

## Мировые тренды технологий машинного обучения для исследования железобетонных конструкций

*Н.С. Курченко*

*Национальный исследовательский Московский государственный строительный университет, г. Москва*

**Аннотация:** В статье приводится обзор и систематизация работ, посвященных применению машинного обучения для решения задач исследования, расчета и проектирования железобетонных конструкций. Рассматриваются апробированные актуальные на сегодняшний момент аспекты, связанные с расчетом, проектированием, а также оценкой технического состояния объектов с помощью различных подходов, реализующих схемы машинного обучения, в т.ч., глубинного обучения, ансамблевые алгоритмы. Показано, что в настоящее время в мировой строительной науке данная область стремительно развивается и совершенствуется. При этом алгоритмами машинного обучения решаются задачи предсказания проектных параметров, задачи идентификации тех или иных параметров, дефектов, повреждений на основе алгоритмов классификации и др. Приведенные в статье материалы позволят специалистам точнее выбрать предметную область исследования и определить направления адаптации и совершенствования собственных разработок в области машинного обучения.

**Ключевые слова:** машинное обучение, железобетонные конструкции, уравнения регрессии, идентификация, аппроксимация, искусственный интеллект

### **Введение.**

Машинное обучение сегодня - это динамично развивающаяся область искусственного интеллекта [1], включающая комплекс разнообразных математических моделей, позволяющих решать задачи поиска и прогнозирования на основе анализа и систематизации некоторого набора уже имеющихся данных. Такой подход представляется целесообразным, когда решение задачи прямым способом является сложным, требует прогноза во времени выявления аномалий, новизны и т.п. В целом для машинного обучения могут быть использованы методы математического анализа, статистики, оптимизации и др., в зависимости от конкретной задачи. Далее мы будем рассматривать преимущественно методы регрессионного анализа, эффективно применимые для решения задач, связанных с деформациями железобетонных конструкций.

---

В частном случае реализация технологии машинного обучения основана на аппроксимации данных некоторого сложного процесса уравнениями регрессии. Наиболее часто используются известные линейные уравнения регрессии вида  $Y_m = W_0 + \sum WX$ , для которых подбираются коэффициенты  $W$  при неизвестных  $X$ , в качестве неизвестных принимаются проектные параметры, свободный коэффициент  $W_0$  определяет начальное смещение данных,  $Y_m$  – это целевое значение, которое предсказывает модель. Точность подбора коэффициентов  $W$  оценивается так называемыми метриками качества, например  $MSE$  – среднеквадратичная ошибка. Считается, что при минимальных значениях  $MSE$ , модель в виде линейного уравнения наиболее точно описывает сложный процесс. По существу, это реализация давно известного метода наименьших квадратов. Для решения экстремальной задачи вида  $MSE \rightarrow \min$  в общем случае могут использоваться два подхода. Первый основан на получении точного решения для вектора-строки  $W$ , когда в аналитическом виде эти коэффициенты получаются из условия равенства нулю матричной производной от выражения  $(Y - WX)'$ , где  $Y$  это вектор значений исследуемого фактора, полученный при наблюдении за сложным процессом, либо в результате численного моделирования. Точное решение уравнения для определения коэффициентов  $W$  требует обращения матрицы разрешающей системы уравнений, получаемой на этапе обучения модели, что для больших матриц весьма затруднительно, а иногда обратных матриц не существует. Поэтому применяется второй подход, связанный с использованием эвристических методов оптимизации. Так для минимизации  $MSE$  или других метрик качества модели может использоваться метод градиентного спуска, методы роевого интеллекта (метод частиц, светлячков, серых волков и т.п.) генетические алгоритмы и другие эвристические подходы.

---

**Методы и материалы.** Для литературного обзора использованы современные источники из наукометрических баз Web of Science, Scopus, RSCI. В качестве поисковой системы использованы общедоступные инструменты ScienceDirect, Mendeley. Систематизация данных об использовании машинного обучения для железобетонных конструкций предлагается по таким тематическим разделам: исследование и проектирование, усиление, восстановление, мониторинг и диагностика дефектов, сейсмостойкость отдельных зданий и застройки и риск-анализ повреждений.

1. *Исследование и проектирование железобетонных конструкций.* В настоящее время для расчета и проектирования железобетонных конструкций имеется приемлемый для инженерного анализа аналитический аппарат в виде нормативной базы СП, а также существуют и совершенствуются программные комплексы конечно-элементного анализа. Машинное обучение используется преимущественно для сложных задач, например, таких, как анализ режимов продавливания, взрывные нагрузки, воздействия коррозии, механические удары, оценка прогрессирующего разрушения при авариях, исследование работы конструкций из новых высокопрочных бетонов и композитных материалов и др. Рассмотрим некоторые такие исследования. В работе [2] машинное обучение используется для предсказания несущей способности плоских плит при их разрушении от продавливания (punching shear). Применение алгоритмов машинного обучения по техникам «Gaussian Process Regression (GPR)» и «Support Vector Regression (SVR)» позволило довольно точно выполнять оценку несущей способности и параметров, влияющих на реализацию механизма разрушения плит. Результаты оценок сопоставлялись с нормами Eurocode 2. Исследования [3] посвящаются пожарной безопасности железобетонных плит. На основе машинного обучения по технологии

---

многослойного перцептрона (MLP) выявляются ключевые параметры пожара, влияющие на несущую способность. Исследовались процессы низкоскоростного удара падающим грузом на конструкции, подвергавшиеся воздействию огня. Прогнозы машинного обучения, предлагаемые в этой работе, используются при проектировании с учетом пожарной безопасности. Разработана модель машинного обучения [4] для анализа перемещений железобетонных колонн при взрывном воздействии. Для предсказания использовалась технология ансамбля деревьев, то есть, объединения отдельных деревьев решений, обученных отдельно, в единую модель. В качестве данных были использованы результаты экспериментов, аналитического и численного моделирования, изложенные в литературе. Разработанные авторами прогнозы могут использоваться для минимизации рисков ущерба при взрывах в зданиях. С целью развития практических методов проектирования железобетонных конструкций в работе [5] разработана методика получения упрощенных формул для моделирования процессов прогрессирующего разрушения железобетонных конструкций зданий. В основе этой методики лежит мультигенетическое программирование (MGGP), которое оперирует данными выборки из латинского гиперкуба. Такая выборка наиболее точно характеризует область значений для предсказываемых параметров и позволяет повышать точность прогнозов. В работе [6] исследуется несущая способность плит на продавливание. Этот вид разрушения является хрупким и затрудняет оценку сопротивляемости конструктивной системы прогрессирующему разрушению. В связи с этим остро стоит проблема предсказания прочности узловых соединений плиты и колонны. Для этих целей авторами на основе машинного обучения создано несколько эффективных моделей, включающих искусственную нейронную сеть (ANN), дерево решений (DT), градиентный бустинг (XGBoost), случайный лес (RF). Качество моделей оценивалось на

---

основе значений известных метрик MAE, RMSE,  $R^2$ . Для получения адекватных предсказаний авторам пришлось рассмотреть более  $10^6$  испытаний. Нормативные требования по обеспечению индекса надежности авторами были достигнуты. В работе [7] исследовались железобетонные панели при ударном нагружении. Ударные воздействия в этом случае сопровождаются очень сложным, нелинейным поведением конструкции. Поэтому получение экспериментальных данных является трудной задачей, в ряде случаев эти данные отличаются друг от друга. С целью некоторого обобщения данных и возможности их прогнозирования механизмов разрушения при ударе была разработана модель машинного обучения с использованием градиентного бустинга. Данная схема показала себя достаточно эффективно, однако точность прогноза из-за отличий в экспериментальных данных оказалась не очень высокой. В работе [8] исследуется проблема сохранности железобетонных конструкций в агрессивных (коррозионных) средах. В частности, экспериментальным путем оценивается коррозионный износ бетона (потеря массы при ускоренной коррозии) и снижение сцепления бетона и арматуры в результате испытаний образцов на выдергивание. Для установления неочевидной зависимости между износом и сцеплением авторами используется логистическая регрессия. Она позволяет классифицировать по величине сцепления является ли элемент коррозионно-поврежденным или нет, а также на основе детальной классификации можно установить и уровень этих коррозионных повреждений

С помощью машинного обучения [9] прогнозируется несущая способность диафрагм жесткости в сооружениях атомной промышленности, работающих на сдвиг (стен сдвига). При этом используется ансамблевый метод беггинга, позволяющий выполнить классификацию предельных состояний конструкции, которые наблюдаются при реализации механизма разрушения.

---

Авторы строят 4 модели обучения для таких состояний, как возникновение трещин, текучесть арматуры, раздробление бетона, полное разрушение. Полученные прогнозы могут помочь при диагностике и ремонте диафрагм, получивших повреждения. В работе [10] рассматривается использование машинного обучения совместно с алгоритмом оптимизации железобетонных рам на основе PSO. Алгоритм на основе самообучения повышает эффективность поиска решения с учетом одновременного удаления нескольких колонн. В качестве аварийных нагрузок используются сейсмические воздействия. В качестве данных для обучения используются результаты поисковой оптимизации. В данной статье [11] способами машинного обучения является гауссовский процесс (n-мерное нормальное распределение случайных величин с учетом времени), а также генеративно-сопоставительная нейросеть (GAN). Суть такой сети в том, специальный генератор создает некоторые выборки данных, а дискриминатор эти данные относит к тому или иному классу и проверяет их подлинность. При этом используются выборки действительных данных. С помощью такого подхода в работе определяются перемещения балок при действии взрывной нагрузки от удаленного источника, а также моделируются параметры рассматриваемой задачи. При этом в качестве материала использованы обычные фибробетоны (SFRC) высокопрочные (HSFRC) и сверхвысокопрочные (UHPC) фибробетоны, армированные стальными волокнами. Параметры фибробетона, армированного углепластиковыми волокнами изучалось в статье [12]. В качестве инструментов для определения коэффициента бокового сопротивления колонн, изготовленных из этого композита, при сейсмических воздействиях использовались три технологии. Это генетическое программирование, минимаксная вероятностная машинная регрессия, и глубокие нейронные сети. Параметрами, которые влияют на сопротивление композита является геометрия углепластиковых аппликаций в

---

виде оболочек и модули упругости бетона и углепластика. Авторами установлено, что две первых технологии являются эффективными для оценки бокового сопротивления прямоугольных и квадратных колонн. Работа [13] посвящается решению сложной задачи усиления существующих колонн сборными фибробетонными оболочками с заполнением пустот цементным раствором. Такие системы усиления позволяют повысить сейсмостойкость зданий за счет повышения сопротивления бетона за счет дополнительного его ограничения в горизонтальной плоскости при сжатии. Оптимизация параметров системы усиления выполняется с использованием генетического алгоритма, а отклик системы на сейсмическое воздействие прогнозируется с использованием искусственной нейронной сети. При этом, в качестве целевого уровня эффективности использовался минимум жесткости при обеспечении максимального значения коэффициента повышения прочности при ограничении поперечных деформаций бетона.

## 2. *Усиление, восстановление мониторинг и диагностика дефектов.*

Следует отметить, что задачи, возникающие при усилении или восстановлении несущей способности железобетонных конструкций очень сложны с точки зрения, как идентификации исходных данных, так и при принятии технических решений. Поэтому технологии искусственного интеллекта в этой области получают все большее развитие. Рассмотрим некоторые работы по ключевым направлениям. При решении задач реконструкции в ряде случаев используется технология ремонта поврежденного обычного бетона фибробетоном. При этом первостепенную важность приобретает адгезионная прочность слоев, сцепление ремонтного состава с основанием (существующим бетоном). Для исследования этого явления при различных параметрах проектирования выполнялся ряд экспериментов и численное моделирование. Для предсказания сцепления и

---



эффективности такого усиления при варьировании проектных параметров в работе [14] была разработана регрессионная модель машинного обучения. Следующей актуальной проблемой является усиление бетонных и железобетонных конструкций углепластиком. Усиленные таким образом конструкции имеют достаточно сложные механизмы деформирования и разрушения, что требует вместо очень сложных конечно-элементных расчетов и экспериментов создания упрощённых предсказательных моделей. Такими моделями в работе [15] являются нейронная сеть, эвристический алгоритм поисковой оптимизации на основе симуляции поведения пчелиной колонии и регрессия гауссовского процесса. С использованием моделей машинного обучения существенно упрощается предсказание прочностных и жесткостных характеристик усиливаемой конструкции. Для ремонта и реставрации строительных конструкций может использоваться цементный раствор, армированный волокнами, тайкой раствор может инъецироваться в отверстия или заполнять швы кладки из бетонных блоков. Расчет такой кладки представляет сложность из-за неопределенности сил сцепления и механических характеристик материалов. Прочность сцепления для такой задачи в [16] оценивалась несколькими широко используемыми моделями машинного обучения, среди которых наиболее эффективной оказалась регрессия гауссовского процесса. Работа [17] посвящена решению задач эффективного усиления конструкций углепластиковыми ламелями. Одним из важных вопросов при этом является обеспечение сцепления между аппликацией и усиливаемой конструкцией. Авторы утверждают, что при различных режимах разрушения процесс сцепления проблематично описать аналитически, поэтому предлагается использовать ансамблевое обучение. Две модели ансамблевого обучения (случайный лес и градиентное дерево решений) используются для предсказания прочности соединения углепластика с бетоном. Кроме того, проводилось сравнение методов

---



ансамблевого обучения с другими подходами. Разработанная модель по мнению авторов позволит облегчить проектирование усиливаемых таким способом систем. Машинное обучение эффективно используется для распознавания трещин в бетонных и железобетонных конструкциях. Такой подход связан с неточностью идентификации трещин или ошибками специалистов, выполняющих оценку состояния несущих систем зданий. В качестве обучающей выборки могут использоваться фотографии трещин, полученные в результате экспериментов для однозначно идентифицированного воздействия. Также могут быть использованы верифицированные данные других объектов. Типы деформаций, которые вызывают образование трещин определяются на основе моделей классификации. Так, например, в работе [18] путем классификации на основе метода опорных векторов со 100% точностью определялись трещины от изгиба, сдвига и сжатия. В работе [19] предлагается способ распознавания дефектов на поверхности стальных элементов. Это трещины, включения, пятна, углубления, царапины. Обнаружить комплексные дефекты позволяет модификация подходов, связанных с глубинным обучением, в частности с преобразованием обычной сверточной сети. Рассматривается вопрос мониторинга и оценки технического состояния мостов на основе совместного применения откалиброванной конечно-элементной модели, обновляющейся в зависимости от состояния условий окружающей среды и модели машинного обучения [20]. При изменениях состояния конструкции датчики передают информацию в конечно-элементную модель, которая оценивает НДС мостовой конструкции. Эти данные используются для обучения модели машинного обучения. Модель может прогнозировать состояние мостов и их разрушение и идентифицировать условия, в которых это может произойти.

Актуальной является задача оценки технического состояния конструкций после аварийных воздействий. С этой целью в [21] используется метод

---

опорных векторов и наивный Байесовский классификатор по типу Гаусса, нейронные сети. Осуществляется также и мониторинг состояния, связывающий жесткости и деформации системы с ее аварийными повреждениями. Алгоритм тестировался на шестиэтажном здании с деревянными рамами и каменными стенами, поврежденном локальной просадкой основания. При этом использовались натурные данные по деформациям, полученным от дополнительных нагрузочных испытаний. В работе [22] предлагается алгоритм для мониторинга и оценки технического состояния высотных зданий. По результатам опроса датчиков записанные сигналы проходят преобразование Фурье, а затем с помощью вейвлет-преобразования очищаются от шума и передаются в качестве исходных данных в работу нейронной сети. Нейронная сеть извлекает из сигналов признаки, которые в дальнейшем классифицируются. Классификация относится к повреждениям и включает несколько их типов: легкие, умеренные и разрушение. Метод сравнивается с другими классификационными моделями, в частности, процессом поиска ближайших соседей, вероятностной нейронной сетью. С целью повышения эффективности мониторинга повреждений несущих конструкций, их иерархической классификации [23] были проанализированы источники данных за последние 10 лет, при этом наибольшую точность и производительность показали методы искусственных и конволюционных нейросетей а также метод опорных векторов.

3. *Сейсмостойкость отдельных зданий и застройки и риск-анализ повреждений.* Достоверное прогнозирование сейсмических повреждений зданий и застройки позволит экономии инвестиций в масштабах страны и сможет превентивно сохранить тысячи человеческих жизней. Именно поэтому во многих странах мира проводятся исследования, в которых инструментом такого прогнозирования является искусственный интеллект. В

---

некоторых странах машинное обучение используется совместно с технологией цифровых двойников [24] при мониторинге отдельных конструкций на этапе эксплуатации. С помощью такого подхода могут моделироваться аварийные воздействия, например удары и сейсмические колебания, воздействующие на преднапряженные стальные конструкции. Такой подход позволяет снижать риск значительных социально-экономических потерь. В практике проектирования железобетонных зданий и сооружений на сейсмические воздействия актуальным является вопрос учета взаимодействия с грунтом при колебаниях. Наличие грунта существенно влияет на частоты собственных колебаний, в т.ч., на основную частоту, которая вносит в деформирование наибольший вклад. Однако точных аналитических формул для описания этого процесса еще нет. В связи с этим возникает потребность в прогнозировании частот колебаний, что решается в работе [25] путем использования регрессионных моделей в виде полиномов высших порядков. Разработана методика оценки рисков сейсмического разрушения на основе современных наиболее часто используемых технологий машинного обучения. Обучающие данные при этом содержали более миллиона точек данных [26]. Использование моделей прогнозирования сейсмических рисков оказалось менее трудоемким, чем методика прямого построения кривых хрупкости. Эти кривые показывают вероятность достижения (превышения) при сейсмическом воздействии порога повреждений, определяемого из условий безопасности здания. Помимо проектирования сейсмостойких зданий одной из важнейших задач является оценка их технического состояния после землетрясения [27]. Для исключения субъективного человеческого фактора при обследовании железобетонных зданий и оценки их повреждений после землетрясения используется подход, основанный на совместном применении алгоритмов компьютерного зрения (задача распознавания образов) и глубинного

---

обучения (нейронной сети). Результаты показали точность прогнозов и фактического сейсмического ущерба на уровне не менее 98%. Кроме процессов прогнозирования компонентов НДС железобетонных конструкций с помощью современных информационных технологий, основанных на аффинных преобразованиях и алгоритмах тесселяции Вороного, авторы работы [28] представили алгоритм для быстрой оценки области разрушений. Эта область позволяет принимать решения по градостроительному планированию территорий и зависит от уровня начальных разрушений конструкции. Методика тестировалась на основе конечно-элементной модели. Для сейсмического анализа зданий используются комбинированные методы, включающие совместное использование моделей машинного обучения и процедур численного интегрирования по времени в рамках МКЭ. Один из таких методов [29] предполагает на основе предсказаний формирование функций отклика сейсмоизоляторов (кривых гистерезиса) с зависимостью от деформации и скорости воздействия. Преимущество такого метода состоит в возможности ускоренного расчета на сейсмические воздействия односторонних конструктивных систем и параметров сейсмоизоляторов, для которых было выполнено обучение. В [30] также рассматривается применение машинного обучения при проектировании зданий в сейсмоопасных районах. Причина использования нейронных сетей – это дороговизна программного обеспечения, большое время анализа, сложность моделирования и получения данных для системы грунт-здание. Разработанная нейронная сеть учитывает взаимодействие основания и сооружения и обучена на зданиях малой этажности (3-5 этажей). Отмечается, что нейронные сети показывают лучшие результаты по сравнению с аналитическими расчетами при неподвижном грунтовом основании. Оценка риска повреждений при сейсмических воздействиях была изучена в [31] также и для деревянных зданий. Первый подход, основан на

---

инкрементальном анализе, который предполагают для оценки риска сейсмических воздействий построение кривых хрупкости. Второй на использовании многослойного перцептрона (вид искусственной нейронной сети). Результаты расчетов и предсказаний для малых повреждений оказались практически идентичными, однако для средних и больших повреждений многослойный перцептрон показал лучшие результаты. Кроме этого полученная модель обладает очень высокой производительностью.

Работа [32] посвящается оценке сейсмического риска уже существующих зданий. Отмечается, что большое число зданий в различных странах мира, например в Турции, подвержено значительному сейсмическому риску полного разрушения. При этом рассматриваются здания из железобетона. Быстрая оценка сейсмического риска полного или частичного разрушения в таких условиях очень актуальна. Разработанный для этих целей алгоритм машинного обучения на основе ансамблевого метода случайного леса с перекрестной  $k$ -кратной валидацией показал свою высокую эффективность. Выполнен также анализ наиболее существенных признаков, влияющих на сейсмостойкость. Это возраст здания, прочность бетона на сжатие, максимальное расстояние между колоннами, предел текучести стали и наличие коррозионных повреждений бетона и арматуры.

В завершение отметим, что существует целый ряд смежных направлений, связанных с железобетонными конструкциями, где начинает активно использоваться искусственный интеллект. Это, например, строительные материалы, проектирование узловых соединений конструкций, прогнозирование надежности и долговечности зданий, информационное моделирование, моделирование динамических воздействий и т.п. Также следует сказать, что все эти направления получают развитие и в работах отечественных исследователей. Например, в задачах прочности железобетонных балок [33], идентификации деформированного состояния

---

пластин [34] и стержней [35], оценке дефектов и повреждений [36, 37], оценке работоспособности конструктивных элементов [38].

### **Выводы**

1. Выполнен краткий литературный обзор использования машинного обучения и других технологий искусственного интеллекта с целью решения прикладных задач, связанных с расчетом, проектированием, строительством, эксплуатацией и реконструкцией зданий из железобетона.

2. Установлено, что данное направление эффективно используется для прогнозирования сложных комплексных процессов, которые трудно описать системой аналитических уравнений.

3. В большинстве работ наиболее эффективно показали себя методы ансамблевого обучения, в частности, искусственная нейронная сеть, случайный лес, метод опорных векторов, а также сочетание машинного обучения с методами стохастической поисковой оптимизации.

4. Разрозненные данные по методам обучения и решаемым задачам требуют дополнительной классификации с целью упрощения выбора того или иного метода при постановке и решении новых исследовательских задач.

### **Литература**

1. Bensoussan, A.; Li, Y.; Nguyen, D.P.C.; Tran, M.B.; Yam, S.C.P.; Zhou, X. Machine Learning and Control Theory. Handbook of Numerical Analysis 2022, 23, doi: 10.1016/bs.hna.2021.12.016.

2. Mellios, N.; Uz, O.; Spyridis, P. Data-Based Modeling of the Punching Shear Capacity of Concrete Structures. Eng Struct 2023, 275, doi: 10.1016/j.engstruct.2022.115195.

3. Daneshvar, K.; Moradi, M.J.; Khaleghi, M.; Rezaei, M.; Farhangi, V.; Hajiloo, H. Effects of Impact Loads on Heated-and-Cooled Reinforced Concrete Slabs. Journal of Building Engineering 2022, 61, doi: 10.1016/j.jobbe.2022.105328.

4. Almustafa, M.K.; Nehdi, M.L. Machine Learning Model for Predicting Structural Response of RC Columns Subjected to Blast Loading. *Int J Impact Eng* 2022, 162, doi: 10.1016/j.ijimpeng.2021.104145.
  5. Lin, K.; Li, D.; Xie, L.; He, M.; Sun, Y. Analytical Model for Progressive Collapse of RC Frame Beam-Column Substructures Using Multi-Gene Genetic Programming. *International Journal of Structural Stability and Dynamics* 2023, 23, doi: 10.1142/S021945542350150X.
  6. Shen, L.; Shen, Y.; Liang, S. Reliability Analysis of RC Slab-Column Joints under Punching Shear Load Using a Machine Learning-Based Surrogate Model. *Buildings* 2022, 12, doi: 10.3390/buildings12101750.
  7. Thai, D.K.; Tu, T.M.; Bui, T.Q.; Bui, T.T. Gradient Tree Boosting Machine Learning on Predicting the Failure Modes of the RC Panels under Impact Loads. *Eng Comput* 2021, 37, doi: 10.1007/s00366-019-00842-w.
  8. Almashakbeh, Y. Integrating experimental analysis and machine learning for assessing bond performance and corrosion severity in reinforced concrete structures. *Journal of Applied Engineering Science* 2023, 21, doi: 10.5937/jaes0-44247.
  9. Ju, B.S.; Kwag, S.; Lee, S. Performance-Based Drift Prediction of Reinforced Concrete Shear Wall Using Bagging Ensemble Method. *Nuclear Engineering and Technology* 2023, 55, doi: 10.1016/j.net.2023.05.008.
  10. Esfandiari, M.J.; Haghghi, H.; Urgessa, G. Machine Learning-Based Optimum Reinforced Concrete Design for Progressive Collapse. *Electronic Journal of Structural Engineering* 2023, 23, doi: 10.56748/EJSE.233642.
  11. Almustafa, M.K.; Nehdi, M.L. Machine Learning Prediction of Structural Response of Steel Fiber-Reinforced Concrete Beams Subjected to Far-Field Blast Loading. *Cem Concr Compos* 2022, 126, doi: 10.1016/j.cemconcomp.2021.104378.
-



12. Xue, X.; Makota, C.; Khalaf, O.I.; Jayabalan, J.; Samui, P.; Abdulsahib, G.M. Machine Learning Approach for Prediction of Lateral Confinement Coefficient of CFRP-Wrapped RC Columns. *Symmetry (Basel)* 2023, 15, doi: 10.3390/sym15020545.

13. Shin, J.; Park, S. Optimum Retrofit Strategy of FRP Column Jacketing System for Non-Ductile RC Building Frames Using Artificial Neural Network and Genetic Algorithm Hybrid Approach. *Journal of Building Engineering* 2022, 57, doi: 10.1016/j.jobbe.2022.104919.

14. Jiao, P.; Roy, M.; Barri, K.; Zhu, R.; Ray, I.; Alavi, A.H. High-Performance Fiber Reinforced Concrete as a Repairing Material to Normal Concrete Structures: Experiments, Numerical Simulations and a Machine Learning-Based Prediction Model. *Constr Build Mater* 2019, 223, doi: 10.1016/j.conbuildmat.2019.07.312.

15. Kumar, A.; Arora, H.C.; Mohammed, M.A.; Kumar, K.; Nedoma, J. An Optimized Neuro-Bee Algorithm Approach to Predict the FRP-Concrete Bond Strength of RC Beams. *IEEE Access* 2022, 10, doi: 10.1109/ACCESS.2021.3140046.

16. Kumar, A.; Arora, H.C.; Kumar, K.; Mohammed, M.A.; Majumdar, A.; Khamaksorn, A.; Thinnukool, O. Prediction of FRCM–Concrete Bond Strength with Machine Learning Approach. *Sustainability (Switzerland)* 2022, 14, doi: 10.3390/su14020845.

17. Chen, S.Z.; Feng, D.C.; Han, W.S.; Wu, G. Development of Data-Driven Prediction Model for CFRP-Steel Bond Strength by Implementing Ensemble Learning Algorithms. *Constr Build Mater* 2021, 303, doi: 10.1016/j.conbuildmat.2021.124470.

18. Aravind, N.; Nagajothi, S.; Elavenil, S. Machine Learning Model for Predicting the Crack Detection and Pattern Recognition of Geopolymer Concrete Beams. *Constr Build Mater* 2021, 297, doi: 10.1016/j.conbuildmat.2021.123785.

---

19. Zhao, W.; Chen, F.; Huang, H.; Li, D.; Cheng, W. A New Steel Defect Detection Algorithm Based on Deep Learning. *Comput Intell Neurosci* 2021, 2021, doi: 10.1155/2021/5592878.

20. Svendsen, B.T.; Øiseth, O.; Frøseth, G.T.; Rønquist, A. A Hybrid Structural Health Monitoring Approach for Damage Detection in Steel Bridges under Simulated Environmental Conditions Using Numerical and Experimental Data. *Struct Health Monit* 2023, 22, doi: 10.1177/14759217221098998.

21. Nazarian, E.; Taylor, T.; Weifeng, T.; Ansari, F. Machine-Learning-Based Approach for Post Event Assessment of Damage in a Turn-of-the-Century Building Structure. *J Civ Struct Health Monit* 2018, 8, doi: 10.1007/s13349-018-0275-6.

22. Rafiei, M.H.; Adeli, H. A Novel Machine Learning-Based Algorithm to Detect Damage in High-Rise Building Structures. *Structural Design of Tall and Special Buildings* 2017, 26, doi: 10.1002/tal.1400.

23. Gomez-Cabrera, A.; Escamilla-Ambrosio, P.J. Review of Machine-Learning Techniques Applied to Structural Health Monitoring Systems for Building and Bridge Structures. *Applied Sciences (Switzerland)* 2022, 12, doi: 10.3390/app122110754

24. Liu, Z.; Yuan, C.; Sun, Z.; Cao, C. Digital Twins-Based Impact Response Prediction of Prestressed Steel Structure. *Sensors* 2022, 22, doi: 10.3390/s22041647.

25. Gravett, D.Z.; Mourlas, C.; Taljaard, V.L.; Bakas, N.; Markou, G.; Papadrakakis, M. New Fundamental Period Formulae for Soil-Reinforced Concrete Structures Interaction Using Machine Learning Algorithms and ANNs. *Soil Dynamics and Earthquake Engineering* 2021, 144, doi: 10.1016/j.soildyn.2021.106656.

26. Kazemi, F.; Asgarkhani, N.; Jankowski, R. Machine Learning-Based Seismic Fragility and Seismic Vulnerability Assessment of Reinforced Concrete

---

Structures. Soil Dynamics and Earthquake Engineering 2023, 166, doi: 10.1016/j.soildyn.2023.107761.

27. Xu, Y.; Li, Y.; Zheng, X.; Zheng, X.; Zhang, Q. Computer-Vision and Machine-Learning-Based Seismic Damage Assessment of Reinforced Concrete Structures. Buildings 2023, 13, doi: 10.3390/buildings13051258.

28. Wang, S.; Cheng, X.; Li, Y.; Song, X.; Guo, R.; Zhang, H.; Liang, Z. Rapid Visual Simulation of the Progressive Collapse of Regular Reinforced Concrete Frame Structures Based on Machine Learning and Physics Engine. Eng Struct 2023, 286, doi: 10.1016/j.engstruct.2023.116129.

29. Mekaoui, N.; Saito, T. A Deep Learning-Based Integration Method for Hybrid Seismic Analysis of Building Structures: Numerical Validation. Applied Sciences (Switzerland) 2022, 12, doi: 10.3390/app12073266.

30. Ali, T.; Eldin, M.N.; Haider, W. The Effect of Soil-Structure Interaction on the Seismic Response of Structures Using Machine Learning, Finite Element Modeling and ASCE 7-16 Methods. Sensors 2023, 23, doi: 10.3390/s23042047.

31. Yuan, X.; Li, L.; Zhang, H.; Zhu, Y.; Chen, G.; Dagli, C. Machine Learning-Based Seismic Damage Assessment of Residential Buildings Considering Multiple Earthquake and Structure Uncertainties. Nat Hazards Rev 2023, 24, doi: 10.1061/nhrefo.nheng-1681.

32. Cosgun, C. Machine Learning for the Prediction of Evaluation of Existing Reinforced Concrete Structures Performance against Earthquakes. Structures 2023, 50, doi: 10.1016/j.istruc.2023.02.127.

33. Усанов С.В., Тамов М.М., Руденко О.В. Нейросетевое прогнозирование сопротивления поперечной силе армированных бетонных двутавровых балок // Вестник МГСУ. – 2022. – №9. – с. 1145–1159.

34. Морковин А.В., Вейна В.С. Разработка методики решения задач прогнозирования деформированной формы пластины под действием

---

нагрузки при помощи нейронных сетей. // Вестник Инженерной школы Дальневосточного федерального университета. 2022. № 3 (52). С. 3-11.

35. Курченко Н.С., Алексейцев А.В. Идентификация силовых воздействий на несущую систему с использованием нейросетевых технологий. // Инженерный вестник Дона. 2023. № 9. URL: ivdon.ru/ru/magazine/archive/n9y2023/8656.

36. Русаков К.Д., Чехов А.В. Двухэтапный подход к распознаванию коррозии металлических конструкций с использованием сверточных нейронных сетей в ходе проведения инспекций промышленных объектов // Известия Юго-Западного государственного университета. 2021. Т. 25. № 3. С. 152-166.

37. Акимов Д.А., Клейменов А.Д., Козельская С.О., Будадин О.Н. Новый подход к оценке эксплуатационной безопасности композитных материалов и деталей сложной конструкции на основе методов искусственного интеллекта на базе глубоких нейронных сетей и результатов многокритериального комплексного неразрушающего контроля. // Контроль. Диагностика. 2020. № 7. С. 18-27.

38. Красонцев Н.А., Ляпин А.А. Нейронная сеть глубокого обучения для исследования работоспособности элементов конструкции. // Вестник науки. 2018. Т. 2. № 9 (9). С. 230-232.

### References

1. Bensoussan, A.; Li, Y.; Nguyen, D.P.C.; Tran, M.B.; Yam, S.C.P.; Zhou, X. Machine Learning and Control Theory. Handbook of Numerical Analysis 2022, 23, doi: 10.1016/bs.hna.2021.12.016

2. Mellios, N.; Uz, O.; Spyridis, P. Eng. Struct. 2023, 275, doi: 10.1016/j.engstruct.2022.115195.

3. Daneshvar, K.; Moradi, M.J.; Khaleghi, M.; Rezaei, M.; Farhangi, V.; Hajiloo, H. *Journal of Building Engineering* 2022, 61, doi: 10.1016/j.jobe.2022.105328.
  4. Almustafa, M.K.; Nehdi, M.L. *Int. J. Impact Eng.* 2022, 162, doi: 10.1016/j.ijimpeng.2021.104145.
  5. Lin, K.; Li, D.; Xie, L.; He, M.; Sun, Y. *International Journal of Structural Stability and Dynamics* 2023, 23, doi: 10.1142/S021945542350150X.
  6. Shen, L.; Shen, Y.; Liang, S. *Buildings* 2022, 12, doi: 10.3390/buildings12101750.
  7. Thai, D.K.; Tu, T.M.; Bui, T.Q.; Bui, T.T. *Eng Comput* 2021, 37, doi: 10.1007/s00366-019-00842-w.
  8. Almashakbeh, Y. *Journal of Applied Engineering Science* 2023, 21, doi: 10.5937/jaes0-44247.
  9. Ju, B.S.; Kwag, S.; Lee, S. *Nuclear Engineering and Technology* 2023, 55, doi: 10.1016/j.net.2023.05.008.
  10. Esfandiari, M.J.; Haghighi, H.; Urgessa, G. *Electronic Journal of Structural Engineering* 2023, 23, doi: 10.56748/EJSE.233642.
  11. Almustafa, M.K.; Nehdi, M.L. *Cem Concr Compos* 2022, 126, doi: 10.1016/j.cemconcomp.2021.104378.
  12. Xue, X.; Makota, C.; Khalaf, O.I.; Jayabalan, J.; Samui, P.; Abdulsahib, G.M. *Symmetry (Basel)* 2023, 15, doi: 10.3390/sym15020545.
  13. Shin, J.; Park, S. *Journal of Building Engineering* 2022, 57, doi: 10.1016/j.jobe.2022.104919.
  14. Jiao, P.; Roy, M.; Barri, K.; Zhu, R.; Ray, I.; Alavi, A.H. *Constr Build Mater* 2019, 223, doi: 10.1016/j.conbuildmat.2019.07.312.
  15. Kumar, A.; Arora, H.C.; Mohammed, M.A.; Kumar, K.; Nedoma, J. *IEEE Access* 2022, 10, doi: 10.1109/ACCESS.2021.3140046.
-

16. Kumar, A.; Arora, H.C.; Kumar, K.; Mohammed, M.A.; Majumdar, A.; Khamaksorn, A.; Thinnukool, O. Sustainability (Switzerland) 2022, 14, doi: 10.3390/su14020845.
  17. Chen, S.Z.; Feng, D.C.; Han, W.S.; Wu, G. Constr Build Mater 2021, 303, doi: 10.1016/j.conbuildmat.2021.124470.
  18. Aravind, N.; Nagajothi, S.; Elavenil, S. Constr Build Mater 2021, 297, doi: 10.1016/j.conbuildmat.2021.123785.
  19. Zhao, W.; Chen, F.; Huang, H.; Li, D.; Cheng, W. Comput Intell Neurosci 2021, 2021, doi: 10.1155/2021/5592878.
  20. Svendsen, B.T.; Øiseth, O.; Frøseth, G.T.; Rønnquist, A. A Struct Health Monit 2023, 22, doi: 10.1177/14759217221098998.
  21. Nazarian, E.; Taylor, T.; Weifeng, T.; Ansari, F. J Civ Struct Health Monit 2018, 8, doi: 10.1007/s13349-018-0275-6.
  22. Rafiei, M.H.; Adeli, H. A Novel Machine Learning-Based Structural Design of Tall and Special Buildings 2017, 26, doi: 10.1002/tal.1400.
  23. Gomez-Cabrera, A.; Escamilla-Ambrosio, P.J. Applied Sciences (Switzerland) 2022, 12, doi: 10.3390/app122110754
  24. Liu, Z.; Yuan, C.; Sun, Z.; Cao, C. Sensors 2022, 22, doi: 10.3390/s22041647.
  25. Gravett, D.Z.; Mourlas, C.; Taljaard, V.L.; Bakas, N.; Markou, G.; Papadrakakis, M. Soil Dynamics and Earthquake Engineering 2021, 144, doi: 10.1016/j.soildyn.2021.106656.
  26. Kazemi, F.; Asgarkhani, N.; Jankowski, R. Soil Dynamics and Earthquake Engineering 2023, 166, doi: 10.1016/j.soildyn.2023.107761.
  27. Xu, Y.; Li, Y.; Zheng, X.; Zheng, X.; Zhang, Q. Buildings 2023, 13, doi: 10.3390/buildings13051258.
  28. Wang, S.; Cheng, X.; Li, Y.; Song, X.; Guo, R.; Zhang, H.; Liang, Z. Eng Struct 2023, 286, doi: 10.1016/j.engstruct.2023.116129.
-



29. Mekaoui, N.; Saito, T. A Applied Sciences (Switzerland) 2022, 12, doi: 10.3390/app12073266.

30. Ali, T.; Eldin, M.N.; Haider, W. Sensors 2023, 23, doi: 10.3390/s23042047.

31. Yuan, X.; Li, L.; Zhang, H.; Zhu, Y.; Chen, G.; Dagli, C. Nat Hazards Rev 2023, 24, doi: 10.1061/nhrefo.nheng-1681.

32. Cosgun, C. Structures 2023, 50, doi: 10.1016/j.istruc.2023.02.127.

33. Usanov S.V., Tamov M.M., Rudenko O.V. Vestnik MGSU. 2022. №9. pp. 1145-1159.

34. Morkovin A.V., Veina V.S. Vestnik Inzhenernoj shkoly Dal'nevostochnogo federal'nogo universiteta. 2022. № 3 (52). pp. 3-11.

35. Kurchenko N.S., Alekseyev A.V. Inzhenernyj vestnik Dona. 2023. № 9. URL: ivdon.ru/ru/magazine/archive/n9y2023/8656.

36. Rusakov K.D., Chekhov A.V. Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. 2021. T. 25. № 3. pp. 152-166.

37. Akimov D.A., Kleimenov A.D., Kozelskaya S.O., Budadin O.N. Kontrol'. Diagnostika.. 2020. № 7. pp. 18-27.

38. Krasontsev N.A., Lyapin A.A. Vestnik nauki. 2018. T. 2. № 9 (9). pp. 230-232.

**Дата поступления: 23.06.2024**

**Дата публикации: 10.08.2024**