрессию решающих деревьев (Decision Tree Regressor), градиентный бустинг (Gradient Boosting Regressor), категориальный бустинг (CatBoost) и ANN, реализованные на фреймворках Keras и TensorFlow, PyTorch, о чем свидетельствует табл. 3.

¹³ Борисова Ю. Нейросети со льдом: как мы разрабатываем методы ИИ для повышения эффективности прогнозирования морского льда в Арктике. URL: <https://habr.com/ru/companies/spbfmo/articles/845940/> (дата обращения: 08.02.2025).

¹⁴ Датасет (от англ. dataset – набор данных) – это организованная коллекция данных, оформленная в формате, удобном для компьютерной обработки. Такие структурированные наборы служат основой для аналитических исследований, DL, ML и принятия решений, основанных на данных [4].

Таблица 1. Искусственные нейронные сети в современных инженерных задачах
Table 1. Artificial neural networks in modern engineering problems

Архитектура ANN ANN architecture	Инженерная задача Engineering problem
Полносвязные нейронные сети Fully Connected Neural Networks (FCNN)	Применяются для решения таких задач ML, как регрессия и классификация. Находят широкое применение в прогнозировании, например, для предсказания нагрузок на оборудование или оценки качества промышленной продукции. В работе [23] рассматривается использование FCNN для прогнозирования затрат на обслуживание мостов. Авторы работы [24] представили метод классификации потерь холостого хода трансформаторов, основанный на многослойной персептронной нейронной сети ¹⁵ (Multilayer Perceptron Neural Network, MPNN), который повышает эффективность оценки затрат для производителей и промышленных компаний на трансформаторы/Used to solve ML problems such as regression and classification, widely used in forecasting, for example, to predict equipment loads or assess the quality of industrial products. The paper [23] examines the use of FCNNs for predicting bridge maintenance costs. The authors of [24] presented a method for classifying transformer no-load losses based on a multilayer perceptron neural network ¹⁴ (MPNN), which improves the efficiency of cost estimation for transformer manufacturers and industrial companies.
Сверточные нейронные сети Convolutional Neural Networks (CNN)	Используются в задачах обработки изображений, включая распознавание объектов и анализ данных с сенсоров [25]. Находят широкое применение в промышленном Интернете вещей (Internet of Things, IoT) благодаря своей способности обрабатывать и анализировать визуальные данные. Активно применяются в инспекции качества, например, для выявления дефектов на производственных линиях. В работе [26] предлагается внедрение CNN для сегментации сигналов электроприводной арматуры/Used in image processing tasks, including object recognition and sensor data analysis [25]. Widely used in the Industrial Internet of Things (IoT) due to their ability to process and analyze visual data. CNNs are actively used in quality inspection, for example, to detect defects on production lines. The paper [26] proposes the implementation of CNNs for segmentation of signals from motorized valves.
Рекуррентные нейронные сети Recurrent Neural Networks (RNN)	Применяются для работы с последовательными данными, такими как временные ряды. Используются для прогнозирования временных рядов в инженерных системах, например, для мониторинга состояния оборудования [27]. В работе [28] RNN применяются с целью прогнозирования временной эволюции химических реакций, что имеет важное значение в химической инженерии/Used to work with sequential data, such as time series and to predict time series in engineering systems, for example, for monitoring the condition of equipment [27]. In [28], RNNs are used to predict the time evolution of chemical reactions, which is of significant importance in chemical engineering.
Долгосрочная краткосрочная память Long Short-Term Memory (LSTM)	Разновидность RNN, которая лучше справляется с зависимостями в длинных последовательностях. Применяется в задачах предсказания отказов оборудования и анализа временных рядов. В [29] рассматривается применение LSTM-сетей в полимерных науках. Эти модели эффективно используют последовательные данные для прогнозирования свойств полимеров, мониторинга процессов полимеризации и оценки деградации и механических характеристик/A type of RNN that better handles dependencies in long sequences. Used in problems such as equipment failure prediction and time series analysis. A review [29] examines the application of LSTM networks in polymer science. These models effectively use sequential data to predict polymer properties, monitor polymerization processes, and assess degradation and mechanical properties.
Авто-кодировщики, или автоэнкодеры Autoencoders	Применяются для снижения размерности данных и выявления скрытых паттернов, а также для сжатия данных и фильтрации сигналов от шума. Одним из ключевых направлений их использования является обнаружение аномалий. Например, в исследовании [30] рассматривается надежность функционирования судового дизельного двигателя, где автоэнкодеры используются для выявления аномалий. Исследования показали, что они являются важным инструментом для повышения надежности функционирования судовых дизельных двигателей/Used to reduce the dimensionality of data and identify hidden patterns, as well as for data compression and filtering signals from noise. One of their key applications is anomaly detection. For example, the work [30] examines the operational reliability of a marine diesel engine, where autoencoders are used to detect anomalies. The research shown that they are an important tool for improving the operational reliability of marine diesel engines.

¹⁵ MPNN – это подмножество FCNN; специфический тип FCNN, состоящий из нескольких слоев, включая входной, скрытые и выходной. В MPNN применяются нелинейные активационные функции, такие как ReLU или сигмоидные функции, что позволяет MPNN эффективно моделировать сложные зависимости в данных [13, 20].

Архитектура ANN ANN architecture	Инженерная задача Engineering problem
Трансформеры ¹⁶ Transformers (Transformers, or Transformer Neural Network, TNN)	Преимущества Transformer-архитектуры включают способность эффективно обрабатывать длинные последовательности данных благодаря механизму внимания, возможность параллельной обработки, а также гибкость применения в различных задачах. Это делает их особенно полезными в современных инженерных решениях. Могут быть использованы для анализа больших объемов данных и построения сложных моделей в инженерии. В работе [31] представлена новая архитектура DNN на основе трансформеров для прогнозирования скорости ветра и генерации ветровой энергии (мощности)/The advantages of the Transformer architecture include the ability to efficiently process long data sequences thanks to an attention mechanism, the ability to process parallel data, and the flexibility to apply them to a variety of tasks. This makes them particularly useful in modern engineering solutions. They can be used to analyze large volumes of data and build complex models in engineering. A new Transformer-based DNN architecture for predicting wind speed and wind energy (power) generation is presented in [31]
Графовые нейронные сети Graph Neural Networks (GNN)	Применяются для работы с неструктуризованными данными, представленными в виде графов. Используются в задачах анализа сетей, таких как оптимизация распределительных сетей или моделирование взаимодействий между компонентами систем. В работе [32] рассматривается использование GNN для прогнозирования полей давления, температуры и скорости, возникающих при внезапном взрыве. Основная цель исследования – добиться точного моделирования взрывных событий в больших и сложных геометрических областях, что невозможно с помощью существующих методов вычислительной гидродинамики/Used to work with unstructured data presented in the form of graphs, i. e., graph data. They are used in network analysis problems, such as optimization of distribution networks or modeling interactions between system components. The work [32] considers the use of GNN for predicting the pressure, temperature, and velocity fields that arise during a sudden explosion. The main goal of the study is to achieve accurate modeling of explosive events in large and complex geometric domains, which is impossible using existing computational fluid dynamics methods
Генеративно-состязательные сети Generative Adversarial Networks (GANs)	Используются для генерации новых данных на основе существующих. Применяются в дизайне и моделировании, например, для создания новых материалов или компонентов. В работе [33] осуществляется анализ возможностей GAN в строительной отрасли; обзор направлен на расширение знаний о данном инновационном алгоритме DL в контексте строительного сектора; результаты исследования демонстрируют, что GAN в основном применяются в четырех ключевых областях строительства/Used to generate new data based on existing data. Applied in design and modeling, for example, to create new materials or components. The work [33] analyzes the capabilities of GANs in the construction industry; the review aims to expand knowledge about this innovative DL algorithm in the context of the construction sector; the results of the study demonstrate that GANs are mainly applied in four key areas of construction

Прочность бетона на сжатие представляет собой нелинейную зависимость, которая определяется возрастом и составом материала. Основные составляющие бетона включают цемент, доменный шлак, летучую золу, воду, суперпластификатор, а также крупные и мелкие заполнители [34]. В ходе тестирования бетон проверялся на прочность в возрасте от 1 до 28 дней, со средним значением около 23 дней. Значения прочности на сжатие, представляющие собой зависимую переменную, варьировались от 2,33 до 90,99 МПа со средним значением 40,35 МПа. Все входные переменные рассматривались как независимые, а прогноз

значений зависимой переменной основывался на этих независимых данных.

Датасет состоит из девяти ключевых признаков (рис. 2):

1. Cement (component 1): количество цемента, используемого в смеси ($\text{кг}/\text{м}^3$);
2. Blast Furnace Slag (component 2): измельченный гранулированный доменный шлак ($\text{кг}/\text{м}^3$);
3. Fly Ash (component 3): летучая зола ($\text{кг}/\text{м}^3$);
4. Water (component 4): количество воды, используемой в смеси ($\text{кг}/\text{м}^3$);
5. Superplasticizer (component 5): количество суперпластификатора, используемого в смеси ($\text{кг}/\text{м}^3$);

¹⁶ Transformer – это DNN, использующая механизм самовнимания для понимания контекстных отношений в последовательных данных. В отличие от обычных ANN или обновленных версий RNN, таких как LSTM, модели TNN отлично справляются с обработкой длинных зависимостей между элементами входной последовательности и обеспечивают параллельную обработку. В результате модели TNN привлекли значительный интерес среди исследователей в области AI.

	Cement (component 1)(kg in a m ³ mixture)	Blast Furnace Slag (component 2) (kg in a m ³ mixture)	Fly Ash (component 3)(kg in a m ³ mixture)	Water (component 4)(kg in a m ³ mixture)	Superplasticizer (component 5)(kg in a m ³ mixture)	Coarse Aggregate (component 6) (kg in a m ³ mixture)	Fine Aggregate (component 7) (kg in a m ³ mixture)	Age (day)	strength
0	540.0	0.0	0.0	162.0	2.5	1040.0	876.0	28	79.98
1	540.0	0.0	0.0	162.0	2.5	1055.0	876.0	28	61.89
2	332.5	142.5	0.0	228.0	0.0	932.0	594.0	270	40.27
3	332.5	142.5	0.0	228.0	0.0	932.0	594.0	365	41.05
4	198.6	132.4	0.0	192.0	0.0	978.4	825.5	380	44.30

Рис. 2. Фрагмент набора данных о прочности бетона на сжатие

Fig. 2. Fragment of the concrete compressive strength dataset

6. Coarse Aggregate (component 6): крупный заполнитель (кг/м³);
7. Fine Aggregate (component 7): мелкий заполнитель (кг/м³);
8. Age: возраст бетона в днях (1~365);
9. Strength: целевая переменная, которая означает прочность бетона на сжатие (МПа, мегапаскаль).

На рис. 3 представлена диаграмма деятельности, описывающая алгоритмы прогнозирования прочности бетона на сжатие с использованием моделей регрессии ML и DL.

Эффективность предсказательной модели регрессии оценивалась с помощью k-кратной перекрестной проверки и двух статистических метрик: коэффициента детерминации (R^2) и среднеквадратичной ошибки (Mean Squared Error – MSE). Эти метрики обеспечивают комплексную оценку точности и предсказательной способности модели регрессии. В табл. 2 представлены модели регрессии, описывающие прочность бетона на сжатие, с использованием соответствующих алгоритмов-регрессоров классического ML.

Точность прогнозирования, а также оценка эффективности моделей регрессии DL, реализованные на фреймворках Keras и PyTorch, оценивается путем анализа статистических мер, включая R^2 и MSE (табл. 3). Результаты показали, что модель регрессии DNN достигла высокой точности в прогнозировании прочности на сжатие бетона, дав значение R^2 равное 0,97. При итеративном подходе к выбору модели ANN, оптимизатора и числа эпох мы наблюдаем значительное улучшение метрик оценки качества ее обучения. Особенно наглядно это проявляется при увеличении количества эпох, что позволяет сети более глубоко прорабатывать данные и, как следствие, значительно повышать свои результаты. Этот процесс показывает, как точная настройка модели и её параметров способствует опти-

мизации производительности, раскрывая потенциал ANN.



Рис. 3. Диаграмма деятельности

Fig. 3. Activity diagram

Таблица 2. Эффективность различных регрессоров классического машинного обучения по предсказанию прочности бетона на сжатие

Table 2. Performance of different classical Machine Learning regressors in predicting concrete strength

Алгоритм-регрессор ML ML regressor algorithm	R^2	MSE
Decision Tree Regressor	0,79	58,5213
Ridge Regression	0,81	51,1325
Gradient Boosting Regressor	0,89	29,6867
CatBoost Regressor	0,92	20,9679

Таблица 3. Эффективность регрессоров глубокого обучения по предсказанию прочности бетона
Table 3. Performance of Deep Learning Regressors in predicting concrete strength

Регрессор DL и его характеристики DL Regressor and its characteristics			R2	MSE
Модель ANN ANN model	Оптимиза- тор Optimizer	Коли- чество эпох Number of eras		
Keras – Tensorflow	Adam ¹⁷	100	0,92	26,4843
Keras – Tensorflow	Adam	1000	0,93	20,2351
PyTorch	SGD ¹⁸	10000	0,95	15,1925
PyTorch	SGD	20000	0,97	10,2723

Эффективность нейросетевого подхода к прогнозированию оптимального устойчивого компонентного состава бетонных смесей была подтверждена рядом научных исследований [34–36]. Рассмотрим несколько примеров. Коллектив авторов [34] разработал две модели прогнозирования, применяя ANN и множественную линейную регрессию с использованием программного обеспечения MATLAB и IBM SPSS. Результаты показали, что модель на основе ANN обеспечила более точное прогнозирование прочности на сжатие.

В исследовании [35] ученые применили несколько методов ML и выяснили, что ANN выделяется высоким значением коэффициента детерминации R^2 , что подтверждает ее способность объяснять изменчивость данных. Кроме того, ANN продемонстрировала наименьшее значение MSE, что свидетельствует о высокой точности ее прогнозов. Хотя ANN показала лучшие результаты, модель градиентного бустинга также продемонстрировала сопоставимую производительность, что подтверждает её целесообразность. Выбор между этими методами зависит от баланса между объяснимостью и точностью: в то время как градиентный бустинг предоставляет более углубленное понимание взаимосвязей между переменными, ANN выделяется высокой точностью своих прогнозов. Это также наблюдается в практической работе студентов из раздела «Основы глубокого обучения»

disciplines «Машинное обучение» в ОмГТУ (табл. 2, 3).

Таким образом, модель регрессии на основе ANN является высокоточным, экономически эффективным и практическим цифровым инструментом для прогнозирования прочности бетона на сжатие. Это подтверждает многообещающий потенциал использования технологий DL в данной области, что дает инженерам-бетонщикам возможность создавать надежные модели для предсказания прочности бетона на сжатие, используя ANN.

Заключение

Технологии DL становятся неотъемлемым компонентом современной инженерной практики, находя широкое применение в ключевых отраслях промышленности, таких как гражданское строительство, машиностроение, электроника и энергетика. Проведенное исследование показало, что ANN представляют особую ценность при анализе промышленных данных, обладающих сложными и нелинейными взаимосвязями, для решения актуальных практических задач. Их основное преимущество заключается в способности обрабатывать большие объемы информации, выявляя скрытые закономерности и создавая точные прогностические модели, что особенно важно для цифровой трансформации современной промышленности.

В работе определены наиболее перспективные архитектуры ANN, применяемые для решения прикладных инженерных задач. Это подчеркивает необходимость подготовки студентов инженерно-технического профиля к работе с современными технологиями AI для анализа данных и разработки инновационных цифровых решений. Особое внимание следует уделить интеграции технологий DL в современный образовательный процесс технического университета. Рекомендуется трехуровневая интеграция DL в инженерное образование: на базовом уровне должны быть обязательные курсы по основам ANN и DL; на проектном уровне – проведение сквозных практикумов с реальными промышленными кейсами и разработка прототипов для реальных производственных задач; на исследовательском уров-

¹⁷ Adam (Adaptive Moment Estimation) – алгоритм оптимизации, который используется для обучения ANN.

¹⁸ Stochastic Gradient Descent (SGD) – алгоритм оптимизации, широко используемый в ML и статистике для минимизации функций потерь; особенно эффективен в контексте обучения ANN.

не – внедрение специализированных модулей по направлениям НТИ, применение ANN в рамках курсовых работ (для решения модельных инженерных задач) и выпускных квалификационных работ (создание комплексных инновационных решений для национальной цифровой промышленности).

Таким образом, для эффективной подготовки будущих инженеров к применению технологий DL в их профессиональной деятельности следует внедрить сквозное обучение этим технологиям на всех уровнях националь-

ного высшего инженерного образования. Это позволит студентам развивать навыки анализа и интерпретации промышленных данных, а также формировать критическое мышление относительно применения алгоритмов DL и выбора эффективной модели для прогнозирования. Акцент на обучение технологиям DL в образовательных программах инженерного профиля будет способствовать не только профессиональному росту выпускников, но и их активному участию в цифровой трансформации промышленности в эпоху Industry 4.0.

СПИСОК ЛИТЕРАТУРЫ

1. «О Стратегии научно-технологического развития Российской Федерации». Указ Президента РФ от 28 февраля 2024 г. № 145. URL: <https://www.garant.ru/products/ipo/prime/doc/408518353/> (дата обращения: 08.02.2025).
2. Моисеева Н.А. Значимость сквозных цифровых технологий в подготовке будущих инженеров (на примере искусственного интеллекта) // Инженерное образование. – 2024. – № 35. – С. 74–86. DOI: 10.54835/18102883_2024_35_7 EDN: OUGOJC
3. Дудкина И. Перспективы промышленных стартапов // Главный инженер. Управление промышленным производством. – 2023. – № 4. URL: <https://panor.ru/articles/perspektivy-promyshlennyykh-startapov/92078.html#> (дата обращения: 08.02.2025).
4. Advanced Deep Learning for engineers and scientists: a practical approach / Ed. by Bh.P. Kolla et al. – Cham: Springer, 2021. – 285 p.
5. Artificial Intelligence in mechanical and industrial engineering / Ed. by K. Kaushik, Z. Divya, J.D. Paulo. – Boca Raton: CRC Press, 2024. – 156 p.
6. Waziri B.S., Bala K., Bustani S.A. Artificial Neural Networks in construction engineering and management // International journal of architecture, engineering and construction. – 2017. – Vol. 6. – № 1. – P. 50–60. DOI: 10.7492/IJAEC.2017.006
7. Дорожная карта развития «сквозной» цифровой технологии «Нейротехнологии и искусственный интеллект». URL: https://rfrit.ru/media/documents/%D0%94%D0%9A_%D0%A1%D0%A6%D0%A2_%D0%98%D0%98.pdf (дата обращения: 08.02.2025).
8. «О Стратегии развития информационного общества в Российской Федерации на 2017–2030 годы». Указ Президента РФ от 9 мая 2017 г. № 203 URL: <https://base.garant.ru/71670570/> (дата обращения: 08.02.2025).
9. «О внесении изменений в Указ Президента Российской Федерации от 10 октября 2019 г. № 490 «О развитии искусственного интеллекта в Российской Федерации» и в Национальную стратегию, утвержденную этим Указом». Указ Президента РФ от 15.02.2024 № 124. URL: <http://publication.pravo.gov.ru/document/0001202402150063> (дата обращения: 08.02.2025)
10. Подготовка инженерных кадров. URL: <https://issek.hse.ru/news/896326010.html> (дата обращения: 08.02.2025).
11. Soni N., Sharma E.K., Singh N., Kapoor A. Artificial intelligence in business: from research and innovation to market deployment // Procedia Computer Science. – 2020. – Vol. 167. – P. 2200–2210. DOI: <https://doi.org/10.1016/j.procs.2020.03.272>
12. Искусственный интеллект: к новой парадигме инженерного образования? / Ю.П. Похолков, К.К. Зайцева, Е.В. Исаева, И.О. Муравлев // Инженерное образование. – 2023. – № 34. – С. 180–189. DOI: 10.54835/18102883_2023_34_16
13. Шолле Ф. Глубокое обучения на Python. – М.: Питер, 2022. – 400 с.
14. Симонов Н., Ивенев Н. Опыт и перспективы применения искусственных нейронных сетей в электроэнергетике // Электроэнергия. Передача и распределение. – 2019. – № S4 (15). – С. 42–48. EDN RRJHDU
15. Detection, classification and zone location of fault in transmission line using Artificial Neural Network / R. Resmi, V. Vanitha, E. Aravind, B.R. Chandrasekaran, K.R. Aswin, S. Harithaa // 2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT). – 2019. – P. 1–5. DOI: 10.1109/ICECCT.2019.8868990
16. Alilouch R., Hasnaoui F. Intelligent relay based on Artificial Neural Networks ANN for transmission line // 2022 IEEE 9th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT). – 2022. – P. 468–473. DOI: 10.1109/SETIT54465.2022.9875449

17. Лифанов А.В., Соколов Д.И. Искусственный интеллект на базе нейросетей для промышленных предприятий // Автоматизация в промышленности. – 2019. – № 12. – С. 16–19. EDN PTJLEI
18. Евсеева А.К. Использование нейросетей в промышленном производстве // Наука XXI века: актуальные направления развития. – 2024. – № 1–2. – С. 313–317. EDN ZFMLRE
19. Михалев О.Н., Яношкин А.С. Повышение производительности разработки технологических процессов с помощью технологий искусственного интеллекта // Актуальные проблемы в машиностроении. – 2022. – Т. 9. – № 1–2. – С. 7–14. EDN TYTTMR
20. Аггарвал Ч. Нейронные сети и глубокое обучение. – М.: Вильямс, 2020. – 752 с.
21. Tariq M.A. Introduction to Deep Learning for engineers: using Python and Google Cloud Platform (synthesis lectures on mechanical engineering). – San Rafael: Morgan & Claypool, 2020. – 109 p.
22. Deep Learning in engineering, energy and finance principals and applications / S.Sh. Vivek, M. Shubham, N. Anand, K.P. Amit. – Boca Raton: CRC Press, 2024. – 404 p. DOI: <https://doi.org/10.1201/9781003564874>
23. Comparative study of a fully-connected Artificial Neural Network and a convolutional Neural Network in predicting bridge maintenance costs / C. Wang, C. Yao, S. Zhao, S. Zhao, Y.A. Li // Applied Sciences. – 2022. – Vol. 12. – Iss. 7. – 3595. DOI: <https://doi.org/10.3390/app12073595>
24. Application research based on Artificial Neural Network (ANN) to predict no-load loss for transformer's design / A.K. Yadav, A. Azeem, A. Singh, H. Malik, O.P. Rahi // 2011 International Conference on Communication Systems and Network Technologies. – 2011. – P. 180–183. DOI: 10.1109/CSNT.2011.45
25. Manda B., Bhaskare P., Muthuganapathy R. A convolutional Neural Network approach to the classification of engineering models // IEEE Access. – 2021. – Vol. 9. – P. 22711–22723. DOI: 10.1109/ACCESS.2021.3055826
26. Коюев К.И., Трыков Е.Л., Трыкова И.В. Применение свёрточной нейронной сети для сегментации сигналов электроприводной арматуры // Известия высших учебных заведений. Ядерная энергетика. – 2021. – № 2. – С. 158–168. DOI: <https://doi.org/10.26583/npe.2021.2.14>
27. Time series data for equipment reliability analysis with Deep Learning / B. Chen, Y. Liu, C. Zhang, Z. Wang // IEEE Access. – 2020. – Vol. 8. – P. 105484–105493. DOI: 10.1109/ACCESS.2020.3000006
28. Murakami Yuya, Shono Atsushi. Reaction engineering with recurrent Neural Network: kinetic study of Dushman reaction // Chemical Engineering Journal Advances. – 2021. – Vol. 9. – 100219. DOI: <https://doi.org/10.1016/j.ceja.2021.100219>
29. Applications of Long Short-Term Memory (LSTM) Networks in polymeric sciences: a review / I. Malashin, V. Tynchenko, A. Gantimurov, V. Nelyub, A. Borodulin // Polymers. – 2024. – Vol. 16. – Iss. 18. – 2607. DOI: <https://doi.org/10.3390/polym16182607>
30. Predictive anomaly detection for marine diesel engine based on echo state network and autoencoder / C. Qu, Z. Zhou, Z. Liu, S. Jia // Energy Reports. – 2022. – Vol. 8. – № 4. – P. 998–1003. DOI: <https://doi.org/10.1016/j.egyr.2022.01.225>
31. Nath P., Middya A.I., Roy S. Empirical assessment of transformer-based neural network architecture in forecasting pollution trends. Preprint (Version 1). DOI: <https://doi.org/10.21203/rs.3.rs-1793953/v1>
32. Application of graph neural networks to predict explosion-induced transient flow / G. Covoni, F. Montomoli, V.L. Tagarielli et al. // Advanced Modeling and Simulation in Engineering Sciences. – 2024. – Vol. 11. – Article number 18. DOI: <https://doi.org/10.1186/s40323-024-00272-4>
33. Generative adversarial networks in construction applications / P. Chai, L. Hou, G. Zhang, Q. Tushar, Z. Yang // Automation in Construction. – 2024. – Vol. 159. – 105265. DOI: <https://doi.org/10.1016/j.autcon.2024.105265>
34. Prediction model for the compressive strength of green concrete using cement kiln dust and fly ash / E.S. Bakhoun, A. Amir, F. Osama, M. Adel // Scientific Reports. – 2023. – Vol. 13. – 1864. DOI: <https://doi.org/10.1038/s41598-023-28868-7>
35. Loureiro A., Stefani R. Comparing the performance of machine learning models for predicting the compressive strength of concrete // Discover Civil Engineering. – 2024. – Vol. 1. – article number 19. DOI: <https://doi.org/10.1007/s44290-024-00022-w>
36. Shubham K., Rout M., Sinha A.K. Efficient compressive strength prediction of concrete incorporating industrial wastes using deep neural network // Asian Journal of Civil Engineering. – 2023. – Vol. 24. – P. 3473–3490. DOI: <https://doi.org/10.1007/s42107-023-00726-x>

Поступила: 23.04.2025

Принята: 25.10.2025

UDC 378.147

DOI: 10.54835/18102883_2025_38_2

FEATURES OF THE APPLICATION OF DEEP LEARNING TECHNOLOGY BY FUTURE ENGINEERS IN SOLVING PRACTICAL PROBLEMS

Natalya A. Moiseeva,

Cand. Sc., Associate Professor,

nat_lion@mail.ru

Omsk State Technical University,
11, Mira avenue, Omsk, 625003, Russian Federation

In the article the key aspects and features of the application of deep learning technologies by future technical engineers to solve practical problems in various areas of the industrial sector for the national digital economy are discussed. With the rapid development of the Industry 4.0 concept and the growth of data volumes, including industrial data, deep learning is becoming an important tool in the arsenal of a modern engineer. It is conducted the analysis of deep learning algorithms. The paper introduces the examples of the integration of intelligent models into real production processes. Particular attention is paid to the successful application of artificial neural networks for predicting the compressive strength of concrete. In conclusion, the author emphasizes the need to develop students' skills in working with modern tools for industrial data analysis and development of digital models, which will allow them to effectively solve complex analytical problems and adapt to the rapidly changing requirements of the modern labor market. The article will be useful for both students and teachers interested in artificial intelligence technologies, especially in the field of deep learning, in the context of the educational process for training future engineering personnel.

Keywords: engineering education, engineer, artificial intelligence, machine learning, deep learning, artificial neural network

REFERENCES

1. "On the Strategy for Scientific and Technological Development of the Russian Federation". Decree of the President of the Russian Federation of February 28, 2024 No 145. (In Russ.) Available at: <https://www.garant.ru/products/ipo/prime/doc/408518353/> (accessed 08 February 2025).
2. Moiseeva N.A. Importance of end-to-end digital technologies in future engineers' training (based on example of artificial intelligence). *Engineering Education*, 2024, Iss. 35, pp. 74–86. (In Russ.) DOI: 10.54835/18102883_2024_35_7 EDN: OUGOJC
3. Dudkina I. Prospects for industrial startups. *Chief Engineer. Industrial Production Management*, 2023, no. 4. (In Russ.) Available at: <https://panor.ru/articles/perspektivy-promyshlennyykh-startapov/92078.html#> (accessed 08 February 2025).
4. *Advanced Deep Learning for engineers and scientists: a practical approach*. Ed. by Bh.P. Kolla. Cham, Springer, 2021. 285 p.
5. *Artificial Intelligence in mechanical and industrial engineering*. Ed. by K. Kaushik, Z. Divya, J.D. Paul. Boca Raton, CRC Press, 2024. 156 p.
6. Waziri B.S., Bala K., Bustani S.A. Artificial Neural Networks in construction engineering and management. *International journal of architecture, engineering and construction*, 2017, vol. 6, no. 1, pp. 50–60. DOI: 10.7492/IJAEC.2017.006
7. *Roadmap for the development of "end-to-end" digital technology "Neurotechnology and artificial intelligence"*. (In Russ.) Available at: https://rfrit.ru/media/documents/%D0%94%D0%9A_%D0%A1%D0%A6%D0%A2_%D0%98%D0%98.pdf (accessed: 08 February 2025).
8. "On the Strategy for the Development of the Information Society in the Russian Federation for 2017–2030". Decree of the President of the Russian Federation of May 9, 2017 No. 203 (In Russ.) Available at: <https://base.garant.ru/71670570/> (accessed: 08 February 2025).
9. "On Amendments to the Decree of the President of the Russian Federation of October 10, 2019 No. 490 "On the Development of Artificial Intelligence in the Russian Federation" and to the National Strategy approved by this Decree". Decree of the President of the Russian Federation of 15.02.2024 No. 124 (In Russ.) Available at: <http://publication.pravo.gov.ru/document/0001202402150063> (accessed: 08 February 2025)
10. *Training of engineering personnel*. (In Russ.) Available at: <https://issek.hse.ru/news/896326010.html> (accessed: 08 February 2025).
11. Soni N., Sharma E.K., Singh N., Kapoor A. Artificial intelligence in business: from research and innovation to market deployment. *Procedia Computer Science*, 2020, vol. 167, pp. 2200–2210. DOI: <https://doi.org/10.1016/j.procs.2020.03.272>
12. Artificial Intelligence: towards a new paradigm for engineering education? / Yu.P. Poholkov, K.K. Zaitseva, E.V. Isaeva, I.O. Muravlev. *Engineering Education*, 2023, Iss. 34, pp. 180–189. (In Russ.) DOI: 10.54835/18102883_2023_34_16.
13. Chollet F. *Deep Learning with Python*. Moscow, Piter Publ., 2022. 400 p. (In Russ.).

14. Simonov N., Ivenev N. Experience and prospects of application of artificial neural networks in electric power engineering. *Electricity. Transmission and distribution*, 2019, no. S4 (15), pp. 42–48. (In Russ.) EDN RRJHDU.
15. Resmi R., Vanitha V., Aravind E., Chandrasekaran B.R., Aswin K.R., Harithaa S. Detection, classification and zone location of fault in transmission line using Artificial Neural Network. *2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)*. 2019, pp. 1–5. DOI: 10.1109/ICECCT.2019.8868990
16. Alilouch R., Hasnaoui F. Intelligent relay based on Artificial Neural Networks ANN for transmission line. *2022 IEEE 9th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT)*, 2022, pp. 468–473. DOI: 10.1109/SETIT54465.2022.9875449
17. Lifanov A.V., Sokolov D.I. Artificial Intelligence based on Neural Networks for industrial enterprises. *Automation in industry*, 2019, no. 12, pp. 16–19. (In Russ.) EDN PTJLEI.
18. Evseeva A.K. The use of neural networks in industrial production. *Science of the 21st century: current directions of development*, 2024, no. 1–2, pp. 313–317. (In Russ.) EDN ZFMLRE
19. Mihalev O.N., Yanushkin A.S. Improving the productivity of technological process development with the help of artificial intelligence technologies. *Actual problems in machine building*, 2022, vol. 9, no. 1–2, pp. 7–14. (In Russ.) EDN TYTTMR
20. Aggarwal Ch. *Neural Network and Deep Learning*. Moscow, Williams Publ., 2020. 752 p. (In Russ.)
21. Tariq M.A. *Introduction to Deep Learning for engineers: using Python and Google Cloud Platform (Synthesis Lectures on Mechanical Engineering)*. San Rafael, Morgan & Claypool, 2020. 109 p.
22. Vivek S.Sh., Shubham M., Anand N., Amit K.P. *Deep Learning in engineering, energy and finance principals and applications*. Boca Raton, CRC Press, 2024. 404 p. DOI: <https://doi.org/10.1201/9781003564874>
23. Wang C., Yao C., Zhao S., Zhao S., Li Y. A Comparative study of a fully-connected Artificial Neural Network and a convolutional Neural Network in predicting bridge maintenance costs. *Applied Sciences*, 2022, vol. 12, Iss. 7, 3595. DOI: <https://doi.org/10.3390/app12073595>
24. Yadav A. K., Azeem A., Singh A., Malik H. and Rahi O. P. Application research based on Artificial Neural Network (ANN) to predict no-load loss for transformer's design. *2011 International Conference on Communication Systems and Network Technologies*, 2011, pp. 180–183. DOI: 10.1109/CSNT.2011.45
25. Manda B., Bhaskare P., Muthuganapathy R. A convolutional Neural Network approach to the classification of engineering models. *IEEE Access*, 2021, vol. 9, pp. 22711–22723. DOI: 10.1109/ACCESS.2021.3055826
26. Kotsoev K.I., Trykov E.L., Trykova I.V. The use of convolutional Neural Network for segmenting signals of electrically-actuated valves. *Izvestiya vuzov. Yadernaya Energetika*, 2021, no. 2, pp. 158–167. (In Russ.) DOI: <https://doi.org/10.26583/npe.2021.2.14>
27. Chen B., Liu Y., Zhang C., Wang Z. Time series data for equipment reliability analysis with Deep Learning. *IEEE Access*, 2020, vol. 8, pp. 105484–105493. DOI: 10.1109/ACCESS.2020.3000006
28. Murakami Yuya, Shono Atsushi. Reaction engineering with recurrent Neural Network: kinetic study of Dushman reaction. *Chemical Engineering Journal Advances*, 2021, vol. 9, 100219. DOI: <https://doi.org/10.1016/j.ceja.2021.100219>
29. Malashin I., Tynchenko V., Gantimurov A., Nelyub V., Borodulin A. Applications of Long Short-Term Memory (LSTM) Networks in polymeric sciences: a review. *Polymers*, 2024, vol. 16, Iss. 18, 2607. DOI: <https://doi.org/10.3390/polym16182607>
30. Qu C., Zhou Z., Liu Z., Jia S. Predictive anomaly detection for marine diesel engine based on echo state network and autoencoder. *Energy Reports*, 2022, vol. 8, no. 4, pp. 998–1003. DOI: <https://doi.org/10.1016/j.egyr.2022.01.225>
31. Nath P., Middya A. I., Roy S. *Empirical assessment of transformer-based neural network architecture in forecasting pollution trends*. Preprint (Version 1). DOI: <https://doi.org/10.21203/rs.3.rs-1793953/v1>
32. Covoni G., Montomoli F., Tagarielli V.L. Application of graph neural networks to predict explosion-induced transient flow. *Advanced Modeling and Simulation in Engineering Sciences*, 2024, vol. 11, Article number: 18. DOI: <https://doi.org/10.1186/s40323-024-00272-4>
33. Chai P., Hou L., Zhang G., Tushar Q., Yang Z. Generative adversarial networks in construction applications. *Automation in Construction*, 2024, vol. 159, 105265. DOI: <https://doi.org/10.1016/j.autcon.2024.105265>
34. Bakhoum E.S., Amir A., Osama F., Adel M. Prediction model for the compressive strength of green concrete using cement kiln dust and fly ash. *Scientific Reports*, 2023, vol. 13, 1864. DOI: <https://doi.org/10.1038/s41598-023-28868-7>
35. Loureiro A., Stefani R. Comparing the performance of machine learning models for predicting the compressive strength of concrete. *Discover Civil Engineering*, 2024, vol. 1, article number 19. DOI: <https://doi.org/10.1007/s44290-024-00022-w>
36. Shubham K., Rout M., Sinha A.K. Efficient compressive strength prediction of concrete incorporating industrial wastes using deep neural network. *Asian Journal of Civil Engineering*, 2023, vol. 24, pp. 3473–3490. DOI: <https://doi.org/10.1007/s42107-023-00726-x>

Received: 23.04.2025

Accepted: 25.10.2025