



УДК 69.07

DOI: 10.22227/2949-1622.2026.3.78-99

НАУЧНАЯ СТАТЬЯ/RESEARCH ARTICLE

Возможности использования искусственного интеллекта для расчета железобетонных конструкций

Т.А. Мацевич*, С.Ю. Савин, Ю.А. Шапошникова, И.К. Манаенков, В.И. Черник

Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ),
Москва, Российская Федерация

* matseevichta@mgsu.ru

Ключевые слова: железобетон, конструкция, расчет, искусственный интеллект, машинное обучение

История статьи

Поступила в редакцию: 25.04.2026

Доработана: 08.05.2026

Принята к публикации: 10.05.2026

Для цитирования

Мацевич Т.А., Савин С.Ю., Шапошникова Ю.А., Манаенков И.К., Черник В.И. Возможности использования искусственного интеллекта для расчета железобетонных конструкций // Железобетонные конструкции. 2026. Т. 15. № 3. С. 78–99.

Аннотация. В данной обзорно-аналитической статье выполнена систематизация и критический анализ современного состояния исследований по применению машинного обучения для расчета железобетонных конструкций. В работе рассмотрены основные разновидности используемых моделей машинного обучения, проанализированы количественные метрики для оценки качества их предсказаний, а также обсуждены проблемы, связанные с интерпретируемостью результатов, оценкой ошибок и выявлением нелинейных зависимостей. Отдельное внимание уделено существующим пробелам в научном знании в области расчета железобетонных конструкций с использованием моделей машинного обучения, нормативным коллизиям и ограничениям, препятствующим практическому внедрению технологий ИИ в проектирование. На основе проведенного анализа сформулированы перспективные направления дальнейших исследований.

Татьяна Анатольевна Мацевич, доктор физико-математических наук, доцент, профессор кафедры железобетонных и каменных конструкций, Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ), 129337, г. Москва, Ярославское шоссе, д. 26; eLIBRARY SPIN-код: 1299-6980, Scopus: 51461741900, ResearcherID: AAB-2742-2020, ORCID: 0000-0001-6292-0759, E-mail: MatseevichTA@mgsu.ru

Сергей Юрьевич Савин, кандидат технических наук, доцент, доцент кафедры железобетонных и каменных конструкций, Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ), 129337, г. Москва, Ярославское шоссе, д. 26; eLIBRARY SPIN-код: 1301-4838, Scopus: 57052453700, ResearcherID: M-8375-2016, ORCID: 0000-0002-6697-3388, E-mail: suwin@yandex.ru

Шапошникова Юлия Александровна, кандидат технических наук, доцент, доцент кафедры железобетонных и каменных конструкций, Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ), 129337, г. Москва, Ярославское шоссе, д. 26; eLIBRARY SPIN-код: 2131-2252, Scopus: 57190858958, ResearcherID: P-8986-2018, ORCID: 0000-0001-7740-9400, E-mail: yuliatalyzova@yandex.ru

Манаенков Иван Константинович, кандидат технических наук, доцент, доцент кафедры железобетонных и каменных конструкций, Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ), 129337, г. Москва, Ярославское шоссе, д. 26; eLIBRARY SPIN-код: 5415-7373, Scopus: 57209888951, ResearcherID: AAE-1570-2022, ORCID: 0000-0002-5260-8793, E-mail: manaenkov.i.k@gmail.com

Владимир Игоревич Черник, кандидат технических наук, доцент кафедры железобетонных и каменных конструкций, Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ), 129337, г. Москва, Ярославское шоссе, д. 26; PИНЦ ID: 1091685, Scopus: 57218420224, ResearcherID: AAD-8260-2022, ORCID: 0000-0001-6240-9993, E-mail: chernik_vi@mail.ru

© Мацевич Т.А., Савин С.Ю., Шапошникова Ю.А., Манаенков И.К., Черник В.И., 2026



This work is licensed under a Creative Commons Attribution 4.0 International License
<https://creativecommons.org/licenses/by/4.0/>

Potential of Artificial Intelligence in the Analysis and Design of Reinforced Concrete Structures

T.A. Matseevich*, S.Yu. Savin, Yu.A. Shaposhnikova, I.K. Manaenkov, V.I. Chernik

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

* matseevichta@mgsu.ru

Keywords: reinforced concrete, structural design, structural analysis, artificial intelligence, machine learning

Article history

Received: 25.04.2026

Revised: 08.05.2026

Accepted: 10.05.2026

For citation

Matseevich T.A., Savin S.Yu., Shaposhnikova Yu.A., Manaenkov I.K., Chernik V.I. Potential of Artificial Intelligence in the Analysis and Design of Reinforced Concrete Structures. *Reinforced Concrete Structures*. 2026; 3(15):78-99.

Abstract. In this review, the current state of research on the use of machine learning for the design of reinforced concrete structures has been systematized and critically analyzed. The paper examines the main types of machine learning models used, analyzes quantitative metrics for assessing the quality of their predictions, and discusses issues related to the interpretability of results, error estimation, and the identification of nonlinear relationships. Special attention is given to existing gaps in scientific knowledge, regulatory conflicts, and limitations that hinder the practical implementation of AI technologies in design. Based on the analysis, promising directions for future research have been identified.

ВВЕДЕНИЕ

Традиционные методы расчета железобетонных конструкций, основанные на аналитических моделях сопротивления и конечно-элементном моделировании, являются основой современного проектирования. Однако они часто требуют значительных вычислительных затрат, опираются на упрощающие допущения и не всегда в полной мере учитывают сложные нелинейные взаимодействия между множеством факторов, определяющих работу материала и конструкции. В последние годы стремительное развитие методов искусственного интеллекта (ИИ), и, в частности, машинного обучения (МО), открыло новые перспективы для решения этих проблем. Способность алгоритмов МО выявлять скрытые закономерности в данных, аппроксимировать сложные функции и обобщать информацию без необходимости описания в явном виде физических закономерностей потенциально делает их мощным инструментом для расчета строительных конструкций [1].

Tatyana A. Matseevich, Doctor of Physical and Mathematical Sciences, Associate Professor, Professor of the Department of Reinforced Concrete and Masonry Structures, Moscow State University of Civil Engineering (National Research University) (MGSU), 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; eLIBRARY SPIN-code: 1299-6980, Scopus: 51461741900, ResearcherID: AAB-2742-2020, ORCID: 0000-0001-6292-0759, E-mail: MatseevichTA@mgsu.ru

Sergei Yu. Savin, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Reinforced Concrete and Masonry Structures, Moscow State University of Civil Engineering (National Research University) (MGSU), 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; eLIBRARY SPIN-code: 1301-4838, Scopus: 57052453700, ResearcherID: M-8375-2016, ORCID: 0000-0002-6697-3388, E-mail: suwin@yandex.ru

Yulia A. Shaposhnikova, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Reinforced Concrete and Masonry Structures, Moscow State University of Civil Engineering (National Research University) (MGSU), 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; eLIBRARY SPIN-code: 2131-2252, Scopus: 57190858958, ResearcherID: P-8986-2018, ORCID: 0000-0001-7740-9400, E-mail: yuliatalyzova@yandex.ru

Ivan K. Manaenkov, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Reinforced Concrete and Masonry Structures, Moscow State University of Civil Engineering (National Research University) (MGSU), 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; eLIBRARY SPIN-code: 5415-7373, Scopus: 57209888951, ResearcherID: AAE-1570-2022, ORCID: 0000-0002-5260-8793, E-mail: manaenkov.i.k@gmail.com

Vladimir I. Chernik, Candidate of Technical Sciences, Associate Professor of the Department of Reinforced Concrete and Stone Structures, Moscow State University of Civil Engineering (National Research University) (MGSU), 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; ID RSCI: 1091685, Scopus: 57218420224, ResearcherID: AAD-8260-2022, ORCID: 0000-0001-6240-9993, E-mail: chernik_vi@mail.ru

Широкий спектр исследований демонстрирует успешное применение различных моделей МО для решения задач строительной механики и проектирования строительных конструкций из различных материалов, в том числе композиционных, таких как железобетон. В работах, посвященных прогнозированию несущей способности элементов, показана высокая эффективность ансамблевых методов, таких как Random Forest [2] и Gradient Boosting [3], а также методов опорных векторов [4]. Например, в исследованиях Sayed и др. [5] сравнивались модели на основе МО с традиционными подходами для прогнозирования прочности сжатия железобетонных колонн. Mustafa и Ahmad [6] провели оценку ряда методов МО для прогнозирования несущей способности прямоугольных колонн, показав, что полиномиальная регрессия может достигать высокой точности. Эти работы подчеркивают потенциал МО как альтернативы или дополнения к эмпирическим формулам. Подобные подходы находят применение и для других типов конструкций, включая прогнозирование несущей способности стальных балок при высоких температурах [7], оценку прогрессирующего обрушения стальных каркасов [8, 9], а также для задач идентификации динамических характеристик, таких как прогнозирование собственных частот балок [10].

Наряду с прогнозированием несущей способности активно развиваются подходы к автоматизации процессов армирования и компоновки конструкций. Исследование [11] демонстрирует возможность интеграции технологий информационного моделирования (BIM) с визуальным программированием для автоматизации армирования железобетонных конструкций. В работе [12] рассматривается применение генеративного проектирования для оценки качества компоновки несущих конструкций. Эти работы указывают на расширение области применения ИИ от сугубо вычислительных задач к задачам оптимизации проектных решений.

Несмотря на значительный прогресс, широкое внедрение методов МО в инженерную практику сдерживается рядом фундаментальных проблем. Ключевыми из них являются: интерпретируемость результатов, так как многие модели (например, глубокие нейронные сети) работают по принципу «черного ящика», что вызывает недоверие у инженеров-проектировщиков [13]; проблема качественной оценки результата и анализа ошибок моделей, включая их чувствительность к выбросам и обобщающую способность; а также необходимость выявления и учета сложных нелинейных зависимостей между параметрами, которые не всегда могут быть адекватно описаны существующими физическими моделями. В ответ на эти вызовы появляются новые направления, такие как объяснимое машинное обучение (например, с использованием SHAP-анализа [13]) и физически-информированные нейронные сети (PINNs) [14], которые интегрируют физические законы в процесс обучения для повышения надежности и интерпретируемости прогнозов. Исследования по применению PINNs в моделировании сложного сопротивления бетона [15] свидетельствуют о растущем интересе к гибридным подходам, сочетающим сильные стороны моделей, обученных на больших данных, и известные физические закономерности. Еще одной областью приложения машинного обучения является применение машинного зрения к оценке параметров технического состояния строительных конструкций [16] и анализу механизмов и динамики разрушения конструкций [17].

Цель данной обзорно-аналитической статьи состоит в систематизации и критическом анализе современного состояния исследований по применению машинного обучения для расчета железобетонных конструкций. В работе рассмотрены основные разновидности используемых моделей машинного обучения, проанализированы количественные метрики для оценки качества их предсказаний, а также обсуждены проблемы, связанные с интерпретируемостью ре-

зультатов, оценкой ошибок и выявлением нелинейных зависимостей. Особое внимание уделено существующим пробелам в научном знании в области применения методов машинного обучения к расчету железобетонных конструкций, нормативным коллизиям и ограничениям, препятствующим практическому внедрению технологий ИИ в проектирование. На основе проведенного анализа сформулированы перспективные направления дальнейших исследований.

ПРАВОВЫЕ АСПЕКТЫ ПРИМЕНЕНИЯ ИИ В СТРОИТЕЛЬНОМ ПРОЕКТИРОВАНИИ

В России принят ряд важных документов, регулирующих сферу искусственного интеллекта (ИИ). Указ Президента РФ от 15.02.2024 № 124 внес масштабные изменения в Национальную стратегию развития искусственного интеллекта до 2030 года. Он определил новые приоритеты, включая совершенствование этических правил в сфере ИИ, создание механизмов оценки рисков, разработку требований к информационной безопасности, определение правил работы с большими генеративными моделями, создание системы оценки эффективности внедрения ИИ. Закон от 25.06.2024 № 93-ФЗ внес поправки в закон «Об экспериментальных правовых режимах в сфере цифровых инноваций» (вводится защита исключительных прав на результаты интеллектуальной деятельности, созданные с применением ИИ, упрощается доступ разработчиков к участию в экспериментальных правовых режимах (регуляторных «песочницах»), компании обязаны вести реестр лиц, работающих с ИИ, которые будут нести ответственность за нештатные ситуации). ГОСТ Р 71539–2024 устанавливает требования к процессам жизненного цикла системы искусственного интеллекта. ГОСТ Р 71752–2024 определяет требования к структуре и содержанию технического задания в области ИИ. ГОСТ Р 71476–2024 (ИСО/МЭК 22989: 2022) определяет концепции и терминологию ИИ. ГОСТ Р 71718–2024 определяет использование ИИ в строительном контроле.

Национальная стратегия развития ИИ на период до 2030 г. (Указ Президента Российской Федерации от 10.10.2019 г. № 490) определяет ИИ как «комплекс технологических решений, позволяющий имитировать когнитивные функции человека (включая самообучение и поиск решений без заранее заданного алгоритма) и получать при выполнении конкретных задач результаты, сопоставимые, как минимум, с результатами интеллектуальной деятельности человека; включает в себя информационно коммуникационную инфраструктуру, программное обеспечение (в том числе то, в котором используются методы машинного обучения), процессы и сервисы по обработке данных и поиску решений». В ГОСТ Р 71476–2024 ИИ определяется как «область науки и техники, рассматривающая технические системы, которые порождают такие результаты, как контент, прогнозы, рекомендации или решения для заданного набора поставленных человеком задач».

Активное внедрение инструментов искусственного интеллекта в различные сферы деятельности, в том числе проектирование, создает ряд правовых вопросов в части авторства и ответственности за полученные результаты. Сравнение по ключевым параметрам регулирования ИИ в России, Китае, США и Европейском Союзе на текущий момент (2025–2026 гг.) представлено в табл. 1.

Таблица 1

Сравнение по ключевым параметрам регулирования ИИ в разных странах на текущий момент (2025–2026 гг.)

Параметр	Россия	Китай	США	Европейский Союз
Единый закон об ИИ	Нет (обсуждается, но не принят)	Нет, но есть серия обязательных положений	Нет на федеральном уровне, но есть на уровне штатов	Да (AI Act, вводится поэтапно с 2024 г.)
Обязательная регистрация/сертификация моделей	Нет обязательной регистрации. Для медицинских ИИ-устройств требуется регистрация в Росздравнадзоре	Да — все генеративные и рекомендательные алгоритмы проходят регистрацию в САС и оценку безопасности	Только для госзакупок и для моделей, требующих огромных вычислительных мощностей (по EO 14110). Штаты могут требовать отчеты	Да — для высокорисковых систем (оценка соответствия); для генеративных — только требования прозрачности
Маркировка ИИ-контента	Обязательна с 2024 г. (ФЗ «Об информации» — уведомление, что контент создан ИИ)	Обязательна (явная или скрытая метка, водяные знаки)	Требуется на уровне штатов (Калифорния) и добровольно по отраслевым стандартам (C2PA)	Обязательна для генеративных систем
Регулирование биометрии/Deepfake	Ограничено 152-ФЗ (согласие на биометрию) и этическими нормами. Прямого запрета дипфейков пока нет	Строгий контроль: дипфейки с гослицами запрещены, требуется согласие человека	Жестко на уровне штатов (BIPA в Иллинойсе, AB-730 в Калифорнии). Федерально пока нет	Запрещен социальный рейтинг и удаленная биоидентификация в реальном времени (кроме исключений)
Ответственность за ошибки ИИ	Владелец/оператор через общие нормы ГК (вред), КоАП и УК (халатность, нарушение прав)	Оператор и разработчик (вплоть до уголовной ответственности, если доказан умысел или халатность)	Через общие доктрины (product liability, negligence, диффамация) — судебная практика	Производитель/оператор высокорисковой системы (презумпция вины)
Штрафы	За нарушения 152-ФЗ: до 300–500 тыс. руб. (юридические лица до 6 млн руб.). За 149-ФЗ (маркировка) — до 1 млн руб. Возможна уголовная ответственность за причинение вреда	До 10 млн юаней или 5 % оборота и отзыв лицензии	Ограничены отраслевыми законами (FTC: до \$50 тыс. за нарушение; штатные — до \$5–10 тыс. за каждое нарушение BIPA)	До €35 млн или 7 % годового оборота
Трансграничный оборот данных	Ограничен 152-ФЗ (не передавать данные россиян без согласия)	Жесткая локализация (данные граждан КНР хранятся внутри страны)	Свободный, но для европейцев — GDPR; есть ограничения по экспорту ИИ-чипов	Жесткие ограничения (GDPR), требуется адекватный уровень защиты

В табл. 2 представлена структура приоритетных сфер внедрения ИИ в регионах России на II квартал 2025 г. (по данным АНО «Цифровая экономика») и качественно описаны, какие изменения произошли по сравнению с 2023 г.

Таблица 2

Приоритетные сферы внедрения ИИ в регионах России (II кв. 2025 г.)

Сфера	Доля от всех ИИ решений	Изменения с 2023 г. (качественная оценка)
Здравоохранение	25 %	В 2023 г. уже была в топе, но доля была ниже (оценочно ~20 %). Рост связан с массовым внедрением анализа медизображений и голосовых помощников
Государственное управление	24 %	В 2023 г. также была приоритетной, но уступала образованию. Сейчас вышла на второе место за счет цифровизации госуслуг и документооборота
Безопасность	16 %	Доля стабильна (в 2023 г. — около 15 %). Активно развивается видеоаналитика и системы распознавания лиц
Образование	Не входит в топ 3	В 2023 г. образование входило в тройку лидеров (~18 %)
Природа и экология	Входит в топ 10	В 2023 г. эта сфера почти не фигурировала. Появление связано с новыми экологическими проектами и мониторингом
Город и ЖКХ	Входит в топ 10	В 2023 г. была на периферии. Сейчас растет за счет «умных» диспетчерских и систем мониторинга инженерных сетей
Социальная сфера	Входит в топ 10	В 2023 г. была менее заметна. Сейчас автоматизация соцвыплат и поддержка населения набирают обороты.
Строительство	Входит в топ 10	В 2023 г. почти не применялась. В 2025 г. утвержден первый ГОСТ по ИИ в строительном контроле, что стимулирует внедрение

Правительство РФ поставило задачу к 2030 г. войти в первую пятерку стран мира по метрикам ИИ, установив следующие ключевые показатели:

- не менее 95 % приоритетных отраслей экономики с высоким значением индекса готовности к внедрению ИИ-технологий;
- до 60 млрд руб. — ежегодный объем оказанных услуг по разработке и реализации ИИ-решений;
- более 1 эксафлопса — совокупная мощность суперкомпьютеров в России;
- более 15,5 тыс. выпускников программ высшего образования в области ИИ в год;
- не менее 80 % работников, имеющих навыки использования ИИ.

МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ В РАСЧЕТАХ СТРОИТЕЛЬНЫХ КОНСТРУКЦИЙ

Применение методов машинного обучения в расчетах строительных конструкций активно развивается и в последние годы стало новым трендом в международных научных публикациях [1–9]. Основным инструментом для расчета различных параметров строительных конструкций здесь выступают регрессионные модели. При этом методы машинного обучения позволяют выявлять сложные, нелинейные зависимости, которые трудно описать традиционными аналитическими формулами.

Все модели машинного обучения для решения задач регрессии можно разделить на несколько категорий в зависимости от их сложности и подхода к обучению (табл. 3).

Таблица 3

Категория моделей машинного обучения, используемых в расчете строительных конструкций

Категория	Виды моделей	Достоинства
Простые регрессионные модели	Линейная регрессия, Полиномиальная регрессия, Гребневая регрессия (Ridge), Лассо (Lasso)	Высокая интерпретируемость
Ансамблевые методы	Случайный лес (Random Forest), Градиентный бустинг (Gradient Boosting, XGBoost)	Высокая точность, устойчивость к переобучению
Нейросетевые подходы	Искусственные нейронные сети (ANN), Многослойный перцептрон (MLP)	Способность моделировать сверхсложные нелинейности
Специализированные методы	Метод опорных векторов (SVR), Кригинг (Kriging), Метод k -ближайших соседей (KNN)	Хорошая интерпретируемость, высокая интерполяционная способность

Рассмотрим особенности некоторых моделей машинного обучения и области их приложения в расчете строительных конструкций.

Простые регрессионные модели

Простые регрессионные модели включают линейные, полиномиальные регрессии, а также регуляризованные модели, такие как Ridge, Lasso. Линейная регрессия — наиболее простая для интерпретации модель, которая устанавливает линейную зависимость вида $Y_m = W_0 + \sum W X$, где X — входные параметры, например прочность бетона, размер сечения, а W — весовые коэффициенты.

Регрессионные модели могут быть использованы и для подбора параметров более сложных зависимостей. Однако набор входных параметров здесь определяется самим исследователем на основе анализа экспериментальных данных с учетом формулируемых гипотез о связи и взаимном влиянии этих параметров на искомую величину. Поэтому возникает необходимость качественной и количественной оценки значимости входных параметров модели и их взаимной корреляции.

Полиномиальные и иные нелинейные регрессии представляют собой расширение линейной модели, которое позволяет решать более сложные задачи, учитывать нелинейные взаимосвязи. Так, например, в работе [18] была использована оптимизированная версия метода Левенберга – Марквардта [19], реализованная в ПО MathCAD, для подбора параметров d, θ нелинейной вязкоупругой модели бетона, описываемой зависимостью вида:

$$\sigma(\varepsilon, t) = f_0(\varepsilon) + \int_{t_1}^t \dot{\varepsilon}(\tau) \cdot p(\eta_\varepsilon) \cdot \sum_i^n d_i(t) \cdot e^{-\theta_i(t)(t-\tau)} d\tau. \tag{1}$$

Регуляризованные модели МО, такие как Ridge, Lasso, включают дополнительные штрафы за сложность модели, что помогает предотвратить переобучение и делает ее более устойчивой.

Достоинством таких моделей является высокая степень интерпретируемости и обозримости. Однако при этом необходимо изначально задаться некоторым исходным видом зависимости, связывающей входные и искомую величину, что не во всех случаях является очевидным, особенно при большом количестве входных параметров или нелинейной связи между ними.

Ансамблевые методы

Ансамблевые методы, такие как Decision Tree, Random Forest, Gradient Boosting, комбинируют результаты множества простых моделей, называемых «деревьями решений», для получения одного точного прогноза. При использовании ансамблевых методов нет привычного уравнения регрессии. Так, в методе «Дерево решений» (Decision Tree) модель строится путем разбиения выборки данных по признакам на блоки, для каждого из которых строится постоянный прогноз (решение). Модель Random forest [2] представляет огромный набор простых «деревьев решений», построенных на разных подвыборках данных. Они состоят из цепочек вопросов и, в зависимости от значения входного параметра, соответствующих им результатов (рис. 1). В конце каждого дерева хранится одно число — ответ для данного набора входных данных. Таким образом, параметры модели Random forest — это не весовые коэффициенты аналитического выражения, а пороги разбиения (например, 20, 30 МПа и т.д.) и признаки в каждом узле каждого дерева, которые находят во время обучения. При этом результатом расчета по данной модели является среднее арифметическое ответов всех деревьев решений.

Градиентный бустинг [3] представляет собой модифицированный вариант метода Random Forest, где каждое последующее дерево решений исправляет ошибки предыдущего. В различных сравнительных исследованиях применения бустинговых моделей машинного обучения к расчету железобетонных конструкций, например работы [5, 6], они часто демонстрируют самую высокую точность и хорошую устойчивость к переобучению. В целом ансамблевые модели, такие как Random Forest, Gradient Boosting, хорошо справляются с нелинейными зависимостями и устойчивы к выбросам за счет осреднения или уточнения результата по нескольким деревьям решений. Однако отсутствие явной аналитической зависимости делает недоступной интерпретацию полученного результата.




Рис. 1. Схема алгоритма работы модели MO Random Forest. Источник [4]

Fig. 1. Scheme of ML algorithm Random Forest. Source [4]

Нейросетевые методы

Нейросетевые модели машинного обучения, такие как искусственные нейронные сети (ANN) [5, 8] или многослойный перцептрон (MLP), являются универсальными аппроксиматорами, способными моделировать зависимости практически любой сложности. Они состоят из множества взаимосвязанных «нейронов», организованных в слои (рис. 2).




Рис. 2. Графическая интерпретация метода «Искусственных нейронных сетей»
— Artificial Neural Network (ANN)

Fig. 2. Graphical interpretation of the Artificial Neural Network (ANN) approach

В методе искусственной нейронной сети (ANN) [8] уравнение регрессии есть, но оно не выглядит как одна простая формула, а представляет собой цепочку простых уравнений, наложенных друг на друга. Так, для одного нейрона зависимость имеет вид:

$$f = f(W_1 \cdot X_1 + W_2 \cdot X_2 + \dots + b), \quad (2)$$

где f — искомая нелинейная функция.

Тогда формула предсказания для сети с одним скрытым слоем примет вид:

$$y = f_2(W_2 \cdot f_1(W_1 \cdot X + b_1) + b_2), \quad (3)$$

где W_1 , W_2 — матрицы весов; b_1 , b_2 — смещения.

Если нейронов много и слоев несколько, то выход одного слоя становится входом для следующего. Исследования показывают, что нейронные сети могут быть не только точны, но и могут быть интерпретируемы. Например, с помощью SHAP-анализа для выявления важности факторов.

Специализированные методы

К специализированным методам машинного обучения относят метод опорных векторов (SVR) [5], метод k -ближайших соседей (KNN) [8, 9] и др. В методе опорных векторов (рис. 3) для регрессии (SVR) уравнение регрессии линейное, но оно имеет некоторые особенности. В простейшем случае (линейный SVR) уравнение такое же, как у обычной линейной регрессии:

$$y = W_1 \cdot X_1 + W_2 \cdot X_2 + \dots + b. \quad (4)$$

Особенность состоит в том, что при подборе уравнения регрессии игнорируются ошибки, если они выходят за область заданной ширины ε (эпсилон). Это делает метод более устойчивым к выбросам в данных. Для отыскания уравнения задают ширину области ε и штраф за вылеты C значений за пределы области. При таком подходе важно, чтобы большинство точек лежало внутри этой области. Точки на границе или снаружи называются опорными векторами — они определяют положение прямой, аппроксимирующей решение.

Метод k -ближайших соседей (KNN) [8, 9] прогнозирует значение для нового объекта на основе значений его k ближайших «соседей» в пространстве признаков.




Рис. 3. Графическая интерпретация Метода опорных векторов — Support Vector Regression (SVR)

Fig. 3. Graphical interpretation of the Support Vector Regression (SVR) approach

Сопоставление результатов расчета по различным моделям

Рассмотрим результаты сопоставления различных моделей машинного обучения при расчете железобетонных конструкций. Для количественной оценки качества моделей используются различные статистические метрики, представленные в табл. 4.

В работе [4] выполнен расчет несущей способности центрально сжатых железобетонных элементов, усиленных композитными материалами. Статистические метрики для результатов расчета по четырем моделям машинного обучения: GB — Gradient Boosting (Градиентный бустинг), RF — Random Forest (Случайный лес), ANN — Artificial Neural Networks (Искусственные нейронные сети), SVR — Support Vector Regressor (Метод опорных векторов) представлены на рис. 4. Наилучшие результаты продемонстрировали модели GB — Gradient Boosting (Градиентный бустинг), RF — Random Forest (Случайный лес). Близкий к ним результат продемонстрировала модель ANN – Artificial Neural Networks (Искусственные нейронные сети), см. рис. 4, а. Однако применительно к оценке надежности строительных конструкций важно понимать, что, несмотря на хорошие статистические метрики, отклонения рассчитанных значений могут быть как в меньшую, так и в большую сторону от искомой величины. Так, для двух подвыборок данных (рис. 4, b) отношение рассчитанной (спрогнозированной) несущей способности к экспериментально установленной $P_{analytical}/P_{experimental}$ варьировалось для рассмотренных моделей МО в следующих пределах: для SVR — от 0,2 до 3,2; для GB — от 0,9 до

1,5; для RF — от 0,85 до 1,45; для ANN — от 0,8 до 2,1. Очевидно неудачные результаты расчета несущей способности колонн с использованием модели SVR здесь могут быть объяснены плохим соответствием общего вида искомого уравнения регрессии решаемой задаче, нелинейной связью между входными параметрами и искомой величиной.

Таблица 4

Статистические метрики оценки качества модели машинного обучения

Статистический показатель	Формула	Идеальное значение
Среднеквадратичная ошибка	$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$	0
Корень из среднеквадратичной ошибки	$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}$	0
Средняя абсолютная ошибка	$MAE = \frac{\sum_{i=1}^n \hat{y}_i - y_i }{n}$	0
Средняя абсолютная процентная ошибка	$MAPE = \frac{1}{n} \sum_{i=1}^n \left \frac{\hat{y}_i - y_i}{y_i} \right \times 100\%$	0
Коэффициент детерминации	$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$	1




Рис. 4. Сравнение моделей машинного обучения на примере расчета центрально сжатых колонн, усиленных FRP. Источник [4]

Fig. 4. Comparison of Machine Learning (ML) models for structural analysis of centrally compressed columns enhanced with FRP. Source [4]

Следует заметить, что и в тех случаях, когда были получены хорошие статистические метрики (модели RF, GB, ANN) [5–9], значительная часть рассчитанных значений несущей способности превышала экспериментальные — до 1,5 раз при использовании модели GB, до 1,45 раз для модели RF и до 2,1 раза для модели ANN. Это обстоятельство подчеркивает важность использования для оценки качества моделей машинного обучения не только количественных

статистических критериев, но и качественного понимания физической сущности исследуемого явления. Так, при расчете несущей способности элементов конструкций для обеспечения их надежности и безопасности необходимо стремиться к тому, чтобы рассчитанные значения не превышали экспериментально установленных с заданной обеспеченностью. При прогнозировании значений нагрузок, напротив, наиболее неблагоприятным случаем, который необходимо учесть в проектировании, является превышение расчетных значений над фактическими.

МЕТОДЫ МАШИННОГО ЗРЕНИЯ В МОНИТОРИНГЕ ТЕХНИЧЕСКОГО СОСТОЯНИЯ СТРОИТЕЛЬНЫХ КОНСТРУКЦИЙ

Еще одним направлением приложения искусственного интеллекта является машинное зрение, которое может быть использовано при оценке технического состояния строительных конструкций. Традиционный визуальный осмотр железобетонных конструкций остается трудоемким, субъективным и подверженным человеческому фактору [20]. Для преодоления этих ограничений в последние годы активно развиваются методы машинного зрения, позволяющие автоматизировать обнаружение, локализацию и количественную оценку повреждений.

Современные исследования в этой области можно разделить на три основные группы: распознавание повреждений, их локализация и количественная оценка. В основе большинства реализаций методов машинного зрения для решения этих задач лежат сверточные нейронные сети (CNN) и архитектуры на основе трансформеров [21].

В работе [16] предложена трехэтапная компьютеризированная система для обнаружения трещин и автоматического определения их длины, максимальной ширины и площади (рис. 5). Рассмотренный подход может существенно повысить эффективность сбора информации о трещинах непосредственно на строительных площадках.




Рис. 5. Применение машинного зрения для анализа расположения и размеров трещин. Источник [16]

Fig. 5. Machine vision application in detection and measurement of cracks in concrete structures.

Source [16]

Основным направлением развития методов машинного зрения является переход от простого обнаружения к количественным измерениям параметров дефектов и повреждений. В работе [22] представлена автоматизированная система для измерения ширины трещин в железобетонных элементах. Предложенный авторами алгоритм калибровки и масштабирования позволяет переводить размеры трещин из пиксельных в реальные величины с использованием недорогих устройств. Выполненная ими валидация метода на 230 точках измерений показала среднюю относительную погрешность 12,65 %, что подтверждает надежность такого подхода.

Показательным примером использования машинного зрения для расследования крупных аварий служит исследование Kong и Smyl [17], посвященное обрушению жилого комплекса в Серфсайде (рис. 6). В исследовании разработана методология для оценки процесса разрушения здания на основе компьютерного зрения и трекинга характерных точек на видеозаписях. Этот подход позволил проанализировать динамику обрушения по видеозаписям, доступным в социальных сетях, что открывает новые возможности для расследования подобных инцидентов.

Kemal H., Serhat D. [23] продемонстрировали эффективность U-Net архитектур для быстрой оценки повреждений железобетонных конструкций после землетрясения в Турции. Модели глубокого обучения показали существенное преимущество перед традиционным визуальным осмотром, обеспечивая более быструю, согласованную и точную оценку ущерба.




Рис. 6. Результаты обработки машинным зрением видеозаписей обрушения комплекса Champlain Towers (Florida, 21 June 2021) и виды использованных геометрических преобразований изображений. Источник [17]
Fig. 6. Machine Vision application for processing collapse of the Champlain Towers (Florida, 21 June 2021) and corresponding geometrical transformations which was adopted. Source [17]

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КОМПОНОВКИ И КОНСТРУИРОВАНИЯ ЖЕЛЕЗОБЕТОННЫХ КОНСТРУКЦИЙ

Практической реализацией методов машинного обучения применительно к расчету и проектированию железобетонных конструкций являются экспертные системы. В основе экспертных систем лежит база знаний и набор правил вида «ЕСЛИ – ТО», позволяющих компьютеру имитировать рассуждения специалиста [24]. Это направление сегодня называют: символьный ИИ (Symbolic AI) или классический подход к ИИ, основанный на логических правилах и экспертных знаниях GOF AI (Good Old-Fashioned AI).

Экспертные системы используют дерево логических правил, создаваемое человеком. Современные методы машинного обучения, такие как Деревья решений (Decision Trees) и Случайный лес (Random Forest), также используют древовидную структуру принятия решений. По своей логике дерево решений близко к экспертной системе, однако условия ветвления в нем определяются не экспертом, а автоматически на основе анализа обучающих данных. В методе случайного леса итоговый результат формируется путем голосования множества независимо построенных деревьев решений.

Одним из примеров такого подхода является программный комплекс PromCore (URL: <https://promcore.io>). Программный комплекс имеет в своем составе 3 модуля на основе методов машинного обучения:

1. SmartPylon — модуль, позволяющий выполнять компоновку несущих пилонов на архитектурном плане здания. В качестве исходных данных задаются зоны допустимого положения пилонов и диапазон расстояний между ними. Сгенерированные схемы передаются в модуль FEMnet.
2. FEMnet — расчетный МКЭ-модуль на основе нейросетей, который позволяет определить наиболее экономичную схему расстановки пилонов и колонн, с точки зрения минимизации армирования и толщины плиты безбалочного железобетонного перекрытия.
3. SmartCity — расчетный модуль на основе нейросетей, который позволяет выполнить раскладку продольной арматуры в плитах перекрытия. Проводит статический анализ НДС железобетонных безбалочных плит и, используя изополя требуемого армирования, выполняет раскладку фоновой и дополнительной арматуры.

Правила размещения несущих элементов задаются инженером, а оценка внутренних усилий выполняется обученной нейронной сетью FEMnet. В отличие от традиционного конечно-элементного расчета, нейронная сеть позволяет получать предварительную оценку конструктивных решений практически в реальном времени, что делает возможным быстрый анализ большого числа вариантов на ранних стадиях проектирования.

В основу метода положено предположение о том, что чем меньше абсолютные значения моментов в плите в направлениях X и Y , тем меньше суммарное армирование плит [25]. Критерием оптимизации является коэффициент анизотропии плиты перекрытия. При равномерной конечно-элементной сетке определяется по формуле:

$$k = \frac{\max(\bar{m}_x, \bar{m}_y)}{\min(\bar{m}_x, \bar{m}_y)}, \quad (5)$$

где $\bar{m}_x$ и $\bar{m}_y$ — показатели моментов вдоль осей X и Y :

$$\bar{m}_x = \frac{1}{n} \sum_{i=1}^n M_{xi}, \quad (6)$$

$$\bar{m}_y = \frac{1}{n} \sum_{i=1}^n M_{yi}, \quad (7)$$

M_{xi} и M_{yi} — изгибающие моменты в направлении X и Y ;

i — номер конечного элемента;

n — общее число конечных элементов.

В идеале показатель анизотропии должен стремиться к $k = 1$. Чем более уравновешены моменты в обоих направлениях, тем меньше зоны дополнительного армирования.

Данный подход может быть применен и к проектированию свайного поля. Чем меньше разница между максимально и минимально нагруженной свайей, тем меньше показатель анизотропии фундаментной плиты и тем меньше армирование.

Нейронная сеть FEMnet является примером суррогатной модели, обученной на результатах конечно-элементных расчетов. Это позволяет выполнять предварительную оценку работы конструкций в сотни раз быстрее традиционного МКЭ при приемлемой для ранних стадий проектирования точности.

Для дополнительного ускорения оценки внутренних усилий в вертикальных несущих элементах в системе PromCore реализован алгоритм определения зон влияния (грузовых площадей), основанный на методе вычитания конусов (рис. 7). Метод дает разницу не более 10 % по сравнению с усилиями, полученными с помощью МКЭ. Скорость генерации 1 варианта составляет 0,01 с.




Рис. 7. Определение грузовых площадей вертикальных несущих конструкций в модуле FEMnet.

URL: <https://promcore.io>

Fig. 7. Determining the load-bearing areas of vertical pilons in the FEMnet module.

URL: <https://promcore.io>

В состав ПК PromCore входит расчетный модуль SmartCity, который позволяет выполнить автоматизированную раскладку рабочей арматуры в плитах перекрытия на основе методов машинного обучения (рис. 8). Все параметры армирования задаются исходя из особенностей конкретного проекта. Алгоритм SmartCity включает: статический анализ НДС с определением изополей требуемого армирования; анализ изополей и раскладку фоновой и дополнительной арматуры с учетом исходных данных; составление спецификаций расхода арматуры. Далее возможен экспорт результатов армирования в программы САПР (например, Revit) для разработки чертежей рабочей документации.




Рис. 8. Пример раскладки рабочей арматуры в модуле SmartCity на основе изополей требуемого армирования.

URL: <https://promcore.io>

Fig. 8. An example of the layout of reinforcement in the SmartCity module based on the schemes of the required reinforcement. URL: <https://promcore.io>

Помимо этого, существуют программные решения для разработки моделей на основе машинного обучения под конкретные инженерные и научные задачи, такие как STATISTICA Neural Networks. Пакет Neural Networks встроен в набор других аналитических средств программы STATISTICA, что позволяет использовать общие исходные данные для различных методов анализа.

В работе [26] рассмотрена возможность применения искусственного интеллекта при моделировании напряженно-деформированного состояния усиленных конструкций. Выявлено, что применение искусственного интеллекта в виде нейросетевого моделирования позволяет прогнозировать несущую способность и выполнять расчеты усиленных композитными материалами строительных конструкций.

Алгоритм формирования нейросетевой модели для определения несущей способности железобетонных конструкций:

- 1) определить состав и количество независимых переменных, оказывающих наибольшее влияние на выходной параметр (несущая способность элемента);
- 2) отобрать тестовую партию экспериментальных исследований, необходимую для обучения создаваемой искусственной нейронной сети;
- 3) запрограммировать искусственную нейронную сеть, например, с использованием модуля Neural Networks системы STATISTICA;
- 4) проверить созданную искусственную нейронную сеть на образцах, которые не участвовали в обучении.

Интеграция программных решений на основе методов машинного обучения в практику строительного проектирования позволит решить задачи автоматизированной обработки больших массивов информации и сократить время на рутинные проектные процедуры, а также решать задачи эффективной оптимизации проектных решений при минимальных затратах вычислительных мощностей.

ОПАСНОСТИ И ОГРАНИЧЕНИЯ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В РАСЧЕТАХ ЖЕЛЕЗОБЕТОННЫХ КОНСТРУКЦИЙ

При использовании любых программ и продуктов искусственного интеллекта, и, в частности, машинного обучения (МО), следует всегда помнить о том, что эти модели имеют границы применимости. Восхищение точностью прогнозов, которое могут демонстрировать нейросетевые и ансамблевые модели на обучающих выборках, не должно затмевать фундаментальные ограничения, присущие этим подходам. Для инженера-проектировщика, привыкшего опираться на физически обоснованные и верифицированные методики, понимание этих ограничений становится вопросом профессиональной ответственности и грамотности, поскольку от качества прогноза зависит безопасность проектируемых зданий и сооружений.

Прежде всего, следует отметить проблему интерпретируемости результатов, которая в научной литературе получила образное название — «черный ящик». Многие инженеры — потребители моделей машинного обучения не доверяют результатам, если не могут понять метод их получения. Это особенно критично для задач строительной механики, где важно не просто получить число, сколько осознать корректность полученной физической картины напряженно-деформированного состояния конструкции. Сложные ансамблевые и нейросетевые модели, хотя и обеспечивают высокую точность, не предоставляют явного физического уравнения, связывающего входные и выходные параметры. Это порождает серьезные препятствия для внедрения ИИ в практику проектирования, поскольку инженер не может проверить физический смысл полученных с помощью ИИ результатов и вынужден полагаться на модель как на абсолютный авторитет, что противоречит самой сути инженерного мышления [13].

С практической точки зрения еще более серьезными проблемами в применении ИИ являются экстраполяция и обобщения. Машинное обучение блестяще работает в интерполяционном режиме, т.е. внутри области, представленной в обучающей выборке. Однако при выходе за ее пределы модели могут демонстрировать катастрофическую потерю точности. Как показано в исследовании [27], посвященном моделированию поведения бетона, неограниченная модель Гауссовской регрессии прекрасно интерполирует вблизи обучающих данных. Но при экстраполяции, т.е. при выходе из обучающей области, работа модели резко ухудшается и нарушает фундаментальные физические ограничения. Например, если нейросеть обучалась на бетоне классов В15–В40, то при попытке предсказать прочность колонны из бетона В80 можно получить физически абсурдный результат, который будет воспринят моделью как достоверный. Применительно к железобетонным конструкциям это создает прямую угрозу: редкие, но критически важные сценарии нагружения, нестандартные классы материалов или нетипичные конструктивные решения оказываются вне зоны компетенции ИИ.

Косвенным, но крайне важным следствием проблем экстраполяции и обобщения является высокая чувствительность к объему и качеству исходных данных. Получение репрезентативных выборок для железобетонных конструкций сопряжено со значительными затратами на физические испытания. В условиях ограниченных данных модели чрезвычайно склонны к переобучению, когда они идеально «запоминают» обучающую выборку (демонстрируя коэффициент детерминации $R^2 = 1,0$), но оказываются полностью несостоятельными на новых, даже незначительно отличающихся примерах. Современные исследования в области структурного мониторинга [28] подчеркивают, что существующие методы на основе датчиков и физических моделей имеют ограничения при решении задач, связанных со сложным механическим поведением и нехваткой данных, что делает особенно актуальным внедрение гибридных подходов.

Стоит отметить, что осознание и систематизация перечисленных выше ограничений методов МО представляет собой не критику технологий ИИ как таковых, а необходимый этап их корректного внедрения в инженерную практику. Задача инженера — не заменить машинным обучением классическую механику, а использовать его как ускоритель там, где классические

методы работают долго, а также всегда проверять границы применимости искусственного интеллекта.

Важным аспектом, часто остающимся за рамками обсуждения, является зависимость качества ответа нейросети от корректности постановки задачи. Современные генеративные модели и регрессионные алгоритмы не обладают самостоятельным мышлением. Они являются сложными аппроксиматорами, отражающими закономерности, заложенные в обучающих данных и структуре запроса. Нечетко сформулированная задача порождает столь же нечеткое решение.

Например, слишком простой запрос типа «Рассчитай балку» приведет к генерации общей, возможно, даже физически некорректной информации, тогда как постановка задачи с указанием конкретных данных (расчетной схемы, геометрических параметров, класса бетона и характера нагружения) позволяет модели сформировать осмысленный и проверяемый результат. Образно говоря, ИИ — это «зеркало» инженерной мысли: оно не создает нового смысла, а отражает и структурирует то, что в него вложено пользователем.

Суть работы с ИИ заключается в том, что ИИ не способен заменить инженерную компетенцию, но при корректном использовании может выявить и усилить ее. Скучный вопрос родит скучный ответ; глубокий, инженерно-грамотный вопрос откроет инженеру новые смыслы. Компетентный пользователь, четко формулирующий физическую постановку задачи, получает эффективного ассистента, а некомпетентный, доверяющий модели как источнику истины, — становится опасным. Таким образом, культура работы с ИИ начинается с культуры постановки вопроса.

Таким образом, осознание того, что ИИ — это ускоритель работы и «зеркало» инженерной мысли, а не ее замена, позволяет сконцентрироваться на разработке подходов, нивелирующих перечисленные опасности. В частности, в научном сообществе активно развиваются физико-информированные нейронные сети (PINNs), которые встраивают законы физики непосредственно в процесс обучения, тем самым повышая интерпретируемость, устойчивость к экстраполяции и снижая потребность в больших объемах данных [29]. Этот путь представляется наиболее перспективным для создания действительно надежных и практически применимых инструментов ИИ для расчета железобетонных конструкций [30–32].

ЗАКЛЮЧЕНИЕ

1. Методы МО (особенно ансамблевые и нейросетевые) позволяют моделировать работу конструкций там, где классические аналитические формулы дают большую погрешность — например, при учете совместного влияния дефектов, неоднородности материалов или динамических нагрузок.

2. В отличие от классических регрессий, где инженер сам должен задать вид зависимости (линейную, квадратичную и т.д.), методы МО сами «находят» значимые комбинации входных параметров. Это ускоряет разработку суррогатных моделей для конечно-элементных расчетов.

3. Случайный лес, Бустинг, Нейронные сети и SVR дают точные прогнозы, но не предоставляют явного физического уравнения. Инженеру сложно объяснить, почему модель выдала именно этот результат, что критично для экспертизы и норм проектирования

4. Все рассмотренные методы требуют репрезентативной обучающей выборки. Для строительных конструкций получить тысячи размеченных примеров часто дорого (физические испытания). При малых данных модели переобучаются.

5. Простые линейные модели быстры и прозрачны, но недостаточно точны для сложных конструкций. Глубокие нейронные сети и градиентный бустинг дают высокую точность, но требуют больших вычислительных ресурсов для обучения и подбора параметров, а также опыта в настройке.

6. Методы машинного обучения, несмотря на высокую точность прогнозов на обучающих выборках, имеют принципиальные ограничения интерпретируемости, экстраполяции и чувствительности к объему данных, что требует критического осмысления результатов и не допускает их прямого использования в нормативном проектировании железобетонных конструкций без дополнительной физической верификации.

7. Эффективность применения ИИ в инженерных расчетах определяется не столько возможностями алгоритмов, сколько компетенцией пользователя: грамотная постановка задачи и критическая оценка полученного ответа остаются необходимыми условиями безопасного использования этих технологий.

Перспективы использования и направления дальнейших исследований:

1. Разработка методов, которые встраивают в архитектуру Нейронных сетей или Случайного леса известные физические законы (уравнения равновесия, совместности деформаций). Это позволит повысить интерпретируемость и уменьшить потребность в больших данных. Наиболее перспективным направлением здесь являются Физико-информированные нейронные сети (Physics-Informed Neural Networks, PINNs), активно развивающиеся в современной научной литературе.

2. Создание предобученных моделей для распространенных классов элементов (балки, колонны) с возможностью дообучения под конкретные задачи с малым числом экспериментов. Это позволит использовать инструменты МО при обследовании существующих зданий.

3. Адаптация методов МО для визуализации того, какие параметры (прочность, геометрия, армирование) и в какой степени влияют на прогноз несущей способности или деформативности.

4. Встраивание обученных регрессионных моделей в реальном времени в цифровые двойники зданий. Например, нейросеть, обученная на данных мониторинга, прогнозирует развитие трещин или осадок при изменении нагрузки, работая внутри BIM-платформ.

5. Разработка методов решения обратных задач, позволяющих по измеренным деформациям, перемещениям или частотам собственных колебаний определять скрытые параметры конструкции (фактическую прочность бетона, диаметр и расположение арматуры, наличие дефектов). Это направление особенно актуально для обследования существующих зданий и сооружений, где разрушающие методы контроля невозможны или ограничены.

6. Создание методологии валидации и сертификации моделей машинного обучения для использования в нормативном проектировании, включая разработку критериев оценки достоверности прогнозов, определение границ применимости для конкретных классов конструкций и формирование рекомендаций по верификации результатов с использованием классических аналитических и численных методов.

СПИСОК ЛИТЕРАТУРЫ

1. Захаров Ф.Н., Цзе Ц., И.С. Физически-информированные нейронные сети для задач строительной механики и конструкций: моделирование прогиба однопролетной балки // Железобетонные конструкции. 2025. № 9 (1). С. 35–48. DOI: 10.22227/2949-1622.2025.1.35-48
2. Breiman L. Random forests. Mach Learn. 2001. 45 p. DOI: 10.1023/A:1010933404324
3. Natekin A., Knoll A. Gradient boosting machines : a tutorial // Front Neurorobot. 2013. P. 7. DOI: 10.3389/fnbot.2013.00021
4. Cortes C., Vapnik V. Support-Vector Networks // Mach Learn. 1995. № 20. DOI: 10.1023/A:1022627411411
5. Sayed Y.A.K., Alzhraa I.A., Tamrazyan A.G., Fahmy M.F.M. Machine-learning-based models versus design-oriented models for predicting the axial compressive load of FRP-confined rectangular RC columns // Engineering Structures. 2023. Vol. 285. P. 116030. DOI: 10.1016/j.engstruct.2023.116030
6. Mustafa R., Ahmad M.T. Appraisal of numerous machine learning techniques for the prediction of axial load carrying capacity of rectangular concrete column // Asian J Civ Eng. 2024. Vol. 25. Pp. 4471–4486. DOI: 10.1007/s42107-024-01060-6

7. Couto C., Tong Q., Gernay T. Predicting the Capacity of Thin-Walled Beams at Elevated Temperature with Machine Learning // *Fire Saf J.* 2022. Vol. 130. DOI: 10.1016/j.firesaf.2022.103596
8. Fu F. Fire Induced Progressive Collapse Potential Assessment of Steel Framed Buildings Using Machine Learning // *J Constr Steel Res.* 2020. Vol. 166. DOI: 10.1016/j.jcsr.2019.105918
9. Zhu Y.F., Yao Y., Huang Y., Chen C.H., Zhang H.Y., Huang Z. Machine Learning Applications for Assessment of Dynamic Progressive Collapse of Steel Moment Frames // *Structures.* 2022. P. 36. DOI: 10.1016/j.istruc.2021.12.067
10. Das O. Prediction of the Natural Frequencies of Various Beams Using Regression Machine Learning Models // *Sigma Journal of Engineering and Natural Sciences.* 2023. Vol. 41. DOI: 10.14744/sigma.2023.00040
11. Ниширимана Ж.Д., Эльшейх А.М. Автоматизация армирования железобетонных конструкций с помощью технологии информационного моделирования и визуального программирования // *Вестник евразийской науки.* 2025. Т. 17. № 2. URL: <https://esj.today/PDF/36SAVN225.pdf>
12. Фомин Н.И., Исупов Н.С. Оценка качества компоновки несущих конструкций с применением технологии генеративного проектирования // *Вестник евразийской науки.* 2024. Т. 16. № 5. URL: <https://esj.today/PDF/54SAVN524.pdf>
13. Tahmassebi A., Motamedi M., Alavi A.H., Gandomi A.H. An explainable prediction framework for engineering problems: case studies in reinforced concrete members modeling // *Journal of Engineering Computations.* 2021. URL: https://opus.lib.uts.edu.au/bitstream/10453/167687/2/Engineering_Computations_RC_Failures_XGB_SHAP%20%281%29%20%281%29.pdf
14. Varghese S., Anand R., Paliwal G. Physics-Informed Neural Network for Concrete Manufacturing Process Optimization // *Computer Science. Machine Learning.* 2024. DOI: 10.48550/arXiv.2408.14502
15. Ke Y., Liu C.W., Zhang S.S. Physics-informed neural network (PINN)-based numerical simulation of concrete mechanical responses // *Engineering Structures.* 2026. Vol. 350. P. 121982. DOI: 10.1016/j.engstruct.2025.121982
16. Qi Y., Ding Z., Luo Y., Ma Z. A Three-Step Computer Vision-Based Framework for Concrete Crack Detection and Dimensions Identification // *Buildings.* 2024. No. 14. P. 2360. DOI: 10.3390/buildings14082360
17. Kong X., Smyl D. Investigation of the condominium building collapse in Surfside, Florida: A video feature tracking approach // *Structures.* 2022. Vol. 43. Pp. 533–545. DOI: 10.1016/j.istruc.2022.06.009
18. Savin S.Yu., Sharipov M.Z. Nonlinear visco — elastic behavior of concrete under static-dynamic loading: Experimental and numerical studies // *Structures.* 2025. Vol. 74. P. 108496.
19. Reklaitis G.V., Ravindran A., Ragsdell K.M. *Engineering Optimization: Methods and Applications.* John Wiley & Sons, 2006.
20. Pan X., Yang T.T.Y., Li J. et al. A review of recent advances in data-driven computer vision methods for structural damage evaluation: algorithms, applications, challenges, and future opportunities // *Arch Computat Methods Eng.* 2025. Vol. 32. Pp. 4587–4619. DOI: 10.1007/s11831-025-10279-8
21. Song Y., Zhang Q., Su Y., Zhang S., Wang R., Zhang W., Bi Z., Yu Y. Advances in crack dataset development and deep learning-based detection models // *Journal of Building Engineering.* 2025. Vol. 116. P. 114734.
22. Hassouna M., Marzouk M., Fathalla E. Automated low-cost framework for crack measurements in RC structures using deep learning approach. 2026. P. 14678. DOI: 10.1038/s41598-026-50880-w
23. Kemal H., Serhat D. Deep Learning–Based Automated Crack Detection for Post-Earthquake Damage Assessment in Reinforced Concrete Structures // *Advances in Civil Engineering.* 2026. P. 6845779. DOI: 10.1155/adce/6845779
24. Левин Р., Дранг Д., Эделсон Б. Практическое введение в технологию искусственного интеллекта и экспертных систем с иллюстрациями на Бейсике / пер. с англ.; предисл. М.Л. Сальникова, Ю. В. Сальниковой. М. : Финансы и статистика, 1990. 239 с.
25. Фомин Н.И., Исупов Н.С. Оценка качества компоновки несущих конструкций с применением технологии генеративного проектирования // *Вестник евразийской науки.* 2024. Т. 16. № 5. URL: <https://esj.today/PDF/54SAVN524.pdf>
26. Римшин В.И., Трунтов П.С., Молчанова А.Е. Методы применения искусственного интеллекта при моделировании напряженно-деформированного состояния усиленных конструкций // *Вестник Поволжского государственного технологического университета. Серия «Материалы. Конструкции. Технологии».* 2023. № 3 (27). С. 45–54. DOI: 10.25686/2542-114X.2023.3.45
27. Li C. et al. Physics-Informed Gaussian Process Regression for the Constitutive Modeling of Concrete: A Data-Driven Improvement to Phenomenological Models // *arXiv. Preprint,* 2026. URL: <https://arxiv.org/abs/2601.03367>
28. Guo X., Song Zh. Review on crack monitoring technology based on physics-informed neural networks // *Jixie Qiangdu. (Mechanical Strength).* 2025. Vol. 47. Pp. 18–30. DOI: 10.16579/j.issn.1001.9669.2025.12.002
29. Saeed H.M. et al. Recent Advances of Machine Learning in Fracture Mechanics of Quasi-Brittle Materials : a Review // *Jurnal Kejuruteraan.* 2025. No. 37 (7). Pp. 3151–3172. DOI: 10.17576/jkukm-2025-37(7)-06
30. Baniya S., Maity D. A comprehensive review of theoretical concepts and advancements in physics-informed neural networks with applications in structural engineering // *Artificial Intelligence Review.* 2025. Vol. 59. No. 49. DOI: 10.1007/s10462-025-11444-y

31. Varghese S., Anand R., Paliwal G. Physics-Informed Neural Network for Concrete Manufacturing Process Optimization // arXiv. 2025. Vol. 2408. P. 14502. DOI: 10.48550/arXiv.2408.14502
32. Sahin T., Wolff D., von Danwitz M., Popp A. Towards a Hybrid Digital Twin: Fusing Sensor Information and Physics in Surrogate Modeling of a Reinforced Concrete Beam // Proceedings of the 2024 Sensor Data Fusion: Trends, Solutions, Applications (SDF 2024). 2024. DOI: 10.1109/SDF63218.2024.10773885

REFERENCES

1. Zakharov F.N., Jie Q., Yi X. Physics-Informed Neural Networks for Structural Mechanics and Construction: Modeling the Deflection of a Single-Span Beam Physics-Informed Neural Networks. *Reinforced concrete structures*. 2025; 9(1):35-48. DOI: 10.22227/2949-1622.2025.1.35-48 (in Russian).
2. Breiman L. Random forests. *Mach Learn*. 2001; 45. DOI: 10.1023/A:1010933404324
3. Natekin A., Knoll A. Gradient boosting machines : a tutorial. *Front Neurorobot*. 2013; 7. DOI: 10.3389/fnbot.2013.00021
4. Cortes C., Vapnik V. Support-Vector Networks. *Mach Learn*. 1995; 20. DOI: 10.1023/A:1022627411411
5. Sayed Y.A.K., Alzhraa I.A., Tamrazyan A.G., Fahmy M.F.M. Machine-learning-based models versus design-oriented models for predicting the axial compressive load of FRP-confined rectangular RC columns. *Engineering Structures*. 2023; 285:116030. DOI: 10.1016/j.engstruct.2023.116030
6. Mustafa R., Ahmad M.T. Appraisal of numerous machine learning techniques for the prediction of axial load carrying capacity of rectangular concrete column. *Asian J Civ Eng*. 2024; 25:4471-4486. DOI: 10.1007/s42107-024-01060-6
7. Couto C., Tong Q., Gernay T. Predicting the Capacity of Thin-Walled Beams at Elevated Temperature with Machine Learning. *Fire Saf J*. 2022; 130. DOI: 10.1016/j.firesaf.2022.103596
8. Fu F. Fire Induced Progressive Collapse Potential Assessment of Steel Framed Buildings Using Machine Learning. *J Constr Steel Res*. 2020; 166. DOI: 10.1016/j.jcsr.2019.105918
9. Zhu Y.F., Yao Y., Huang Y., Chen C.H., Zhang H.Y., Huang Z. Machine Learning Applications for Assessment of Dynamic Progressive Collapse of Steel Moment Frames. *Structures*. 2022; 36. DOI: 10.1016/j.istruc.2021.12.067
10. Das O. Prediction of the Natural Frequencies of Various Beams Using Regression Machine Learning Models. *Sigma Journal of Engineering and Natural Sciences*. 2023; 41. DOI: 10.14744/sigma.2023.00040
11. Nshimirimana Zh.D., Elsheikh A.M. Automation of Reinforcement of Reinforced Concrete Structures Using Building Information Modeling and Visual Programming Technology. *Bulletin of Eurasian Science*. 2025; 17:2. URL: <https://esj.today/PDF/36SAVN225.pdf> (in Russian).
12. Fomin N.I., Isupov N.S. Assessment of the Quality of Arrangement of Load-Bearing Structures Using Generative Design Technology. *Bulletin of Eurasian Science*. 2024; 16:5. URL: <https://esj.today/PDF/54SAVN524.pdf> (in Russian).
13. Tahmassebi A., Motamedi M., Alavi A.H., Gandomi A.H. An explainable prediction framework for engineering problems: case studies in reinforced concrete members modeling. *Journal of Engineering Computations*. 2021. URL: https://opus.lib.uts.edu.au/bitstream/10453/167687/2/Engineering_Computations_RC_Failures_XGB_SHAP%20%281%29%20%281%29.pdf
14. Varghese S., Anand R., Paliwal G. Physics-Informed Neural Network for Concrete Manufacturing Process Optimization. *Computer Science. Machine Learning*. 2024. DOI: 10.48550/arXiv.2408.14502
15. Ke Y., Liu C.W., Zhang S.S. Physics-informed neural network (PINN)-based numerical simulation of concrete mechanical responses. *Engineering Structures*. 2026; 350:121982. DOI: 10.1016/j.engstruct.2025.121982
16. Qi Y., Ding Z., Luo Y., Ma Z. A Three-Step Computer Vision-Based Framework for Concrete Crack Detection and Dimensions Identification. *Buildings*. 2024; 14:2360. DOI: 10.3390/buildings14082360
17. Kong X., Smyl D. Investigation of the condominium building collapse in Surfside, Florida: A video feature tracking approach. *Structures*. 2022; 43:533-545. DOI: 10.1016/j.istruc.2022.06.009
18. Savin S.Yu., Sharipov M.Z. Nonlinear visco — elastic behavior of concrete under static-dynamic loading: Experimental and numerical studies. *Structures*. 2025; 74:108496.
19. Reklaitis G.V., Ravindran A., Ragsdell K.M. *Engineering Optimization: Methods and Applications*. John Wiley & Sons, 2006.
20. Pan X., Yang T.T.Y., Li J. et al. A review of recent advances in data-driven computer vision methods for structural damage evaluation: algorithms, applications, challenges, and future opportunities. *Arch Computat Methods Eng*. 2025; 32:4587-4619. DOI: 10.1007/s11831-025-10279-8
21. Song Y., Zhang Q., Su Y., Zhang S., Wang R., Zhang W., Bi Z., Yu Y. Advances in crack dataset development and deep learning-based detection models. *Journal of Building Engineering*. 2025; 116:114734.
22. Hassouna M., Marzouk M., Fathalla E. Automated low-cost framework for crack measurements in RC structures using deep learning approach. 2026; 14678. DOI: 10.1038/s41598-026-50880-w
23. Kemal H., Serhat D. Deep Learning–Based Automated Crack Detection for Post-Earthquake Damage Assessment in Reinforced Concrete Structures. *Advances in Civil Engineering*. 2026; 6845779. DOI: 10.1155/adce/6845779

24. Levin R., Drang D., Edelson B. *Practical Introduction to Artificial Intelligence and Expert Systems Technology with Illustrations in BASIC*. Translated from English. Preface by M.L. Salnikov, Yu.V. Salnikova. Moscow, Finansy i statistika, 1990; 239. (in Russian).
25. Fomin N.I., Isupov N.S. Assessment of the Quality of Arrangement of Load-Bearing Structures Using Generative Design Technology. *Vestnik evraziyskoy nauki (Bulletin of Eurasian Science)*. 2024; 16:5. URL: <https://esj.to-day/PDF/54SAVN524.pdf> (in Russian).
26. Rimshin V.I., Truntov P.S., Molchanova A.E. Methods of Applying Artificial Intelligence in Modeling the Stress-Strain State of Strengthened Structures. *Bulletin of the Volga State Technological University. Series "Materials. Structures. Technologies"*. 2023; 3(27):45-54. DOI: 10.25686/2542-114X.2023.3.45 (in Russian).
27. Li C. et al. Physics-Informed Gaussian Process Regression for the Constitutive Modeling of Concrete: A Data-Driven Improvement to Phenomenological Models. *arXiv*. Preprint, 2026. URL: <https://arxiv.org/abs/2601.03367>
28. Guo X., Song Zh. Review on crack monitoring technology based on physics-informed neural networks. *Jixie Qiangdu. (Mechanical Strength)*. 2025; 47:18-30. DOI: 10.16579/j.issn.1001.9669.2025.12.002
29. Saeed H.M. et al. Recent Advances of Machine Learning in Fracture Mechanics of Quasi-Brittle Materials : a Review. *Jurnal Kejuruteraan*. 2025; 37(7):3151-3172. DOI: 10.17576/jkukm-2025-37(7)-06
30. Baniya S., Maity D. A comprehensive review of theoretical concepts and advancements in physics-informed neural networks with applications in structural engineering. *Artificial Intelligence Review*. 2025; 59:49. DOI: 10.1007/s10462-025-11444-y
31. Varghese S., Anand R., Paliwal G. Physics-Informed Neural Network for Concrete Manufacturing Process Optimization. *arXiv*. 2025; 2408:14502. DOI: 10.48550/arXiv.2408.14502
32. Sahin T., Wolff D., von Danwitz M., Popp A. Towards a Hybrid Digital Twin: Fusing Sensor Information and Physics in Surrogate Modeling of a Reinforced Concrete Beam. *Proceedings of the 2024 Sensor Data Fusion: Trends, Solutions, Applications (SDF 2024)*. 2024. DOI: 10.1109/SDF63218.2024.10773885