

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И ТЕЛЕКОММУНИКАЦИИ
INFORMATION TECHNOLOGY AND TELECOMMUNICATIONS

УДК 69.059.4



DOI: 10.21822/2073-6185-2025-52-3-61-70

Оригинальная статья /Original article

**Автоматизация процесса оценки технического состояния наружных стен
кирпичных зданий с использованием технологии машинного обучения**

С.А. Крылов, Г.Г. Кашеварова

Пермский национальный исследовательский политехнический университет,
614990, г. Пермь, Комсомольский проспект, д. 29, Россия

Резюме. Цель. Целью работы является разработка программы по определению категории технического состояния зданий с использованием машинного обучения. Задачи работы заключаются в анализе существующих методов машинного обучения, написании кода программы, сборе обучающего набора данных, определение оптимального соотношения параметров обучения, определение наиболее точного алгоритма машинного обучения при заданных параметрах и исходных данных. **Метод.** Исследование основано на методах и алгоритмах диагностирования состояния технических систем с использованием технологии машинного обучения. **Результат.** Результаты исследования показывают, что даже при ограниченном объеме данных программа способна корректно и с высокой точностью определять категории технического состояния, минимизируя риск пропуска аварийных ситуаций, а также подтверждает перспективность применения машинного обучения в строительной диагностике. **Вывод.** Значимость полученных результатов для строительной отрасли состоит в том, что применение созданной программы позволит увеличить точность и скорость обследования зданий, что в свою очередь повысит их безопасность.

Ключевые слова: алгоритм, здание, категория, машинное обучение, техническое состояние

Для цитирования: С.А. Крылов, Г.Г. Кашеварова. Автоматизация процесса оценки технического состояния наружных стен кирпичных зданий с использованием технологии машинного обучения. Вестник Дагестанского государственного технического университета. Технические науки. 2025;52(3):61-70. DOI:10.21822/2073-6185-2025-52-3-61-70

**Automating the Process of Assessing the Technical Condition of Exterior Walls of Brick
Buildings Using Machine Learning**

S.A. Krylov, G.G. Kashevarova

Perm National Research Polytechnic University,
29 Komsomolsky Ave., Perm 614990, Russia

Abstract. Objective. The aim of this study is to develop a program for determining the technical condition of buildings using machine learning. The objectives of the study include analyzing existing machine learning methods, writing program code, collecting a training dataset, determining the optimal ratio of training parameters, and determining the most accurate machine learning algorithm for the given parameters and input data. **Method.** The study is based on methods and algorithms for diagnosing the condition of technical systems using machine learning technology. **Result.** The results demonstrate that even with a limited amount of data, the program is capable of correctly and accurately determining technical condition categories, minimizing the risk of missing emergency situations, and also confirms the potential of using machine learning in construction diagnostics. **Conclusion.** The significance of the obtained results for the construction industry is that the use of the developed program will increase the accuracy and speed of building inspections, which in turn will improve their safety.

Keywords: algorithm, building, category, machine learning, technical condition

For citation: S.A. Krylov, G.G. Kashevarova. Automating the Process of Assessing the Technical Condition of Exterior Walls of Brick Buildings Using Machine Learning. Herald of

Введение. Повышение конструктивной безопасности – одно из приоритетных направлений комплексной безопасности зданий и сооружений РФ. Техническое обследование жилых и общественных зданий требует обширных знаний, зависит от опыта экспертов и является одной из сложнейших задач в строительной отрасли.

В настоящее время процедура оценки технического состояния строительных конструкций, которая заключается в определении их категории технического состояния, а также принятие решений о дальнейшей эксплуатации, ремонте или усилении, как правило выполняется без использования автоматизированных систем [1]. Это влечет повышенные затраты времени и усилий. При этом в российском строительном секторе наблюдается значительная нехватка кадров, достигающая, по различным оценкам, от 10 до 25 %, что также сказывается на сроках и стоимости работ по обследованию зданий.

Все вышесказанное приводит к снижению срока эксплуатации зданий, так как отсутствие регулярного мониторинга приводит к тому, что дефекты остаются незамеченными пока не достигнут критического значения. Это затрудняет планирование ремонтно-восстановительных работ и профилактических мероприятий [2].

Одна из основных задач строительной сферы заключается в выполнении мониторинга существующей застройки, чтобы минимизировать или полностью исключить пребывание людей в аварийных зданиях.

Статья посвящена рассмотрению процесса автоматизации обследования зданий, заключающегося в определении категории технического состояния наружных стен кирпичных зданий, как наиболее массовых зданий на территории страны [3, 4]. Учитывая широкое распространение искусственного интеллекта в различные области, его способность запоминать, извлекать знания и обучаться на имеющихся данных, авторами принято решение использовать машинное обучение (направление в искусственном интеллекте) для автоматизации процесса оценки технического состояния фасадов зданий.

Искусственный интеллект (ИИ) - это искусственная система, имитирующая решение человеком сложных задач в процессе его жизнедеятельности, традиционно требующие человеческого интеллекта, такие как распознавание образов, принятие решений и прогнозирование.

Одним из основных направлений искусственного интеллекта является машинное обучение (machine learning, ML) - это совокупность методов искусственного интеллекта, с помощью которых можно создавать самообучающиеся компьютерные системы (в частности, нейронные сети).

В отличие от традиционных методов, где разработчик задает правила, в машинном обучении система самостоятельно выявляет закономерности на основе предоставленных исходных данных и заданных критериев оптимизации.

Искусственные нейронные сети (ИНС) - это один из наиболее распространенных подходов в машинном обучении, архитектура которых построена по принципу организации и функционирования биологических нейронных сетей [5]. Они эффективны для распознавания образов, обработки естественного языка и других сложных задач.

Анализ научных публикаций показывает, что в 2000–2024 гг. проведено значительное количество исследований, связанных с автоматизацией определения категории технического состояния как зданий, так и конструкций:

- Соколов В.А. разработал подход по определению технического состояния конструкций и зданий в целом, основанный на теоретическом аппарате технической диагностики, который использует вероятностные методы распознавания состояний сложных технических систем. Диагностирование выполняется статистическим методом с применением обобщенной формулы Байеса [6, 7].

- Штовба С.Д. и Панкевич О.Д. создали экспертную систему (модель принятия решений) для определения причины появления трещин в кирпичных стенах по результатам визуального обследования на основе теории нечетких множеств (нечетких правил). Принятие решения о техническом состоянии выполняется на основании 42 входных признака и нечетких баз знаний, которые содержат 151 правило [8].
- Солдатенко Т.Н. в своей работе показал возможность применения аппарата теории нечетких множеств как для идентификации, так и для прогноза дефектов кирпичных стен [9].
- Тонков Ю.Л. разработал математическую модель для определения категории технического состояния строительных конструкций, а также на ее основе интеллектуальную экспертную систему [10], [11].
- Тарарушкин Е.В. разработал математическую модель на базе теории нечеткой логики, которая позволяет определять показатель физического износа несущих конструкций и здания при проведении технического обследования. Физический износ рассчитывается по схеме Мамдани в зависимости от степени повреждения конструкции и уровня профессионализма инженера-обследователя. [12].
- Платунов В.Ю. предложил определять категорию технического состояния строительных конструкций и назначать ремонтные мероприятия с помощью нейронной сети полносвязной с двумя скрытыми слоями [13].
- Mani Amrouni Hosseini и др. разработали нейросетевую модель по определению мероприятий по техническому обслуживанию, аренды и ремонта на основании данных осмотра зданий и созданной BIM-модели [14]. А также они создали автоматизированный метод категоризации стен зданий по пяти техническим состояниям. Для определения категории применили алгоритм на основе нечеткой логики [15].
- Mohammad Reza Amiri Shahmirani и др. разработали модель на базе нечеткой логики по оценке степени повреждений городских построек в будущем землетрясении в зависимости от возраста, конструктива, объемно-планировочного решения, высоты зданий, расстояния до разлома и других параметров. Для обучения модели использовались полевые данные 527 зданий [16], [17].

Как следует из анализа научной литературы, применение методов машинного обучения для решения подобных задач отмечалось лишь в нескольких случаях. Это связано с тем, что более широкое применение данная технология получили только с 2006г.

Постановка задачи. Цель настоящего исследования заключается в оценке возможности применения методов машинного обучения для прогнозирования категории технического состояния и разработке программы для определения категории технического состояния зданий и сооружений.

Задачи исследования:

1. Анализ существующих методов машинного обучения и выбор наиболее рационального алгоритма для определения категории технического состояния наружных стен кирпичных зданий.
2. Написание программы по определению категории технического состояния наружных стен кирпичных зданий.
3. Определение наиболее оптимального соотношения параметров обучения.
4. Сравнение точности и скорости работы программы на практике при использовании различных алгоритмов машинного обучения при заданных параметрах и исходных данных.

Методы исследования. Для создания обучающей выборки были использованы результаты обследований различных кирпичных зданий. Кирпичные многоэтажные здания были выбраны как наиболее изученные и массовые здания на территории страны. Для увеличения объема обучающей выборки каждый фасад здания рассматривался отдельно. Также для удобства дальнейшего использования разработанной программы фасад здания разбивается на элементы с характерными дефектами (признаками): цоколь;

основное поле стены; опорная зона перемычек и сами перемычки.

В качестве входных учитывались 18 признаков наружных стен, которые влияют на категорию технического состояния.

Основными из них являются: степень повреждения защитных и отделочных слоев, степень повреждения вертикальными трещинами наружных стен, ширина раскрытия трещин, величина отклонения кладки стены от вертикали, наличие уменьшения сечения кирпичной кладки, фактическая прочность кладки, величина снижения несущей способности кладки при наличии дефектов, характер повреждения опор кладки, ширина раскрытия трещин перемычек и т.д.

В качестве выходных параметров принята категория технического состояния в соответствии с ГОСТ 31937-2024 [18]: нормативное; работоспособное; ограниченно работоспособное; аварийное.

По результатам анализа существующих методов машинного обучения [19-22] определили наиболее подходящие алгоритмы: для решения задачи прогнозирования категории технического состояния:

1. **Random Forest** («случайный лес») - это алгоритм машинного обучения, который состоит из множества отдельных независимых «решающих деревьев». В отличие от нейросетевых моделей из библиотек Keras/TensorFlow, у данной модели нет объекта history с метриками по эпохам, потому что «случайный лес» обучается одним проходом, без итераций по эпохам. Применение данного алгоритма выполняется с помощью библиотеки scikit-learn.
2. **Gaussian NB** (гауссовский наивный байесовский классификатор) - это алгоритм машинного обучения, который является разновидностью наивного байесовского метода. Он работает с непрерывными атрибутами и характеристиками данных, которые следуют распределению Гаусса в рамках всего набора данных. Обучение сводится к вычислению средних и стандартных отклонений по каждому признаку для каждого класса. Применение данного алгоритма выполняется с помощью библиотеки scikit-learn.
3. **Adam** (Adaptive Moment Estimation) - алгоритм оптимизации [23], который используется для обучения нейронных сетей. Он сочетает лучшие черты двух известных оптимизаторов: AdaGrad (адаптивный градиентный алгоритм) и RMSprop (адаптивный алгоритм оптимизации скорости обучения), благодаря чему обеспечивает эффективное и стабильное обучение. Применяется с помощью высокоуровневого интерфейса API (Application Programming Interface) Keras и библиотеки TensorFlow.
4. **Adam W** - это модернизированный алгоритм оптимизации Adam [24]. Изменения улучшили сходимость, регуляризацию и привели к более стабильному обучению. Применяется также с помощью API Keras и библиотеки TensorFlow.
5. **Auto Gluon** - это библиотека с открытым исходным кодом (AutoML (Automated Machine Learning)) для машинного обучения, которая упрощает и автоматизирует процесс создания моделей машинного обучения. Самостоятельно пробует различные модели обучения («случайный лес», нейронные сети и т.д.) и находит наиболее рациональные решения [25, 26].

Написание программы выполнялось в среде разработки *Visual studio code* (VS code), на языке программирования *Python*. В качестве первоначального из пяти вариантов на данном этапе принят алгоритм Adam. Для создания кода использовалась библиотека машинного обучения *Tensor Flow* и API *Keras*, которые содержат набор готовых функций, модулей и блоков.

Сбор исходных данных осуществлялся в виде таблицы в *Excel* с предварительной нормализацией значений параметров в интервале от 0 до 1. На данном этапе сформирована обучающая выборка из 18 признаков (дефектов) наружных стен и 100 фасадов зданий. Загрузка данных в *Python* осуществлялась при помощи библиотеки *Pandas*.

Программный код состоит из следующих основных частей:

1. Загрузка данных из файла Excel.
2. Преобразование целевой переменной из текста в цифровые значения, так как используемая модель работает только с цифровыми данными.
3. Указание столбца с целевой переменной и столбцов с признаками.
4. Разделение данных на обучающую и тестовую выборку. В данной программе приняли величину тестовой выборки 35%.
5. Создание модели нейронной сети. Архитектура сети принята полносвязной (fully connected) с тремя слоями. Первый слой, скрытый с 64 нейронами и функцией активации ReLU (Rectified Linear Unit), которая задаёт нелинейность и способствует более быстрой сходимости модели. Второй слой аналогичный первому, но с 10 нейронами. Третий слой – выходной с 4 нейронами — по одному на каждый класс. Также в выходном слое применяется функция активации softmax, которая преобразует выходы слоя в вероятности классов, сумма которых равна 1. Она часто используется для многоклассовой классификации [27].
6. Добавление функции dropout, которая регуляризует нейронные сети исключая часть случайных нейронов. Она используется для предотвращения переобучения и увеличения стабильности модели, реализуя случайное исключение отдельных нейронов в процессе обучения между скрытыми слоями. В данной программе применено значение dropout равное 0,5 на первых двух слоях.
7. Выполнение компиляции модели. Это процесс настройки параметров обучения (выбор методов оптимизации (в данном случае алгоритм Adam), функций потерь (Loss) и градиентного спуска), которые позволяют сети давать более точные прогнозы.
В данной задаче функция потерь определяется как среднеквадратичное отклонение между предсказанными и фактическими значениями при прямом ходе и обратном распространении ошибки по направлению от выходного слоя к входному. Метод градиентного спуска применяется для минимизации функции потерь.
8. Вычисление весов классов для их балансировки, что помогает модели уделять равное внимание всем категориям зданий. Применяется, так как 1 и 4 категории технического состояния зданий встречаются в обучающих данных значительно реже других.
9. Обучение модели. В работе проверялось различное количество эпох (от 50 до 300), но окончательно принято 150 эпох по соотношению точности и скорости обучения. Данные обучающей выборки разделяются на обучающую и валидационную при помощи команды `validation_split`, что позволяет оценить процесс обучения. В представленной работе размер валидационной выборки составляет 20 % от объема данных для обучения.
10. После чего выполнялась оценка модели на тестовых данных с получением итоговых результатов точности определения категорий технического состояния.

Графики функции потерь и точности представлены на рис. 1 и рис. 2 соответственно.

Обсуждение результатов. Графики функции потерь (loss) и точности (accuracy) процесса обучения показывают достаточно высокие результаты обучения, но имеется потенциал для улучшения. Требуется более тонкая настройка для борьбы с переобучением, а также увеличение объемов обучающих данных.

Переобучение возникает, когда модель запоминает все обучающие данные вместо того, чтобы сформировать общие закономерности.




Рис. 1 - График функции потерь

Синяя линия (Train Loss) - значение функции потерь на обучающей выборке,
 Оранжевая линия (Validation Loss) – величина потерь на валидационной выборке
 (данных, которые модель не видит во время обучения).

[1] Fig. 1 - Graph of the loss function.

Train Loss - the value of the loss function on the training sample; Validation Loss –
 losses on the validation sample (data that the model does not see during training).




Рис. 2 - График точности

Синяя линия (Train Accuracy) - доля правильных ответов на обучающих данных,
 Оранжевая линия (Validation Accuracy) - точность на валидационной выборке.

[2] Fig. 2 - Accuracy graph

[3] Train Accuracy - the percentage of correct answers based on training data; Validation Accuracy - accuracy based on the validation sample.

В процессе обучения точность составила 92.3%, на валидационной выборке 84.62%.
 Проверка нейросетевой модели на тестовой выборке показала точность 62.8%.

В ходе ручного анализа определили, что при ошибочной идентификации категории технического состояния, предполагаемая программой категория является смежной с фактической. То есть при фактической категории «работоспособная» программа ее определяет как «ограниченно-работоспособная», что указывает на некоторое занижение категории при определении программой.

Степень занижения будет уменьшаться с увеличением объема исходных данных [28, 29]. Отметим, что ошибка предсказания в поставленной задаче не так важна, как способность не пропустить аварийную категорию технического состояния, с чем модель справляется даже при использовании простого алгоритма машинного обучения Adam.

Результаты тестирования работоспособности разработанной программы показывают, что более половины результатов обследований можно с ее помощью предсказать в короткие сроки. Это позволяет также применять данную разработку для оперативного определения технического состояния зданий после чрезвычайных происшествий [30].

После апробирования программы на алгоритме Adam проверили точность обучения и предсказания на других четырех алгоритмах машинного обучения.

Результаты тестирования с использованием различных алгоритмов машинного обучения сведены в табл. 1.

Таблица 1. Результаты тестирования с использованием различных алгоритмов машинного обучения

Table 1. Test results using various machine learning algorithms

Наименование алгоритма	Точность (Accuracy) на тестовой выборке	Время обучения, с
Random Forest	71.4%	3.9
GaussianNB	63%	0.01
Adam	60.2% - без Dropout 62.8% с Dropout 0,5	60.3 - без Dropout 65.3 - с Dropout 0,5
AdamW	74.3%	55.2
AutoGluon	77.1%	33.16

По результатам апробации различных методов машинного обучения на основе предоставленных данных и заданных критериев оптимизации определили, что оптимальным является использование автоматизированной библиотеки машинного обучения AutoGluon, так как она показывает наибольшую точность.

Время обучения превышает многие другие методы, но в представленной задаче не является критичным, так как обучение на всех данных выполняется единожды и в дальнейшем для определения категории технического состояния используются уже сформированные закономерности.

Данная библиотека самостоятельно выполняет перебор различных алгоритмов, комбинирует лучшие подходы в различных вариациях, адаптируясь к характеристикам конкретных данных. В процессе обучения точность составила 95,3%, на валидационной выборке 87,5%. При проверке нейросетевой модели на тестовой выборке показала точность до 77,1%.

Вывод.

1. По результатам анализа существующих методов машинного обучения и их практического сравнения на одинаковых исходных данных для определения категории технического состояния наружных стен кирпичных зданий выбран метод машинного обучения AutoML на базе библиотеки AutoGluon.
2. Разработана программа для автоматизации определения категории технического состояния наружных стен кирпичных зданий на основе машинного обучения. Экспериментальные исследования показали достаточную точность в процессе обучения (92,3 %) и при проверке на тестовой выборке (76,6%).
3. Определены оптимальные значения основных параметров обучения (количество эпох, скрытых слоев, нейронов в скрытых слоях, количество исключаемых нейронов), а также необходимые минимальные настройки для борьбы с «запоминанием» обучающих данных, вместо формирования общих закономерностей;
4. Результаты исследования демонстрируют эффективность применения алгоритмов машинного обучения для определения категории технического состояния зданий и могут, в том числе, получить применение в обучении молодых специалистов при обследовании зданий.

Библиографический список:

1. Кашеварова Г.Г., Тонков Ю.Л., Фурсов М.Н. Нечеткая экспертная система диагностики повреждений строительных конструкций // Вестник Волжского регионального отделения Российской академии архитектуры и строительных наук (ВРО РААСН). 2014. №17. С. 167-173.
2. Наумов А.Е., Юдин Д.А., Долженко А. В. Совершенствование технологии проведения строительно-технических экспертиз с использованием аппаратно-программного комплекса автоматизированной дефектоскопии // Вестник БГТУ им. В.Г. Шухова. 2019. № 4. С. 61–69. DOI:10.34031/article_5cb824d26344e7.458 99508.
3. Кашеварова Г.Г. «Искусственный интеллект», или «логические рассуждения и разумные решения» в технической диагностике объектов строительства // Academia. Архитектура и строительство. 2023.

- № 4. С. 166–180. – DOI: 10.22337/2077-9038-2023-4-166-180.
4. Крылов, С.А. Автоматизация диагностирования причин возникновения дефектов на фасадах кирпичных зданий с применением технологий искусственного интеллекта / С.А. Крылов, Г.Г. Кашеварова // Вестник Пермского национального исследовательского политехнического университета. Прикладная экология. Урбанистика. – 2023. – № 4. – С. 51–62. DOI: 10.15593/2409-5125/2023.04.05
 5. Gbadegeshin, S.A., Al Natsheh, A., Ghafel, K., Tikkanen, J., Gray, A., Rimpiläinen, A., Hirvonen, N. (2021). What is an Artificial intelligence (ai): a simple buzzword or a worthwhile inevitability? In ICERI 2021 Proceeding, 1, 468–479. <https://doi.org/10.21125/iceri.2021.0171>.
 6. Соколов, В.А. Вероятностный анализ технического состояния кирпичных стен зданий старой городской застройки / Соколов В.А. // Безопасность зданий и сооружений. – 2015. – № 1(57). – С. 65–73.
 7. Sokolov V.A. (2013). Diagnostics of the technical condition of buildings and structures using methods of fuzzy set theory. Magazine of Civil Engineering, 5, 31–37. <https://doi.org/10.18720/MCE.15.4>.
 8. Shtovba S.D., Pankevych O. D. Fuzzy technology-based cause detection of structural cracks of stone buildings. CEUR workshop proceedings, 2108, 209–218
 9. Солдатенко, Т.Н. Модель идентификации и прогноза дефектов строительной конструкции на основе результатов ее обследования / Т. Н. Солдатенко // Инженерно-строительный журнал. – 2011. – № 7 (25). – С. 52–61.
 10. Kashevarova G.G., Tonkov Y.L. (2018). Intelligent technologies in the examination of construction structures. Academia. Architecture and Construction, 1, 92–99. <https://doi.org/10.22337/2077-9038-2018-1-92-99>.
 11. Кашеварова Г.Г., Тонков Ю.Л. Экспертная система для практической диагностики строительных конструкций // Academia. Архитектура и строительство. – 2022. – № 2. – С. 85–91. <https://doi.org/10.22337/2077-9038-2022-1-85-91>.
 12. Тарарушкин Е.В.. Применение нечеткой логики для оценки физического износа несущих конструкций зданий // Вестник БГТУ им. В.Г. Шухова. – 2016. – № 10. – С. 77–82. doi.org/10.12737/22032.
 13. Кашеварова Г.Г., Платунов В.Ю., Крылов С.А. Определение категории технического состояния строительных конструкций зданий перегрузочных узлов калийных солей на основе многолетнего мониторинга с использованием нейронных сетей. В сборнике. Вестник Приволжского территориального отделения Российской академии архитектуры и строительных наук. Сборник научных трудов. Нижний Новгород, 2024. С. 212–218. eLIBRARY ID: 75131299
 14. Hosseini, M.A., M. Ravanshadnia, M. Rahimzadegan, and S. Ramezani (2024). Next-generation building condition assessment: BIM and neuralnetwork integration. Journal of Performance of Constructed Facilities, 38 (6). <https://doi.org/10.1061/JPCFEV.CFENG-4828>.
 15. Hosseini, M.A., M. Ravanshadnia, M. Rahimzadegan, and S. Ramezani (2024). A robustf model for evaluating defects in building elements. Numerical Methods in Civil Engineering, 9(1). <https://doi.org/10.61186/NMCE.2406.1064>.
 16. Mangalathu, S., Sun, H., Nweke, C.C., Yi, Z., & Burton, H.V. Classifying earthquake damage to buildings using machine learning. Earthquake Spectra, 2020;. 36(1), 183–208. doi.org/10.1177/8755293019878137.
 17. Amiri Shahmirani, M.R., Nikghalb Rashti, A.A., Adib Ramezani, M.R., & Golafshani, E.M. (2022). Buildings, Causalities, and Injuries Innovative Fuzzy Damage Model during Earthquakes. Shock and Vibration. <https://doi.org/10.1155/2022/4746587>.
 18. ГОСТ 31937-2024 (2024). Здания и сооружения. Правила обследования и мониторинга технического состояния [Текст]. – Введ. 2024-05-01. – М. Институт стандартизации, 2024. – 69 с.
 19. Бурков А. Машинное обучение без лишних слов / А. Бурков. - СПб.: Питер, 2020. — 192 с.
 20. Romeiko, X.X., Zhang, X., Pang, Y., Gao, F., Xu, M., Lin, S., & Babbitt, C. (2024). A review of machine learning applications in life cycle assessment studies. Science of the Total Environment. <https://doi.org/10.1016/j.scitotenv.2023.168969>.
 21. S. Hu, T. Guo., M.S. Alam., Y. Koetaka, E. Ghafoori., Th. L. Karavasilis (2025). Machine learning in earthquake engineering: A review on recent progress and future trends in seismic performance evaluation and design. Engineering Structures. <https://doi.org/10.1016/j.engstruct.2025.120721>.
 22. Málaga-Chuquitaype, C. (2022). Machine Learning in Structural Design: An Opinionated Review. Frontiers in Built Environment, 8. <https://doi.org/10.3389/fbuil.2022.815717>.
 23. Kurian, B., & Liyanapathirana, R. (2020). Machine Learning Techniques for Structural Health Monitoring. Proceedings of the 13th International Conference on Damage Assessment of Structures. Lecture Notes in Mechanical Engineering, 3–24. https://doi.org/10.1007/978-981-13-8331-1_1.
 24. Soydaner, D. (2020). A Comparison of Optimization Algorithms for Deep Learning. International Journal of Pattern Recognition and Artificial Intelligence, 34 (13). <https://doi.org/10.1142/S0218001420520138>.
 25. Kuzyakin A.P. (2023) Comparative analysis of modern AutoML solutions. Collection of scientific papers of the 26th Russian Scientific Conference, 1. 183–195.
 26. Ferreira, L., Pilastrri, A., Martins, C.M., Pires, P.M., & Cortez, P. (2021). A Comparison of AutoML Tools for Machine Learning, Deep Learning and XGBoost. International Joint Conference on Neural Networks (IJCNN). <https://doi.org/10.1109/IJCNN52387.2021.9534091>.
 27. Akinosho, T.D., Oyedele, L.O., Bilal, M., Ajayi, A.O., Delgado, M.D., Akinade, O.O.; Ahmed, A.A. (2020).

- Deep learning in the construction industry: A review of present status and future innovations. *Journal of Building Engineering*, 32. <https://doi.org/10.1016/j.jobbe.2020.101827>.
28. Yang, C., Gunay, B., Shi, Z., & Shen, W. (2021). Machine Learning-Based Prognostics for Central Heating and Cooling Plant Equipment Health Monitoring. *IEEE Transactions on Automation Science and Engineering*, 18 (1), 346–355. <https://doi.org/10.1109/TASE.2020.2998586>.
 29. Sun, H., Burton, H.V., & Huang, H. (2021). Machine learning applications for building structural design and performance assessment: State-of-the-art review. *Journal of Building Engineering*. <https://doi.org/10.1016/j.jobbe.2020.101816>.
 30. Amiri Shahmirani, M.R.; Nikghalb Rashti, A.A.; Adib Ramezani, M.R.; Golafshani, E.M. (2021). Application of fuzzy modelling to predict the earthquake damage degree of buildings based on field data. *Journal of Intelligent and Fuzzy Systems*, 41 (2), 2717–2730. <https://doi.org/10.3233/JIFS-202424>

References:

1. Kashevarova G.G., Tonkov Y.L., Fursov M.N. Fuzzy expert system for diagnosing damage to building structures. *Bulletin of the Volga Regional Branch of the Russian Academy of Architecture and Building Sciences (VRO RAASN)*. 2014;17: 167-173.
2. Naumov A.E., Yudin D.A., Dolzhenko A.V. Improving the technology of conducting construction and technical expertise using a hardware and software complex of automated inspection. *Bulletin of BSTU named after V.G. Shukhov*, 2019;4, 61–69. https://doi.org/10.34031/article_5cb824d26344e7.45899508.
3. Kashevarova G.G. «Artificial Intelligence» or «Logical Discussion and Reasonable Solutions» in Technical Diagnostics of Construction Projects. *Academia. Architecture and Construction*, 2023;4:166–180. <https://doi.org/10.22337/2077-9038-2023-4-166-180>.
4. Krylov S.A., Kashevarova G.G. Automation of diagnosing the causes of defects on the facades of brick buildings using artificial intelligence technologies. *PNRPU Bulletin. Applied ecology. Urban development*, 2023; 4, 51-62. <https://doi.org/10.15593/2409-5125/2023.04.05>.
5. Gbadegeshin, S.A., Al Natsheh, A., Ghafel, K., Tikkanen, J., Gray, A., Rimpiläinen, A., Hirvonen, N. What is an artificial intelligence (ai): a simple buzzword or a worthwhile inevitability? In *ICERI2021 Proceeding*, 2021; 1: 468–479. <https://doi.org/10.21125/iceri.2021.0171>.
6. Sokolov V.A. Probabilistic analysis of the technical state of brick walls of the old city buildings. *Safety of buildings and structures*, 2015;1 (57): 65-73.
7. Sokolov V.A. Diagnostics of the technical condition of buildings and structures using methods of fuzzy set theory. *Magazine of Civil Engineering*. 2013; 5: 31-37. <https://doi.org/10.18720/MCE.15.4>.
8. Shtovba S.D., Pankevych O.D. 2018 Fuzzy technology-based cause detection of structural cracks of stone buildings. *CEUR workshop proceedings*, 2105; 209–218.
9. Soldatenko T.N. Model of Identification and Prediction of Building Design Defects on the Basis of Its Inspections Results. *Magazine of Civil Engineering*, 2011;7 (25), 52–61. <https://doi.org/10.5862/MCE.25.8>.
10. Kashevarova G.G., Tonkov Y.L. Intelligent technologies in the examination of construction structures. *Academia. Architecture and Construction*, 2018;1:92-99. <https://doi.org/10.22337/2077-9038-2018-1-92-99>.
11. Kashevarova G.G., Tonkov Y.L. Expert system for practical diagnostics of building structures. *Academia. Architecture and Construction*, 2022; 2:85–91. <https://doi.org/10.22337/2077-9038-2022-1-85-91>.
12. Tararushkin E.V. Use of fuzzy logic for assessment of damage structures of buildings. *Bulletin of BSTU named after V.G. Shukhov*, 2016;10:77-82. <https://doi.org/10.12737/22032>.
13. Kashevarova G.G., Platunov V.Y., Krylov S.A. Multi-task neural network model of classification based on multi-year database of monitoring of technical condition of building structures of transshipment hubs buildings. *Bulletin of the Volga Regional Branch of the Russian Academy of Architecture and Building Sciences (VRO RAASN)*, 2024; 27: 212-218. <https://doi.org/10.22337/2077-9038-2023-4-166-180>.
14. Hosseini, M.A., M. Ravanshadnia, M. Rahimzadegan, and S. Ramezani. Next-generation building condition assessment: BIM and neuralnetwork integration. *Journal of Performance of Constructed Facilities*, 2024;38(6). <https://doi.org/10.1061/JPCFEV.CFENG-4828>.
15. Hosseini, M.A., M. Ravanshadnia, M. Rahimzadegan, and S. Ramezani. A robustf model for evaluating defects in building elements. *Numerical Methods in Civil Engineering*, 2024;9(1). <https://doi.org/10.61186/NMCE.2406.1064>.
16. Mangalathu, S., Sun, H., Nweke, C.C., Yi, Z., & Burton, H.V. Classifying earthquake damage to buildings using machine learning. *Earthquake Spectra*, 2020;36(1):183–208. doi.org/10.1177/8755293019878137.
17. Amiri Shahmirani, M. R., Nikghalb Rashti, A.A., Adib Ramezani, M. R., & Golafshani, E. M. (2022). Buildings, Causalities, and Injuries Innovative Fuzzy Damage Model during Earthquakes. *Shock and Vibration*. <https://doi.org/10.1155/2022/4746587>.
18. GOST 31937-2024. Buildings and Structures. Rules for Inspection and Monitoring of Technical Condition. Russian Standardization Institute. Moscow, 2024;69.
19. Burkov A. The Hundred-Page Machine Learning Book. Piter. Saint Petersburg, 2020; 192.
20. Romeiko, X.X., Zhang, X., Pang, Y., Gao, F., Xu, M., Lin, S., & Babbitt, C. (2024). A review of machine learning applications in life cycle assessment studies. *Science of the Total Environment*.

- <https://doi.org/10.1016/j.scitotenv.2023.168969>.
21. S. Hu, T. Guo., M.S. Alam., Y. Koetaka, E. Ghafoori., Th.L. Karavasilis (2025). Machine learning in earthquake engineering: A review on recent progress and future trends in seismic performance evaluation and design. *Engineering Structures*. <https://doi.org/10.1016/j.engstruct.2025.120721>.
 22. Málaga-Chuquitaype, C. Machine Learning in Structural Design: An Opinionated Review. *Frontiers in Built Environment*, 2022; 8. <https://doi.org/10.3389/fbuil.2022.815717>.
 23. Kurian, B., & Liyanapathirana, R. Machine Learning Techniques for Structural Health Monitoring. Proceedings of the 13th International Conference on Damage Assessment of Structures. *Lecture Notes in Mechanical Engineering*, 2020: 3–24. https://doi.org/10.1007/978-981-13-8331-1_1.
 24. Soydaner, D. A Comparison of Optimization Algorithms for Deep Learning. *International Journal of Pattern Recognition and Artificial Intelligence*, 2020;34(13). doi.org/10.1142/S0218001420520138.
 25. Kuzyakin A.P. Comparative analysis of modern AutoML solutions. *Collection of scientific papers of the 26th Russian Scientific Conference*, 2023; 1:183-195.
 26. Ferreira, L., Pilastrri, A., Martins, C.M., Pires, P.M., & Cortez, P. A Comparison of AutoML Tools for Machine Learning, Deep Learning and XGBoost. *International Joint Conference on Neural Networks (IJCNN)*. 2021. <https://doi.org/10.1109/IJCNN52387.2021.9534091>.
 27. Akinosho, T.D., Oyedele, L.O., Bilal, M., Ajayi, A.O., Delgado, M.D., Akinade, O.O.; Ahmed, A.A. Deep learning in the construction industry: A review of present status and future innovations. *Journal of Building Engineering*, 2020: 32. <https://doi.org/10.1016/j.jobbe.2020.101827>.
 28. Yang, C., Gunay, B., Shi, Z., & Shen, W. Machine Learning-Based Prognostics for Central Heating and Cooling Plant Equipment Health Monitoring. *IEEE Transactions on Automation Science and Engineering*, 2021;18 (1), 346–355. <https://doi.org/10.1109/TASE.2020.2998586>.
 29. Sun, H., Burton, H.V., & Huang, H. Machine learning applications for building structural design and performance assessment: State-of-the-art review. *Journal of Building Engineering*. 2021. doi.org/10.1016/j.jobbe.2020.101816.
 30. Amiri Shahmirani, M.R.; Nikghalb Rashti, A.A.; Adib Ramezani, M.R.; Golafshani, E.M. Application of fuzzy modelling to predict the earthquake damage degree of buildings based on field data. *Journal of Intelligent and Fuzzy Systems*, 2021; 41(2):2717–2730. <https://doi.org/10.3233/JIFS-202424>.

Сведения об авторах:

Сергей Андреевич Крылов, аспирант, кафедра «Строительные конструкции и вычислительная механика»; serishca@yandex.ru

Галина Геннадьевна Кашеварова, доктор технических наук, профессор, член-корреспондент РААСН, заведующий кафедрой «Строительные конструкции и вычислительная механика»; ggkash@mail.ru

Information about authors:

Sergey A. Krylov, Graduate Student, Department of Building Structures and Computational Mechanics

Galina G. Kashevarova, Dr. Sci.(Eng.), Prof., Corresponding Member of the Russian Academy of Architecture and Construction Sciences, Head of the Department of Building Structures and Computational Mechanics; ggkash@mail.ru

Конфликт интересов/Conflict of interest.

Авторы заявляют об отсутствии конфликта интересов/The authors declare no conflict of interest.

Поступила в редакцию/Received 02.07.2025.

Одобрена после рецензирования/ Revised 20.08.2025.

Принята в печать/Accepted for publication 04.09.2025.