

НАУЧНАЯ СТАТЬЯ / RESEARCH PAPER

УДК 004.896

DOI: 10.22227/2305-5502.2024.3.131-142

## Современные подходы к оценке технического состояния строительных конструкций зданий на этапе эксплуатации

Наталья Викторовна Князева<sup>1</sup>, Евгений Анатольевич Назойкин<sup>2</sup>,  
Алексей Александрович Орехов<sup>2</sup>

<sup>1</sup> *Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ); г. Москва, Россия;*

<sup>2</sup> *Российский биотехнологический университет (РОСБИОТЕХ); г. Москва, Россия*

### АННОТАЦИЯ

**Введение.** Рассматривается разработка подходов к построению системы автоматизированной оценки технического состояния строительных конструкций с использованием механизмов обнаружения дефектов и предварительной оценки физического износа зданий на основе методов искусственного интеллекта (ИИ). Современные строительные объекты характеризуются высокой сложностью и масштабом, что требует особого внимания к качеству и надежности конструкций. Традиционные методы проведения технического обслуживания не всегда показывают свою эффективность в связи с влиянием человеческого фактора. В настоящее время основным способом обнаружения дефектов остается визуальный осмотр, который хотя и позволяет оценить состояние объектов, зависит от уровня квалификации и внимательности оценщика. Это создает риски ошибки, что может угрожать безопасности зданий и приводить к неправильным решениям в области ремонта и технического обслуживания. Цель исследования — анализ необходимой функциональности и моделирование автоматизированной системы, способной оперативно и точно выявлять потенциальные дефекты в конструкциях зданий и оценивать вероятный физический износ.

**Материалы и методы.** Комплексный подход включает два основных компонента: систему анализа накопленных данных о физическом износе жилого фонда и механизм обнаружения дефектов на основе анализа изображений с помощью ИИ. Основные исходные данные для анализа — результаты фотофиксации состояния зданий, а также объем накопленных за продолжительный период наблюдений сведений о физическом износе жилого фонда.

**Результаты.** Подробно описаны библиотеки и инструменты, которые необходимы для реализации работы системы, включая популярные фреймворки для машинного обучения и обработки изображений.

**Выводы.** Современные подходы, основанные на применении ИИ и методов машинного обучения, открывают новые горизонты в сфере обнаружения дефектов и прогнозирования технического состояния зданий. Они позволяют значительно увеличить скорость и точность анализа.

**КЛЮЧЕВЫЕ СЛОВА:** обнаружение дефектов, оценка физического износа, техническое обслуживание, фотофиксация, эксплуатация зданий, искусственный интеллект

**ДЛЯ ЦИТИРОВАНИЯ:** Князева Н.В., Назойкин Е.А., Орехов А.А. Современные подходы к оценке технического состояния строительных конструкций зданий на этапе эксплуатации. 2024. Т. 14. Вып. 3. С. 131–142. URL: <http://nso-journal.ru>. DOI: 10.22227/2305-5502.2024.3.131-142

Автор, ответственный за переписку: Наталья Викторовна Князева, [nknyazeva@mgsu.ru](mailto:nknyazeva@mgsu.ru).

## Modern approaches to assessing the technical condition of building structures at the operational stage

Natal'ya V. Knyazeva<sup>1</sup>, Evgenij A. Nazojkin<sup>2</sup>, Aleksej A. Orekhov<sup>2</sup>

<sup>1</sup> *Moscow State University of Civil Engineering (National Research University) (MGSU);  
Moscow, Russian Federation;*

<sup>2</sup> *Russian Biotechnological University (BIOTECH University); Moscow, Russian Federation*

### ABSTRACT

**Introduction.** The paper is devoted to the development of approaches to the construction of an automated assessment system for the technical condition of building structures using defect detection mechanisms and preliminary assessment of the physical deterioration of buildings based on artificial intelligence methods. Modern construction objects are characterized by high complexity and scale, which requires special attention to the quality and reliability of structures. Traditional methods of technical maintenance do not always show their effectiveness due to the influence of human factors. Currently, the primary method of defects detection remains visual inspection, which, although it allows to assess the condition of objects, depends on the level of qualification and attentiveness of the evaluator. This creates risks of error, which can threaten the safety of buildings and lead to incorrect decisions regarding repairs and maintenance. The aim of the research is to analyze the required functionality

and modelling of an automated system capable of quickly and accurately identifying potential defects in building structures and assessing likely physical deterioration.

**Materials and methods.** The comprehensive approach includes two main components: a system for analyzing accumulated data on the physical deterioration of residential properties and a defect detection mechanism based on image analysis using artificial intelligence. The main input data for analysis are the results of photographic documentation of the building condition, as well as the volume of accumulated observations and data on the physical deterioration of the housing stock over a long period of observation.

**Results.** The libraries and tools necessary for the implementation of this system are described in detail, including popular frameworks for machine learning and image processing.

**Conclusions.** Modern approaches based on the application of artificial intelligence and machine learning methods open new horizons in the detection of defects and forecasting the technical condition of buildings. They significantly increase the speed and accuracy of analysis.

**KEYWORDS:** defect detection, physical deterioration assessment, maintenance, photofixation, building operation, artificial intelligence

**FOR CITATION:** Knyazeva N.V., Nazojkin E.A., Orekhov A.A. Modern approaches to assessing the technical condition of building structures at the operational stage. *Stroitel'stvo: nauka i obrazovanie* [Construction: Science and Education]. 2024; 14(3):131-142. URL: <http://nso-journal.ru>. DOI: 10.22227/2305-5502.2024.3.131-142

*Corresponding author:* Natal'ya V. Knyazeva, [nknyazeva@mgsu.ru](mailto:nknyazeva@mgsu.ru).

## ВВЕДЕНИЕ

Введенные в эксплуатацию активы стареют и продление срока службы зданий стало финансово привлекательным решением благодаря экономии средств на проектах реконструкции. На сегодняшний день обнаружение дефектов конструкций происходит в основном за счет визуального осмотра, который дает возможность оценить качество и состояние элементов конструкций, выявить элементы, подлежащие ремонту, и аварийные участки. Однако этот процесс достаточно трудоемкий и целиком зависит от человеческого фактора — опытности и внимательности специалиста по эксплуатации. Несмотря на высокий уровень подготовки и профессиональной квалификации, всегда существует риск человеческой ошибки при интерпретации собранной информации. Это может привести к неверной оценке состояния несущих конструкций, что в свою очередь может стать причиной неуместного или даже небезопасного подхода к ремонту и техническому обслуживанию. Применение современных методов машинного обучения открывает большие возможности в уменьшении рутинной работы специалистов и снижении рисков ошибок за счет человеческого фактора.

Система обнаружения дефектов в строительных конструкциях зданий должна позволять не только идентифицировать проблемы, но и давать возможность оценить величину физического износа, опираясь, с одной стороны, на статистические данные, с другой — на архивные сведения по конкретному элементу, чтобы службы по эксплуатации могли обоснованно принять решения о дальнейшем техническом обслуживании элементов здания. Для того чтобы не просто обнаруживать проблему, а понимать, насколько этот дефект является критическим для здания, необходимо учитывать общий уровень физического износа. С этой целью специалистам по эксплуатации удобно использовать прогнозные данные о состоянии зданий.

## МАТЕРИАЛЫ И МЕТОДЫ

Обзор научных статей позволяет сделать вывод о том, что применение искусственного интеллекта (ИИ) активно обсуждается и реализуется в практике эксплуатации зданий [1, 2]. В основном подход к обработке больших данных на этом этапе жизненного цикла строится вокруг задач снижения теплопотерь и повышения энергоэффективности строительных объектов [3, 4]. С другой стороны ведется много исследований по процессу идентификации поврежденных на основе показаний датчиков [5, 6]. Точность обнаружения несоответствий в конструкциях благодаря непрерывному инструментальному мониторингу значительно выше, но требуются вычислительные мощности и существенные финансовые затраты на обеспечение соответствующими приборами, что не всегда целесообразно. Также встречаются работы, в которых акцент сделан на обнаружение трещин с использованием компьютерного зрения, а высокая точность идентификации достигается за счет преобразования RGB-изображений в оттенки серого и последующей обработки с использованием CLAHE (Contrast Limited Adaptive Histogram Equalization) — алгоритма, который позволяет увеличить контрастность и детализацию изображения [7]. Обзор альтернативных подходов для решения проблемы распознавания изображений трещин, представленный в нескольких научных статьях, свидетельствует о том, что имеется более 60 вариантов глубокого обучения, но все они требуют больших объемов данных, в том числе аннотированных [8, 9].

Использование сверточных нейронных сетей (СНС) для классификации изображений — распространенная практика [10–13]. На этапе проведения строительно-технической экспертизы возникает задача дефектоскопии и решается для внешних конструкций, например кровель, применением глубоких полностью СНС для распознавания дефектов в видеофрагментах, сделанных камерами малых беспилотных летательных аппаратов [14]. Кроме

того, недостаточно глубоко изучен вопрос о применении технологии информационного моделирования на этапе эксплуатации зданий [15–20]. Однако обобщенных исследований, ориентированных на построение системы, способной работать с разными типами дефектов и оценивать общее техническое состояние здания, найти не удалось.

В настоящей работе принято решение сформировать комплексный подход, основанный на следующих компонентах:

- система анализа накопленных данных о физическом износе существующего жилого фонда;
- система обнаружения дефектов строительных конструкций на основе анализа данных фотофиксации с помощью ИИ.

## РЕЗУЛЬТАТЫ

Современные технологии, например системы мониторинга строительных конструкций, включают различные измерительные подсистемы и значитель-

но упрощают процесс накопления сведений. В процессе эксплуатации активов возникает большое количество данных, и для их эффективной обработки требуется применение различных подходов и технологий [21]. Чаще всего подобные системы используются для анализа состояния технически сложных и опасных объектов ввиду дороговизмы реализации. Поэтому основное внимание привлекает сбор статистического материала.

Информация о параметрах существующего жилого фонда содержится в нескольких источниках открытых данных:

- 1) информация об аварийных объектах ЖКХ по открытым данным с сайта Реформа ЖКХ;
- 2) данные Фонда развития территорий по аварийным домам, многоквартирным домам в региональной программе капитального ремонта по областям;
- 3) портал открытых данных Правительства Москвы.

```
<class 'pandas.core.frame.DataFrame'>
Int64Index: 38389 entries, 0 to 85249
Data columns (total 24 columns):
#   Column                                Non-Null Count  Dtype
---  -
0   formalname_region                    38389 non-null  object
1   stage                                38388 non-null  object
2   built_year                           38389 non-null  datetime64[ns]
3   exploitation_start_year              34599 non-null  object
4   house_type                           38389 non-null  object
5   floor_count_max                      38389 non-null  int64
6   floor_count_min                      38389 non-null  int64
7   entrance_count                      38389 non-null  int64
8   residents_count                     38389 non-null  int64
9   area_total                           38389 non-null  object
10  area_residential                     38363 non-null  object
11  area_non_residential                 36329 non-null  object
12  area_common_property                33139 non-null  object
13  area_land                            23540 non-null  object
14  deterioration_total                 38389 non-null  float64
15  determined_date                    38389 non-null  datetime64[ns]
16  floor_type                           24732 non-null  object
17  wall_material                        24739 non-null  object
18  alarm_reason                         38389 non-null  object
19  exp_name                             31743 non-null  object
20  exp_document_date                   31737 non-null  object
21  commission_document_date            33279 non-null  object
22  further_use                          38389 non-null  object
23  building_age_at_determined_date     38389 non-null  int64
dtypes: datetime64[ns](2), float64(1), int64(5), object(16)
memory usage: 7.3+ MB
None
```

Рис. 1. Вывод информации о DataFrame

Также можно масштабировать исследование и подключить любой другой источник архивных сведений.

Исходная информация выгружена из трех источников открытых данных. Далее на основе модели CRISP-DM — стандарта интеллектуального анализа независимого от отрасли, они были преобразованы: категориальные переменные преобразованы в числовые переменные, заполнены пропущенные значения в переменных, проведен Feature Engineering, т.е. были

извлечены новые переменные для таблицы из необработанных данных [22]. Среди примеров использования этой методологии в области строительства, и, в частности, эксплуатации зданий, есть исследования по прогнозированию энергопотребления зданий с использованием факторов внутри помещений [23].

Анализ собранных сведений заключался в решении следующих задач:

- поиск корреляции в данных;
- изучение статистических параметров данных.

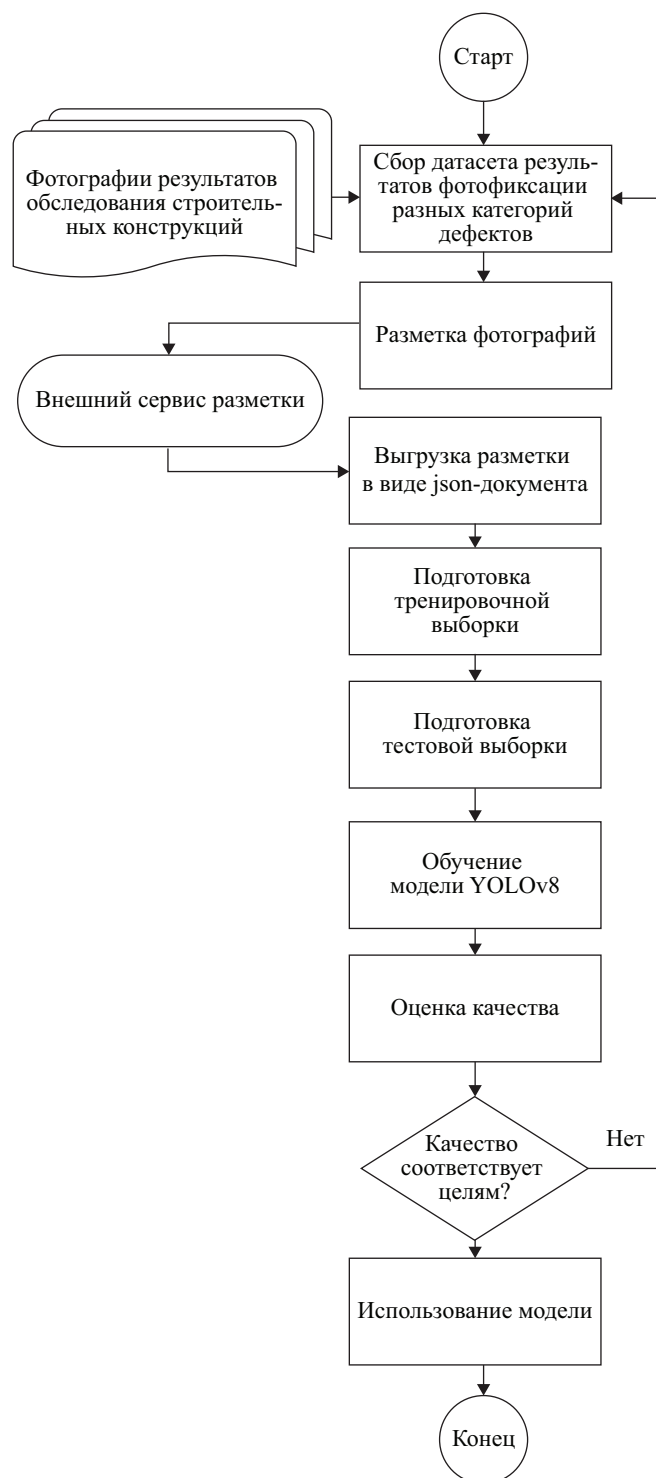


Рис. 2. Блок-схема последовательности построения системы

Целевые метрики: точность предсказания физического износа score, MAE. Среди необходимых для работы библиотек выбраны NumPy и Pandas. Также для визуализации информации предпочтительно отдано широко используемым библиотекам Matplotlib и Seaborn, позволяющим преобразить числовые данные в удобные графики, диаграммы, гистограммы и другие визуальные представления.

В первую очередь информацию необходимо было подгрузить из соответствующих датасетов. Для этого сначала определялась кодировка файла, а затем производилось чтение файла с соответствующей кодировкой. Например, кодировка файла реестра многоквартирных жилых домов по России UTF-8-SIG.

Из-за особенности структуры в таблице много нулевых и лишних значений, что означало необходимость трансформации. Также потребовалось преобразование форматов данных. Добавили несколько новых параметров, например возраст здания на момент технического осмотра.

Затем проверили состав данных после их очистки и подготовки (рис. 1).

Для проведенного исследования довольно важный параметр — тип стенового материала, поскольку в зависимости от него можно идентифицировать разные типы дефектов. Поэтому для дальнейшего анализа разные классы стеновых материалов необходимо закодировать числовыми значениями.

При обучении модели пробовали использовать несколько подходов. Применяли линейную и полиномиальную регрессии, а также обучили модель деревьев решений, которая показала наилучший результат по коэффициенту детерминации и MASE.

В условиях цифровой трансформации и непрерывного технологического прогресса возникают потребности в автоматизации и повышенном контроле за эксплуатацией зданий. Применение систем машинного зрения представляет собой эффективное средство для усовершенствования процессов контроля и прогнозирующих нарушений зданий. Эти системы способны автоматизировать обработку и анализ изображений, выявлять дефекты и отклонения в строительных конструкциях, что в конечном итоге приводит к повышению качества эксплуатации и долговечности зданий.

Среди наиболее подходящих библиотек в этой области в работе использовались: OpenCV, PyTorch, Keras, Scikit-image и TensorFlow.

Задача состояла в построении классификатора, который обнаружит один или несколько из следующих дефектов:

- 1) биогенное поражение поверхности (грибок, плесень, мох) — образование микроорганизмов на поверхности стен из-за высокой влажности и недостаточной вентиляции;
- 2) волосяные трещины — тонкие, мелкие трещины на поверхности стены;
- 3) глубокие трещины — трещины, проникающие внутрь структуры стены;

4) нарушение защитного слоя бетона и оголенные арматуры — излом бетонного слоя, что может привести к коррозии арматуры;

5) отслоение и обрушение отделочного покрытия — отделочные элементы, такие как штукатурка, плитка, окраска отслаиваются от поверхности стены;

6) промерзание — повреждения, вызванные циклическими замораживаниями и оттаиваниями;

7) увлажнение — проникновение влаги в стену из-за нарушений водоотвода или утечек.

В ходе работы была разработана блок-схема построения системы (рис. 2).

Анализ результатов включает рассмотрение матрицы ошибок и оценку точности по классам, что обеспечивает информацию о способности модели к правильной классификации и выявлению возможных ошибок.

Для расширения датасета использовали Яндекс Картинки, Google Картинки.

Разметка данных проводилась на сервисе robots, далее выгружали разметку в виде json-документа.

С целью обучения была применена модель YOLOv8.

Для проверки точности работы модели фотофиксации выполнен эксперимент. Собрали изображения конструкций, на которых заранее были известны места дефектов. Модель успешно распознала 71–88 % из этих дефектов, что подтвердило справедливость выбранного подхода и его применение в реальных условиях эксплуатации зданий (рис. 3).

Однако также были выявлены случаи, когда модель ошибалась, особенно это касалось сложных



Рис. 3. Результат работы системы

визуальных повреждений, требующих более глубокого понимания контекста, например изменения цвета покрытия или миниатюрных трещин, возникших в результате сезонных колебаний температуры.

В связи с этим возникает необходимость постоянного обучения и дообучения модели на новых данных для достижения большей точности.

## ЗАКЛЮЧЕНИЕ

В результате анализа информации с использованием различных методов машинного обучения

удалось выявить определенные закономерности и особенности, связывающие тип стенового материала, возраст конструкции и частоту возникновения дефектов. Предложенный подход не только сделает процесс обнаружения дефектов более быстрым и точным, но и обеспечит значительное снижение рисков аварий и повышение безопасности эксплуатации зданий. Таким образом, применение методов ИИ в анализе состояния строительных конструкций станет важным шагом к обеспечению надежности и долговечности объектов жилого фонда, что в конечном итоге скажется на качестве жизни граждан.

## СПИСОК ИСТОЧНИКОВ

1. *Adewale B.A., Ene V.O., Ogunbayo B.F., Aigbavboa C.O.* A Systematic Review of the Applications of AI in a Sustainable Building's Lifecycle // *Buildings*. 2024. Vol. 14. Issue 7. P. 2137. DOI: 10.3390/buildings14072137
2. *Mishra A., Pareek R.K., Kumar S., Varalakshmi S.* A review of the current and future developments of artificial intelligence in the management and building sectors // *Multidisciplinary Reviews*. 2024. Vol. 6. P. 2023ss068. DOI: 10.31893/multirev.2023ss068
3. *Сулейманова Л.А., Обайди А.А.* Управление жизненным циклом здания на этапе эксплуатации с использованием моделей искусственных нейронных сетей и машинного обучения // *Вестник Белгородского государственного технологического университета им. В.Г. Шухова*. 2024. № 3. С. 38–46. DOI: 10.34031/2071-7318-2024-9-3-38-46. EDN DHJYVT.
4. *Jaufer L., Kader S., Spalevic V., Škatarić G., Dudić B.* Machine learning practices during the operational phase of buildings : a critical review // *Applied Engineering Letters*. 2024. Vol. 9. Issue 1. Pp. 37–45. DOI: 10.46793/aeletters.2024.9.1.4
5. *Burgos D.A.T., Vargas R.C.G., Pedraza C., Agis D., Pozo F.* Damage Identification in Structural Health Monitoring : a Brief Review from its Implementation to the Use of Data-Driven Applications // *Sensors*. 2020. Vol. 20. Issue 3. P. 733. DOI: 10.3390/s20030733
6. *Entezami A., Sarmadi H., Behkamal B., Mariani S.* Health Monitoring of Large-Scale Civil Structures : an Approach Based on Data Partitioning and Classical Multidimensional Scaling // *Sensors*. 2021. Vol. 21. Issue 5. P. 1646. DOI: 10.3390/s21051646
7. *Thohari A.N.A., Karima A., Santoso K., Rahmawati R.* Crack Detection in Building Through Deep Learning Feature Extraction and Machine Learning Approach // *Journal of Applied Informatics and Computing*. 2024. Vol. 8. Issue 1. Pp. 1–6. DOI: 10.30871/jaic.v8i1.7431
8. *Hamishebahar Y., Guan H., So S., Jo J.* A Comprehensive Review of Deep Learning-Based Crack Detection Approaches // *Applied Sciences*. 2022. Vol. 12. Issue 3. P. 1374. DOI: 10.3390/app12031374
9. *Hsieh Y.-A., Tsai Y.J.* Machine learning for crack detection : review and model performance comparison // *Journal of Computing in Civil Engineering*. 2020. Vol. 34. Issue 5. DOI: 10.1061/(asce)cp.1943-5487.0000918
10. *Сикорский О.С.* Обзор сверточных нейронных сетей для задачи классификации изображений // *Новые информационные технологии в автоматизированных системах*. 2017. № 20. С. 37–42. EDN YNADUJ.
11. *Соснин А.С., Сулова И.А.* Функции активации нейросети: сигмоида, линейная, ступенчатая, ReLu, tahn // *Наука. Информатизация. Технологии. Образование*. 2019. С. 237–246. EDN VUZYBA.
12. *Дорафшан С., Томас Р.Дж., Магуайр М.* Сравнение глубоких сверточных нейронных сетей и детекторов краев для обнаружения трещин в бетоне на основе изображений // *Строительство и строительные материалы*. 2018. № 186. С. 1031–1045.
13. *Князева Н.В., Назойкин Е.А., Орехов А.А.* Применение искусственного интеллекта для обнаружения дефектов в строительных конструкциях // *Строительство и архитектура*. 2023. Т. 11. № 3. С. 18. DOI: 10.29039/2308-0191-2023-11-3-18-18. EDN SVXCZV.
14. *Наумов А.Е., Юдин А.В., Долженко А.В.* Совершенствование технологии проведения строительного-технических экспертиз с использованием аппаратно-программного комплекса автоматизированной дефектоскопии // *Вестник Белгородского государственного технологического университета им. В.Г. Шухова*. 2019. № 4. С. 61–69. DOI: 10.34031/article\_5cb824d26344e7.45899508. EDN FHPDTC.
15. *Князева Н.В., Лёвина Д.А.* Использование BIM-сценариев в работе служб эксплуатации // *Вестник Белгородского государственного технологического университета им. В.Г. Шухова*. 2019. № 5. С. 99–105. DOI: 10.34031/article\_5cd6df471c80b0.92422061. EDN IBNDHU.
16. *Курочкина Е.В.* Новые информационные системы в строительстве: Технологии информационных систем в проектировании, строительстве, экс-

платации зданий // Научный Лидер. 2022. № 25 (70). С. 27–30. EDN DVSRFK.

17. Князева Н.В., Медынцева А.А. Алгоритм создания системы мониторинга здания на основе интеграции технологий информационного моделирования и радиочастотной идентификации // Инженерный вестник Дона. 2022. № 12 (96). С. 646–659. EDN NSKKNZ.

18. Герц В.А., Князева Н.В. Анализ нормативно-технической и законодательной базы при реализации этапа эксплуатации зданий непроизводственного назначения с применением технологий информационного моделирования (ТИМ) // Строительство и архитектура. 2023. Т. 11. № 3. С. 9. DOI: 10.29039/2308-0191-2023-11-3-9-9. EDN BCGLSC.

19. Knyazeva N., Medincev A., Orekhov A. Configuring parameters of information model elements for integration with RFID tags // E3S Web of Conferences. 2023. Vol. 458. P. 09010. DOI: 10.1051/e3s-conf/202345809010

20. Munir M., Kiviniemi A., Jones S.W., Finnegan S. BIM-based operational information requirements for asset owners // Architectural Engineering and Design Management. 2020. Vol. 16. Issue 2. Pp. 100–114. DOI: 10.1080/17452007.2019.1706439

21. Zhou X., Qi Y., Tang H. Application of Artificial Intelligence Technology in Big Data Mining // Lecture Notes in Electrical Engineering. 2023. Pp. 737–744. DOI: 10.1007/978-981-99-2092-1\_92

22. Dale D.C., Crawford J., Klippel Z., Reiner M., Osslund T., Fan E. et al. A systematic literature review of the efficacy, effectiveness, and safety of filgrastim // Supportive Care in Cancer. 2018. Vol. 26. Issue 1. Pp. 7–20. DOI: 10.1007/s00520-017-3854-x

23. Elkalawy M., Al-Sakkaf A., Abdelkader E.M., Alfalah G. CRISP-DM-Based Data-Driven Approach for Building Energy Prediction Utilizing Indoor and Environmental Factors // Sustainability. 2024. Vol. 16. Issue 17. P. 7249. DOI: 10.3390/su16177249

Поступила в редакцию 20 сентября 2024 г.

Принята в доработанном виде 25 сентября 2024 г.

Одобрена для публикации 25 сентября 2024 г.

ОБ АВТОРАХ: **Наталья Викторовна Князева** — доцент кафедры информационных систем, технологий и автоматизации строительства; **Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ)**; 129337, г. Москва, Ярославское шоссе, д. 26; nknyazeva@mgsu.ru;

**Евгений Анатольевич Назойкин** — доцент кафедры автоматизированных систем управления биотехнологическими процессами; **Российский биотехнологический университет (РОСБИОТЕХ)**; 125080, г. Москва, Волоколамское шоссе, д. 11; NazojkinEA@mgupp.ru;

**Алексей Александрович Орехов** — аспирант кафедры автоматизированных систем управления биотехнологическими процессами; **Российский биотехнологический университет (РОСБИОТЕХ)**; 125080, г. Москва, Волоколамское шоссе, д. 11; aleksejjok@gmail.com.

## INTRODUCTION

Commissioned assets are ageing and extending the life of buildings has become a financially attractive solution due to cost savings on refurbishment projects. Today, structural defects are detected mainly through visual inspection, which provides an opportunity to assess the quality and condition of structural elements, identify elements to be repaired and emergency areas. However, this process is rather labour-intensive and depends entirely on the human factor — the experience and attention of the operating specialist. Despite the high level of training and professional qualifications, there is always a risk of human error when interpreting the collected information. This can lead to an incorrect assessment of the condition of load-bearing structures, which in turn can cause an inappropriate or even unsafe approach to repair and maintenance.

The application of modern machine learning methods opens up great opportunities in reducing the routine work of specialists and reducing the risks of errors due to the human factor.

A system for the detection of defects in building structures should not only identify problems, but also allow for the assessment of the amount of physical deterioration, based on statistical data on the one hand, and on the other hand, on archival data for a particular element, so that maintenance services can make informed decisions about the further maintenance of the building elements. In order not just to detect a problem, but to understand how critical the defect is for the building, the overall level of physical deterioration must be taken into account. For this purpose, it is convenient for maintenance professionals to use predictive data on the condition of buildings.

**MATERIALS AND METHODS**

A review of scientific papers allows us to conclude that the application of artificial intelligence (AI) is actively discussed and implemented in the practice of building operation [1, 2]. Basically, the approach to big data processing at this stage of the life cycle is built around the tasks of reducing heat loss and improving the energy efficiency of building facilities [3, 4]. On the other hand, there is a lot of research on the process of damage identification based on sensor readings [5, 6]. The accuracy of detecting discrepancies in structures due to continuous instrumental monitoring is much higher, but it requires computational power and significant financial costs to provide appropriate devices, which is not always reasonable. There are also works that focus on crack detection using computer vision, and high identification accuracy is achieved by converting RGB images into shades of grey and sub-

sequent processing using CLAHE (Contrast Limited Adaptive Histogram Equalization) — an algorithm that allows increasing the contrast and image detail [7]. A review of alternative approaches for solving the problem of crack image recognition presented in several scientific papers indicates that there are more than 60 deep learning options, but all of them require large amounts of data, including annotated data [8, 9].

The use of convolutional neural networks (CNN) for image classification is a common practice [10–13]. At the stage of construction and technical expertise, the task of defect identification arises and is solved for external structures, such as roofs, by applying fully deep CNN to recognize defects in video fragments made by cameras of small drones [14]. In addition, the application of information modelling technology in the operational phase of buildings has not been sufficiently explored [15–20]. However, no generalized studies focused on the construction of a system capable of dealing with different

```
<class 'pandas.core.frame.DataFrame'>
Int64Index: 38389 entries, 0 to 85249
Data columns (total 24 columns):
#   Column                                Non-Null Count  Dtype
---  -
0   formalname_region                    38389 non-null   object
1   stage                                38388 non-null   object
2   built_year                           38389 non-null   datetime64[ns]
3   exploitation_start_year              34599 non-null   object
4   house_type                           38389 non-null   object
5   floor_count_max                      38389 non-null   int64
6   floor_count_min                      38389 non-null   int64
7   entrance_count                      38389 non-null   int64
8   residents_count                     38389 non-null   int64
9   area_total                           38389 non-null   object
10  area_residential                     38363 non-null   object
11  area_non_residential                 36329 non-null   object
12  area_common_property                33139 non-null   object
13  area_land                            23540 non-null   object
14  deterioration_total                 38389 non-null   float64
15  determined_date                    38389 non-null   datetime64[ns]
16  floor_type                           24732 non-null   object
17  wall_material                        24739 non-null   object
18  alarm_reason                         38389 non-null   object
19  exp_name                             31743 non-null   object
20  exp_document_date                   31737 non-null   object
21  commission_document_date           33279 non-null   object
22  further_use                          38389 non-null   object
23  building_age_at_determined_date     38389 non-null   int64
dtypes: datetime64[ns](2), float64(1), int64(5), object(16)
memory usage: 7.3+ MB
None
```

Fig. 1. Output of information about DataFrame



types of defects and assessing the overall technical condition of a building could be found.

In this paper, it is decided to form an integrated approach based on the following components:

- a system for analyzing accumulated data on the physical deterioration of the existing housing stock;
- a system for detecting defects in building structures based on the analysis of AI-assisted photofixation data.

## RESULTS

Modern technologies, such as structural monitoring systems, include various measurement subsystems and greatly simplify the process of data accumulation. In the process of asset operation, a large amount of data arises, and their effective processing requires the use of different approaches and technologies [21]. Most often such systems are used to analyze the condition

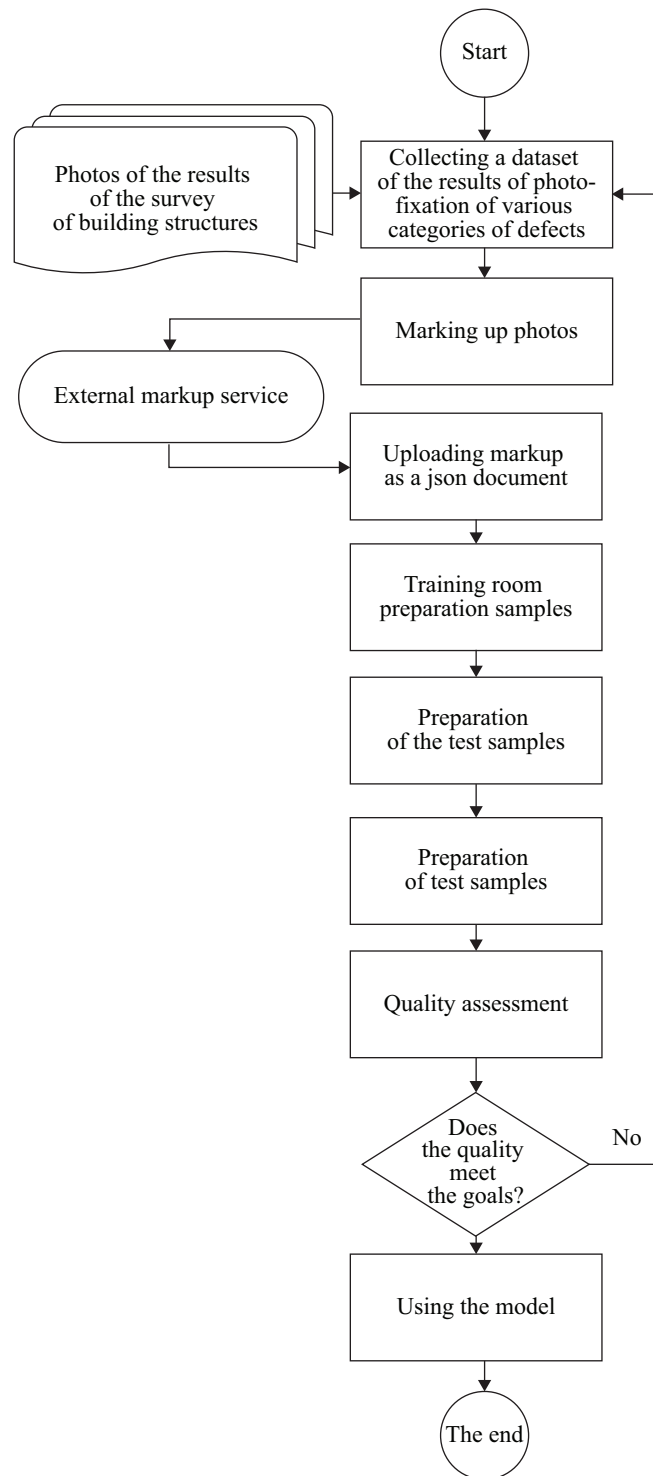


Fig. 2. Block diagram of the system construction sequence

of technically complex and hazardous objects due to their expensive implementation. Therefore, the main attention is drawn to the collection of statistical material.

Information on the parameters of the existing housing stock can be found in several public data sources:

1) information on emergency facilities of the housing and utilities sector according to open data from the Housing and Utilities Reform website;

2) data of the Territorial Development Fund on emergency buildings, apartment buildings in the regional capital repair programme by oblast;

3) Moscow City Government's open data portal.

It is also possible to scale the study and connect any other source of archival information.

The source information was downloaded from three open data sources. Then, based on the CRISP-DM model, an industry-independent intelligent analysis standard, they were preprocessed: categorical variables were converted into numerical variables, missing values in variables were filled in, Feature Engineering was performed, i.e. new variables for the table were extracted from the raw data [22]. Among the examples of the use of this methodology in the field of construction, and building maintenance in particular, are studies on predicting the energy consumption of buildings using indoor factors [23].

The following objectives were used to analyze the collected data:

- looking for correlation in the data;
- examination of statistical parameters of the data.

Target metrics: accuracy of physical wear prediction score, MAE. NumPy and Pandas were chosen among the libraries required for the work. Also, for visualization of information, preference was given to the widely used libraries Matplotlib and Seaborn, which allow transforming numerical data into convenient graphs, diagrams, histograms and other visual representations.

First of all, the information had to be loaded from the corresponding datasets. To do this, first the file encoding was determined, and then the file with the corresponding encoding was read. For example, the file encoding of the register of apartment blocks in Russia is UTF-8-SIG.

Due to the peculiarity of the structure, there are many null and extra values in the table, which meant that transformation was necessary. The data formats also needed to be transformed. Several new parameters were added, such as the age of the building at the time of technical inspection.

We then checked the composition of the data after data cleaning and preparation (Fig. 1).

The type of wall material is a rather important parameter for the conducted research, because, depending on it, different types of defects can be identified. Therefore, for further analyses different classes of wall materials should be coded with numerical values.

When training the model, several approaches were tried. We used linear and polynomial regression, and also

trained a decision tree model, which showed the best results in terms of coefficient of determination and MASE.

With digital transformation and continuous technological advances, there is a need for automation and increased control of building performance. The application of machine vision systems represents an effective means to improve the control processes and predictive disturbances of buildings. These systems are able to automate image processing and analysis, detect defects and deviations in building structures, which ultimately leads to improved building performance and durability.

Among the most suitable libraries in this area, OpenCV, PyTorch, Keras, Scikit-image and TensorFlow were used in this work.

The task was to build a classifier that detects one or more of the following defects:

1) biogenic surface damage (fungus, mould, moss) — formation of microorganisms on the wall surface due to high humidity and insufficient ventilation;

2) hairline cracks — thin, fine cracks in the surface of the wall;

3) deep cracks — cracks that penetrate inside the wall structure;

4) breach of the concrete protective layer and bare reinforcement — fracture of the concrete layer, which may lead to corrosion of the reinforcement;

5) delamination and collapse of the finishing coating — finishing elements such as plaster, tiles, paint are peeling away from the wall surface;



Fig. 3. Result of the system operation

6) freezing — damage caused by cyclic freezing and thawing;

7) moisture — moisture penetration into the wall due to water drainage failures or leaks.

In the course of the work, a block diagram of the system construction was developed (Fig. 2).

Analyzing the results involves examining the error matrix and evaluating the accuracy by class, which provides information about the model's ability to correctly classify and identify possible errors.

Yandex Images, Google Images were used to expand the dataset.

Data markup was performed on the robots service, then uploaded the markup as a json document.

The YOLOv8 model was applied for the purpose of training.

To verify the accuracy of the photofixation model, an experiment was performed. We collected images of structures where the defect locations were known in advance. The model successfully recognized 71–88 % of these defects, which confirmed the fairness of the chosen approach and its application in real conditions of building operation (Fig. 3).

However, there were also instances where the model was wrong, particularly for complex visual damage requiring a deeper understanding of the context, such as changes in coating colour or miniature cracks resulting from seasonal temperature fluctuations.

This necessitates the need to continuously train and retrain the model on new data to achieve greater accuracy.

## CONCLUSION

As a result of analyzing the information using various machine learning methods, it was possible to identify certain regularities and features linking the type of wall material, the age of the structure and the frequency of defects. The proposed approach will not only make the process of defect detection faster and more accurate, but will also provide a significant reduction in the risk of accidents and increase the safety of building operation. Thus, the application of AI methods in analyzing the condition of building structures will be an important step towards ensuring the reliability and durability of residential buildings, which will ultimately affect the quality of life of citizens.

## REFERENCES

1. Adewale B.A., Ene V.O., Ogunbayo B.F., Aigbavboa C.O. A Systematic Review of the Applications of AI in a Sustainable Building's Lifecycle. *Buildings*. 2024; 14(7):2137. DOI: 10.3390/buildings14072137
2. Mishra A., Pareek R.K., Kumar S., Varalakshmi S. A review of the current and future developments of artificial intelligence in the management and building sectors. *Multidisciplinary Reviews*. 2024; 6:2023ss068. DOI: 10.31893/multirev.2023ss068
3. Suleymanova L., Obaydi A. Building life cycle management at the operation stage using artificial neural network models and machine learning. *Bulletin of Belgorod State Technological University named after V.G. Shukhov*. 2024; 3:38-46. DOI: 10.34031/2071-7318-2024-9-3-38-46. EDN DHJYVT. (rus.)
4. Jaufer L., Kader S., Spalevic V., Škatarić G., Dudić B. Machine learning practices during the operational phase of buildings : a critical review. *Applied Engineering Letters*. 2024; 9(1):37-45. DOI: 10.46793/aeletters.2024.9.1.4
5. Burgos D.A.T., Vargas R.C.G., Pedraza C., Agis D., Pozo F. Damage Identification in Structural Health Monitoring: A Brief Review from its Implementation to the Use of Data-Driven Applications. *Sensors*. 2020; 20(3):733. DOI: 10.3390/s20030733
6. Entezami A., Sarmadi H., Behkamal B., Mariani S. Health Monitoring of Large-Scale Civil Structures : an Approach Based on Data Partitioning and Classical Multidimensional Scaling. *Sensors*. 2021; 21(5):1646. DOI: 10.3390/s21051646
7. Thohari A.N.A., Karima A., Santoso K., Rahmawati R. Crack Detection in Building Through Deep Learning Feature Extraction and Machine Learning Approach. *Journal of Applied Informatics and Computing*. 2024; 8(1):1-6. DOI: 10.30871/jaic.v8i1.7431
8. Hamishebahar Y., Guan H., So S., Jo J. A Comprehensive Review of Deep Learning-Based Crack Detection Approaches. *Applied Sciences*. 2022; 12(3):1374. DOI: 10.3390/app12031374
9. Hsieh Y.-A., Tsai Y.J. Machine learning for crack detection: review and model performance comparison. *Journal of Computing in Civil Engineering*. 2020; 34(5). DOI: 10.1061/(asce)cp.1943-5487.0000918
10. Sikorskij O.S. Review of convolutional neural networks for the problem of image classification. *New Information Technologies in Automated System*. 2017; 20:37-42. EDN YNADUJ. (rus.)
11. Sosnin A.S., Suslova I.A. Functions of neural net activation: sigmoid, linear, step, ReLu, tan. Science. *Information Technologies. Education*. 2019; 237-246. (rus.)
12. Dorafshan S., Tomas R.Dzh., Maguajr M. Comparison of deep convolutional neural networks and edge detectors for detecting cracks in concrete based on images. *Construction and Building Materials*. 2018; 186:1031-1045. (rus.)
13. Knyazeva N., Nazojkin E., Orekhov A. The use of artificial intelligence to detect defects in building structures. *Construction and Architecture*. 2023; 11(3):18. DOI: 10.29039/2308-0191-2023-11-3-18-18. EDN SVXCZV. (rus.)

14. Naumov A., Yudin D., Dolzhenko A. Improving the technology of construction and technical expertise using a hardware and software complex of automated inspection. *Bulletin of Belgorod state technological university named after V.G. Shukhov*. 2019; 4:61-69. DOI: 10.34031/article\_5cb824d26344e7.45899508. EDN FHPDTK. (rus.).
15. Knyazeva N., Levina D. Using BIM scenarios in operation services. *Bulletin of Belgorod state technological university named after V.G. Shukhov*. 2019; 5:99-105. DOI: 10.34031/article\_5cd6df471c80b0.92422061. EDN IBNDHU. (rus.).
16. Kurochkina E.V. New information systems in construction: Technologies of information systems in the design, construction, and operation of buildings. *Scientific Leader*. 2022; 25(70):27-30. EDN DVSRFK. (rus.).
17. Knyazeva N.V., Medyntsev A.A. An algorithm for creating a building monitoring system based on the integration of building information modeling and radio frequency identification technologies. *Engineering journal of Don*. 2022; 12(96):646-659. EDN NSKKNZ. (rus.).
18. Gerc V., Knyazeva N. Regulatory documentation for the operation of buildings with TIM. *Construction and Architecture*. 2023; 11(3):9. DOI: 10.29039/2308-0191-2023-11-3-9-9. EDN BCGLSL. (rus.).
19. Knyazeva N., Medincev A., Orekhov A. Configuring parameters of information model elements for integration with RFID tags. *E3S Web of Conferences*. 2023; 458:09010. DOI: 10.1051/e3sconf/202345809010
20. Munir M., Kiviniemi A., Jones S.W., Finnegan S. BIM-based operational information requirements for asset owners. *Architectural Engineering and Design Management*. 2020; 16(2):100-114. DOI: 10.1080/17452007.2019.1706439
21. Zhou X., Qi Y., Tang H. Application of Artificial Intelligence Technology in Big Data Mining. *Lecture Notes in Electrical Engineering*. 2023; 737-744. DOI: 10.1007/978-981-99-2092-1\_92
22. Dale D.C., Crawford J., Klippel Z., Reiner M., Osslund T., Fan E. et al. A systematic literature review of the efficacy, effectiveness, and safety of filgrastim. *Supportive Care in Cancer*. 2018; 26(1):7-20. DOI: 10.1007/s00520-017-3854-x
23. Elkabalawy M., Al-Sakkaf A., Abdelkader E.M., Alfalah G. CRISP-DM-Based Data-Driven Approach for Building Energy Prediction Utilizing Indoor and Environmental Factors. *Sustainability*. 2024; 16(17):7249. DOI: 10.3390/su16177249

Received September 20, 2024.

Adopted in revised form on September 25, 2024.

Approved for publication on September 25, 2024.

**B I O N O T E S :** Natal'ya V. Knyazeva — Associate Professor of the Department of Information Systems, Technology and Automation of Construction; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; nknayazeva@mgsu.ru;

**Evgenij A. Nazojkin** — Associate Professor of the Department of Automated Control Systems for Biotechnological Processes; **Russian Biotechnological University (BIOTECH University)**; 11 Volokolamskoe shosse, Moscow, 125080, Russian Federation; NazojkinEA@mgupp.ru;

**Aleksej A. Orekhov** — postgraduate student of the Department of Automated Control Systems for Biotechnological Processes; **Russian Biotechnological University (BIOTECH University)**; 11 Volokolamskoe shosse, Moscow, 125080, Russian Federation; aleksejjok@gmail.com.