



# СИСТЕМНЫЙ АНАЛИЗ И УПРАВЛЕНИЕ SYSTEM ANALYSIS AND PROCESSING OF KNOWLEDGE

УДК 004.93.12

DOI 10.52575/2687-0932-2025-52-1-156-167

## Использование алгоритмов машинного обучения для оценки степени повреждений объектов жилой инфраструктуры

Головко Я.Ю., Ильинская Е.В.

Белгородский государственный национальный исследовательский университет  
Россия, 308015, г. Белгород, ул. Победы, 85  
mariopwnz1337@gmail.com

**Аннотация.** В современном мире применение алгоритмов машинного обучения приобретает ключевое значение для оценки повреждений объектов жилой инфраструктуры после чрезвычайных ситуаций, включая природные катастрофы, военные конфликты и техногенные аварии. В исследовании рассматривается использование свёрточных нейронных сетей (CNN), рекуррентных нейронных сетей (RNN) и гибридных архитектур (CNN-RNN) для автоматизации анализа степени разрушений. На примере аэрофотоснимков, спутниковых данных и изображений из социальных сетей продемонстрирована эффективность моделей ResNet50, ResNet101, YOLOv5 и VGG19 в обнаружении структурных дефектов, классификации тяжести повреждений и оптимизации восстановительных работ. Эксперименты на наборах данных (после взрыва в Бейруте, землетрясения в Вэньчуане) показали, что модифицированная архитектура YOLOv5 с механизмами внимания (Ghost bottleneck, CBAM) достигает средней точности (mAP) 93,43 % в режиме реального времени, а ResNet50 демонстрирует точность 95,92 % при многоклассовой классификации ущерба. Однако сохраняются проблемы с распознаванием мелких дефектов (трещины, сколы) из-за ограничений разрешения и помех (деревья, строительные леса). Для повышения устойчивости моделей применены методы аугментации данных (повороты, цветокоррекция) и расширены обучающие выборки (до 8192 изображений). Сравнение с традиционными методами (визуальный осмотр, картографирование) подтвердило преимущества машинного обучения: скорость обработки, минимизация человеческого фактора и точное распределение ресурсов.

**Ключевые слова:** машинное обучение, оценка повреждений инфраструктурных объектов, свёрточные нейронные сети (CNN), YOLOv5, ResNet

**Для цитирования:** Головко Я.Ю., Ильинская Е.В. 2025. Использование алгоритмов машинного обучения для оценки степени повреждений объектов жилой инфраструктуры. *Экономика. Информатика*, 52(1): 156–167. DOI 10.52575/2687-0932-2025-52-1-156-167

## Use of Machine Learning Algorithms for Assessing the Degree of Damage to Residential Infrastructure

Yaroslav Yu. Golovko, Elena V. Ilyinskaya

Belgorod State National Research University, 85 Pobeda St, Belgorod 308015, Russia  
mariopwnz1337@gmail.com

**Abstract.** In the modern world, the application of machine learning (ML) algorithms has become increasingly critical across various domains, particularly in assessing damage to residential infrastructure

© Головко Я.Ю., Ильинская Е.В., 2025

following emergencies such as natural disasters, military conflicts, or human-induced incidents. This study explores the integration of convolutional neural networks (CNNs), recurrent neural networks (RNNs), and hybrid architectures (CNN-RNN) to automate damage evaluation, enabling rapid and precise crisis response. By analyzing aerial imagery, satellite data, and crowdsourced visual content, ML models like ResNet50, ResNet101, YOLOv5, and VGG19 demonstrate significant potential in detecting structural damage, classifying severity levels, and prioritizing recovery efforts. Experimental results from benchmark datasets (e.g., post-explosion imagery from Beirut, earthquake-damaged buildings in Wenchuan) reveal that YOLOv5-based architectures achieve up to 93.43 % mean average precision (mAP) in real-time object detection, while ResNet50 attains 95.92 % accuracy in multi-class damage classification. However, challenges persist in recognizing fine-grained defects (e.g., cracks, spalls) due to resolution limitations and occlusions. The study highlights the advantages of attention mechanisms (e.g., CBAM, Ghost bottlenecks) and data augmentation techniques in improving model robustness. Comparative analysis of traditional manual inspections versus ML-driven approaches underscores the latter's efficiency in resource allocation, accelerated reconstruction timelines, and enhanced safety protocols.

**Keywords:** machine learning, infrastructure damage assessment, convolutional neural networks (CNN), YOLOv5, ResNet

**For citation:** Golovko Ya. Yu., Ilyinskaya E. V. 2025. Use of Machine Learning Algorithms for Assessing the Degree of Damage to Residential Infrastructure. *Economics. Information technologies*, 52(1): 156–167 (in Russian). DOI 10.52575/2687-0932-2025-52-1-156-167

## Введение

Оценка степени повреждений объектов жилой инфраструктуры является ключевым аспектом современного общества, влияющим на безопасность граждан, эффективное управление кризисными ситуациями, финансовые решения и инновации в области технологий. В условиях чрезвычайных ситуаций, таких как природные катастрофы или аварии, оценка ущерба становится неотъемлемой частью системы гражданской обороны. Точная и оперативная оценка позволяет минимизировать последствия кризисов и обеспечить быстрое восстановление инфраструктуры.

Для страховых компаний, финансовых учреждений и государственных органов оценка ущерба является ключевым элементом при разработке страховых полисов, определении размеров возмещения убытков и планировании финансовых ресурсов. Применение алгоритмов машинного обучения для оценки ущерба открывает новые возможности для автоматизации процессов, улучшения точности прогнозирования и оптимизации использования ресурсов. Оценка степени повреждений объектов жилой инфраструктуры также имеет прямое отношение к вопросам устойчивого развития городов и регионов, позволяя оценить уровень уязвимости жилых зон и разработать меры по их укреплению.

Точное определение уровня повреждений жилой инфраструктуры обладает рядом важных преимуществ и значимых аспектов. Точная оценка позволяет оптимизировать расходы, фокусируя усилия на объектах с наибольшим ущербом. Знание степени повреждений помогает определить приоритетные задачи и план действий для быстрого и качественного восстановления, а адекватная оценка повреждений помогает предотвратить возможные аварии и обеспечить безопасность при проведении работ по восстановлению.

В целом актуальность данной темы обусловлена не только текущими вызовами в области безопасности и управления кризисными ситуациями, но и потенциалом для применения инновационных подходов, таких как машинное обучение, в решении этих задач.

## Традиционные методы оценки разрушений инфраструктуры

Одним из наиболее распространенных традиционных методов визуальной оценки степени повреждений объектов жилой инфраструктуры после военных действий является оценка вручную. Этот процесс включает в себя отправку специалистов на место

разрушения для тщательного осмотра и оценки уровня повреждений. Специалисты могут использовать стандартизированные шкалы оценки, фотографии, видео и другие средства для документирования и анализа разрушений.

Другим традиционным методом визуальной оценки степени повреждений является использование картографических данных. Специалисты могут анализировать снимки спутников, аэросъемку и другие геопространственные данные для определения областей с разрушениями и оценки масштаба повреждений. Это позволяет создать карты разрушений, которые помогут при планировании и проведении восстановительных работ.

Кроме того, традиционные методы визуальной оценки могут включать экспертные оценки степени повреждений. Специалисты по строительству, инженеры, архитекторы и другие профессионалы могут проводить экспертизу разрушений и давать свои рекомендации по восстановлению объектов жилой инфраструктуры.

К сильным сторонам традиционных методов визуальной оценки относятся их детальность, позволяющая выявлять все аспекты разрушений, надежность экспертных заключений, основанных на профессиональном опыте, а также доступность – эти подходы не требуют сложного оборудования. Однако традиционные методы визуальной оценки могут быть трудоемкими и не всегда эффективными при больших объемах данных. Также одним из недостатков традиционных методов является зависимость от человеческого фактора.

### **Использование алгоритмов машинного обучения для оценки разрушений инфраструктуры**

Использование алгоритмов машинного обучения для оценки степени повреждений объектов жилой инфраструктуры вследствие военных действий представляет собой важную и актуальную задачу в современном мире. Военные конфликты и боевые действия могут привести к серьезным разрушениям зданий, инфраструктуры и жилых объектов, что требует оперативной и точной оценки ущерба.

Применение методов машинного обучения в данной области может значительно упростить и ускорить процесс оценки повреждений. Алгоритмы машинного обучения могут анализировать данные, полученные с помощью дронов [Zhao et al., 2024; Hansen, de Figueiredo, 2024], спутников [Van Etten, 2018; Haryono, Jati, Jatmiko, 2024], камер видеонаблюдения [Hu et al., 2022] и других источников, и автоматически выявлять поврежденные участки, классифицировать их по степени ущерба и предоставлять информацию для оперативного реагирования и восстановления.

Польза использования машинного обучения в данной теме заключается в повышении эффективности и точности оценки повреждений, сокращении времени на проведение инвентаризации ущерба, а также в возможности предотвращения дальнейших разрушений путем оперативного реагирования на обнаруженные проблемы. Это позволит не только улучшить процессы восстановления после военных действий, но и способствует повышению безопасности и благополучия граждан, живущих в зоне конфликтов.

В исследовании [Kallas, Napolitano, 2023] было изучено автоматизированное обнаружение крупномасштабных повреждений исторических зданий в районах, пострадавших от стихийных бедствий, с использованием сегментации изображений. Для сравнения использовались три популярные модели сверточных нейронных сетей: ResNet50, ResNet101 и ResNest50. ResNet50 – это сверточная нейронная сеть, состоящая из 50 слоев, разработанная для классификации изображений. Она использует блоки с остаточным соединением (residual connections), что позволяет эффективно обучать глубокие сети и избежать проблемы затухания градиента [Lin, Wu, 2023]. ResNet101 – это более глубокая версия ResNet, состоящая из 101 слоя. Она имеет больше слоев, чем ResNet50, что позволяет ей извлекать более сложные признаки из изображений, но требует больше вычислительных ресурсов для обучения [Zhang, 2022]. ResNest50 – это архитектура, основанная на идее "Split-Attention", которая позволяет сети уделять внимание различным аспектам

изображения. Она представляет собой улучшенную версию ResNet с более эффективным использованием информации из изображений [Indumathi, Santhoshsivan, Selvakumar, 2024].

В качестве набора данных использовались 100 аэрофотоснимков поврежденных зданий, сделанных после взрыва в Бейруте 4 августа 2020 года. Для увеличения набора данных была использована библиотека *imgaug*, что дало прибавку в 85 %. Библиотека использует аугментацию данных, что позволяет дополнить датасет путем преобразования исходных изображений [Mikołajczyk, Grochowski, 2018]. Исходные снимки имели высокое разрешение (5472×3648), поэтому для обучения они были сжаты до разрешения 512×512 и 28×28 пикселей. Учитывая небольшой размер набора данных, обучение было произведено в 50 эпох по 100 шагов на эпоху, чтобы предотвратить переобучение. Обучение производилось с помощью библиотек TensorFlow и Keras на графическом процессоре Intel(R) UHD Graphics 630 с 8 ГБ памяти.

Удалось добиться следующих результатов: точность обнаружения обрушения стены составила 83,17 % для обучающего набора и 86,81 % для проверочного набора. Аналогичным образом воспроизводимость обнаружения повреждений при обрушении стены достигла 84,80 % и 80,61 % для обучающего набора и проверочного набора соответственно. Оценка F1 модели 3 составила 83,96 % для обучающего набора и 83,59 % для проверочного набора, что указывает на то, что модель имела сбалансированную производительность с точки зрения точности и полноты. Однако в некоторых случаях наблюдались ошибочные определения из-за присутствия деревьев, которые частично закрывали повреждение от обрушения стены, или наличия деревянных и металлических строительных лесов внутри помещения, где произошло повреждение стены. В некоторых случаях были сделаны ошибочные определения из-за сходства разрушенных окон с реальными повреждениями от обрушения стен. Примеры входных изображений и результаты распознавания изображены на рис. 1. Результаты обучения и проверки моделей представлены в табл. 1.



Рис 1. Примеры входных изображений и результаты распознавания  
Fig. 1. Examples of input images and recognition results

Таблица 1  
 Table 1

Результаты обучения и проверки  
 Results of training and testing

Расчетные метрики	ResNet50		ResNet101		ResNest50	
	Обучение	Проверка	Обучение	Проверка	Обучение	Проверка
Общая точность	66,73 %	62,72 %	73,84 %	69,00 %	72,38 %	71,91 %
Точность прогнозирования	79,75 %	82,14 %	84,44 %	83,51 %	83,17 %	86,81 %
Полнота	80,03 %	72,63 %	85,47 %	79,16 %	84,80 %	80,61 %
F1 показатель	79,88 %	77,09 %	84,95 %	81,36 %	83,96 %	83,59 %

В исследовании [Liu et al., 2022] было изучено обнаружение повреждений зданий на уровне земли в режиме реального времени на основе YOLOv5 с использованием наземных изображений. В качестве основной модели для обучения была выбрана YOLOv5 (You Only Look Once version 5) – это современная сверточная нейронная сеть для обнаружения объектов на изображениях в реальном времени [Kaur, Singh, 2023]. Основная идея YOLO заключается в том, что нейронная сеть делит изображение на сетку ячеек и предсказывает ограничивающие рамки и классы объектов в каждой ячейке одновременно [Jiang et al., 2022].

В проекте также был использован Ghost bottleneck – это концепция, которая используется в некоторых современных архитектурах нейронных сетей. Этот подход был представлен для улучшения эффективности и производительности нейронных сетей. Вместо использования обычного узкого места (bottleneck) в сверточных слоях, где количество фильтров уменьшается и затем увеличивается, используется два параллельных пути: один с обычным bottleneck (обычные свертки), а другой с уменьшенным количеством фильтров (ghost модуль). Это позволяет сети изучать более широкий спектр признаков, сохраняя при этом вычислительную эффективность. Ghost bottleneck помогает уменьшить количество параметров и операций, не ухудшая при этом качество предсказаний [Han et al., 2020].

Также был использован СВМ (Convolutional Block Attention Module) – это модуль внимания, который был представлен для улучшения способности сверточных нейронных сетей выделять важные признаки изображений [Woo et al., 2018]. СВМ состоит из двух основных компонентов: блока канального внимания (Channel Attention Module) и блока пространственного внимания (Spatial Attention Module). СВМ обычно интегрируется в сверточные нейронные сети, чтобы улучшить их способность к извлечению информативных признаков. Этот модуль помогает сети более эффективно использовать информацию изображения, что может привести к улучшению качества предсказаний и повышению производительности модели.

Все эксперименты проводились на ПК с памятью 40 ГБ, процессором Intel Xeon E5 с 2,7 ГГц и графическим процессором Tesla K80 с 24 ГБ. Некоторые основные параметры предлагаемой модели таковы: предварительно обученные веса с использованием ImageNet, размер пакета 4, начальная скорость обучения 0,01 и итерации 300 эпох. Алгоритмы обнаружения часто оцениваются с точки зрения точности и скорости. Эффективность алгоритма оценивалась общей точностью, средним значением отзыва, F1-оценкой 0,75 и средней точностью (mAP) [Henderson, Ferrari, 2017].

В качестве набора данных были использованы 856 изображений разрешением 3968×2976 пикселей со смартфонов и камер, которые были аннотированы для распознавания повреждений, а 3918 обрезанных изображений повреждений – с разрешением 800×800 пикселей. Увеличение данных помогло предоставить сети более разнообразные данные, что привело к более обобщаемым результатам. Учитывая размер изображения и характеристики повреждения, выбранные методы улучшения включали

поворот изображения, переворот изображения, преобразование цвета и растяжение изображения. Всего было получено 8192 изображения и отмечено 44 059 участков повреждения. Набор данных, относящийся к землетрясению в Вэньчуань, был разделен на две группы: обучающий набор для обучения модели, на который приходилось 70 % данных, и тестовый набор для оценки модели, на который приходилось оставшиеся 30 %. Поскольку количество поврежденных деталей на разных изображениях отличалось друг от друга, конкретная выборка для обучения и тестирования была отфильтрована вручную.

Для оценки классификации результаты сравнивались с вручную размеченными эталонными данными на основе результатов визуальной интерпретации с использованием наземных изображений. В этом исследовании точность, полнота, общая точность и показатель F1 использовались для оценки эффективности извлечения и классификации для каждой сцены

Были выбраны четыре репрезентативных сценария повреждений, включающих четыре цели повреждения, чтобы продемонстрировать точность обнаружения. Итоговые соответствующие показатели точности четырех целей поражения приведены в табл. 2. Число рядом с меткой означает уверенность в прогнозируемом типе повреждения. Высокая достоверность означает, что повреждение здания может быть точно обнаружено и выполнено относительно надежно. Высокая степень достоверности означала, что модель точно определила ущерб, и очень небольшой ущерб зданию был пропущен. Во всех случаях высокой уверенности в признании ущерба достоверность находилась выше значения 0,86. Самый высокий показатель достоверности до 0,98 был достигнут при обнаружении обломков и обрушений. Уверенность в обнаружении сколов и трещин была сравнительно низкой, что объясняло небольшим размером и масштабом повреждений.

Таблица 2  
Table 2

Результаты YOLOv5 по критериям  
YOLOv5 results by criteria

Типы разрушений	Точность	Полнота	Карта	F1-показатель
Обломки	95,56	92,95	94,26	92,42
Обрушение	91,35	90,93	93,53	91,86
Сколы	89,82	90,18	91,28	89,28
Трещины	87,91	89,58	90,63	90,59
Среднее	91,16	90,91	92,43	91,06

В исследовании [Li et al., 2018.] были изучены локализация и количественная оценка ущерба на изображениях в социальных сетях. В качестве основной модели для обучения и сравнения результатов была выбрана VGG19 – сверточная нейронная сеть, обладающая 16 сверточными слоями и 3 полносвязными [Karacı A., 2022]. Каждый слой свертки оснащен нелинейной активацией ReLU [Krizhevsky, Sutskever, Hinton, 2012]. Также была представлена карта обнаружения повреждений (DDM), основанная на градиентно-взвешенной карте активации классов (GCAM). GCAM использует градиенты целевой категории для вычисления веса конкретной категории для каждой карты признаков слоя свертки [Selvaraju et al., 2017]. Веса используются для агрегирования карт признаков последнего сверточного слоя при предположении, что последний уровень обеспечивает наилучший компромисс между семантическими признаками высокого уровня и пространственной информацией.

Использовались два набора данных: собранный с помощью Google: 308 изображений с помощью ключевых слов «Непал», «здание» и «ущерб», а также 311 изображений зданий без ущерба, а также наборы данных ресурса «AIDR» (платформа для фильтрации и классификации сообщений в социальных сетях, связанных с чрезвычайными ситуациями, катастрофами и

гуманитарными кризисами). Были использованы датасеты с изображениями землетрясения в Непале, землетрясения в Эквадоре, тайфун Хагупит и урагана Мэтью.

Затем был описан подход к обучению моделей и оценке результатов:

1) для классификации изображений использовалась VGG19 (есть ущерб или нет);  
 2) для обнаружения дефектов на отфильтрованных изображениях использовалась DDM (карта обнаружений повреждений), которая генерировалась путем взвешивания последнего сверточного поля модели;

3) для представления серьезности ущерба для каждого изображения рассчитывался показатель серьезности ущерба (DAV), полученное на основе тепловой карты DDM.

Карта ущерба от стихийного бедствия использует числовые значения для измерения интенсивности каждого пикселя изображения и может быть представлена в виде тепловой карты. Было взято среднее значение по всем числовым значениям тепловой карты изображения и использовано полученное значение.

В первой строке показана средняя точность классификаторов на основе DAV (более 5 независимых прогонов) вместе со стандартным отклонением. Вторая и третья строка показывает среднюю точность моделей CNN. Результаты простого классификатора, основанного на DAV, аналогичны результатам модели CNN для землетрясения в Эквадоре и урагана Мэтью (т. е. результаты статистически не отличаются на основе t-критерия  $sp \leq 0.05$ ). Хотя точность CNN в целом выглядит лучше, результаты показывают, что DAV может фиксировать серьезность ущерба (в непрерывном масштабе) и может помочь создать простые и интерпретируемые классификаторы. Результаты представлены в табл. 3.

Таблица 3

Table 3

Результаты  
 Results by models

Метод	Землетрясение в Непале	Землетрясение в Эквадоре	Тайфун Хагупит	Ураган Мэтью
DAV	0,801±0,013	0,886±0,018	0,793±0,017	0,533±0,043
VGG19	0,851±0,003	0,901±0,013	0,852±0,018	0,603±0,151
VGG16	0,840	0,870	0,810	0,740

В исследовании [Chachra et al., 2022] было изучено обнаружение поврежденных зданий с использованием краудсорсинговых изображений в реальном времени. Для обучения были выбраны три основные модели: AlexNet, VGG19, ResNet50. AlexNet – это сверточная нейронная сеть, разработанная для классификации изображений [Krizhevsky, Sutskever, Hinton, 2017]. AlexNet состоит из 5 сверточных слоев и 3 полносвязных слоев. Она использует технику дропаута для борьбы с переобучением и функцию активации ReLU для ускорения обучения.

Для оценки разрушений на фотографиях были выбраны четыре критерия, описывающие степень возможных разрушений:

- 1) без ущерба;
- 2) легкие повреждения: видимые узкие трещины, сколы и/или крайне ограниченное растрескивание бетона;
- 3) умеренные повреждения: трещины, большая площадь сколов бетонного покрытия без обнажения стальных стержней;
- 4) серьезное повреждение: разрушение основного слоя бетона, выпучивание или разрушение арматуры.

В качестве набора данных использовались в общей сложности 2260 изображений, собранных в ходе исследования ущерба, из архива разведки землетрясений (EERI) и

изображений Google. Количество изображений по критериям составляет 496, 404, 580 и 780 соответственно. Перед обучением применяются предварительная обработка изображения и изменение его размера. Кроме того, 80 % полученных изображений для каждого класса повреждений выбираются в качестве обучающего набора, а 20 % – в качестве тестового набора. Набор проверки выбирается в размере 20 % обучающего набора, а остальная часть обучающего набора используется для обучения модели.

Обучение проводилось в MATLAB R2019a на двух компьютерах: Alienware Aurora R8 (Core i7-9700K @ 3,60 ГГц, 16 ГБ памяти DDR4 и 8 ГБ памяти GeForce RTX 2070 GPU) и Lenovo Legion Y740 (Core i7-8750H с частотой 2,20 ГГц, 16 ГБ памяти DDR4 и 8 ГБ памяти (GPU GeForce RTX 2070 max-q).

Хотя точность тестирования среди всех трех предварительно обученных моделей относительно близка, ResNet-50, который имеет самую глубокую архитектуру, дает немного более высокую точность, чем две другие модели сверточных нейронных сетей. Точность обучения и проверки превышает 90 % примерно после 80 эпох обучения и приближается к 100 % в конце. Результаты показывают, что обученная модель способна классифицировать различные состояния повреждения с достаточно высокой точностью, однако точность классификации в отношении умеренного повреждения и серьезного повреждения не так высока, как в отношении класса отсутствия повреждений и легких повреждений. Параметры обучения и результаты представлены в табл. 4.

Таблица 4  
Table 4

Параметры обучения и результаты  
Training parameters and results

Модель	AlexNet	VGG19	ResNet50
Входной размер	227×227×3	224×224×3	224×224×3
Темп обучения	0,0001	0,0001	0,0001
Регуляризация	0,0001	0,0001	0,0001
Коэффициент мощности	0,90	0,90	0,90
Точность при тестировании	93,15 %	95,63 %	95,92 %
Точность при проверке	85,17 %	87,17 %	87,47 %

Алгоритмы машинного обучения демонстрируют значительный потенциал в автоматизации оценки ущерба. Исследования на основе моделей ResNet, YOLOv5 и VGG19 показывают, что точность классификации повреждений достигает 80–95 %, а обработка данных в режиме реального времени возможна при использовании оптимизированных архитектур, таких как Ghost bottleneck и СВМ. Преимущества ML-подходов включают скорость анализа, масштабируемость и способность работать с разнородными данными (дроны, спутники, социальные медиа). Однако их эффективность зависит от качества и объема обучающих данных: небольшие датасеты требуют аугментации, а шумы в краудсорсинговых изображениях снижают точность. Кроме того, сложные модели (например, ResNet101) требуют высоких вычислительных ресурсов, что ограничивает их применение в полевых условиях.

Сравнение подходов показывает, что гибридные методы, сочетающие ML с экспертной валидацией, могут стать оптимальным решением. Традиционные методы обеспечивают точность в локальных задачах, тогда как ML-алгоритмы эффективны для быстрого анализа крупных территорий. Например, YOLOv5 достиг средней точности 91 % при обнаружении трещин и обрушений, но его внедрение требует значительных ресурсов. Для улучшения результатов необходимо решать проблемы интерпретируемости моделей, как в случае с DAV-метрикой, и расширять датасеты для обучения на редких классах повреждений.

Среди основных недостатков современных методов выделяется сильная зависимость от качества входных данных: низкое разрешение изображений или наличие визуальных помех (деревья, строительные леса) существенно снижают надежность распознавания. Тепловые карты повреждений (DDM), хотя и улучшают визуальную интерпретацию, не предоставляют количественных метрик для оценки масштаба ущерба. Кроме того, сохраняется проблема распознавания мелких дефектов – трещины и сколы часто остаются незамеченными из-за ограничений масштаба или артефактов сжатия. В табл. 5 представлены обобщенные данные по каждому исследованию.

Таблица 5  
Table 5

Обобщение опыта исследований  
Generalization of research experience

Используемые модели/алгоритмы	Набор данных	Метрики эффективности	Преимущества	Недостатки
ResNet50, ResNet101, ResNest50	100 аэрофотоснимко в Бейрута	F1: 83,59 % (валидация), точность: 86,81 %	Высокая детализация анализа, использование аугментации данных	Ошибки из-за помех, ограниченный размер данных
YOLOv5 (LA-YOLOv5 с Ghost bottleneck, CBAM)	8192 изображений землетрясения	mAP: 93,43 %, F1: 92,26 %, точность: 92,47 %	Высокая скорость и точность, эффективность в реальном времени	Сложности с мелкими повреждениям и (трещины)
VGG19 + DDM (на основе GCAM)	Данные из соцсетей	Точность: 80–90 % (зависит от события)	Интерпретируемость, использование данных из соцсетей	Зависимость от качества изображений
ResNet50, AlexNet, VGG19	2260 изображений из открытых источников	Точность: 95,92 % (ResNet50)	Хорошая классификация легких и серьезных повреждений	Низкая точность для умеренных повреждений

Для решения проблемы ограниченности реальных данных, особенно для редких классов повреждений (например, трещины, сколы), а также зависимости качества моделей от объема обучающей выборки можно использовать генеративно-состязательные сети (GAN) для создания синтетических изображений разрушений [Creswell et al., 2018]. Например, модели типа StyleGAN3 могут генерировать фотореалистичные изображения с заданными характеристиками (степень повреждения, тип инфраструктуры) [Zhu, 2023]. Для снижения риска ошибок из-за помех можно использовать пространственную аугментацию для генерации изображений с частично скрытыми объектами (например, деревьями или строительными лесами).

Также была выявлена проблема ограниченности CNN в улавливании глобальных зависимостей (например, связь между трещиной в стене и деформацией фундамента). Использование Vision Transformers позволит сделать разбиение изображения на патчи (например, 16×16 пикселей) и обработку их через механизм самовнимания, что даст возможность анализировать контекст всей картинке [Khan, 2022]. Таким образом, можно использовать гибридную модель, когда CNN используется для первичного извлечения признаков (например, границы разрушений), а Vision Transformers – для анализа контекста

(например, оценка масштаба ущерба). В случае с YOLOv5 замена отдельных слоев на блоки внимания могла дать улучшения обнаружения мелких дефектов.

Для повышения точности классификации редких классов можно использовать F2-Score (акцент на полноту) для минимизации пропусков критических повреждений. Для оценки качества модели на несбалансированных данных может быть использована метрика Matthews Correlation Coefficient (MCC), которая учитывает все четыре записи матрицы путаницы (истинно положительные, истинно отрицательные, ложно положительные и ложно отрицательные), предоставляя более репрезентативную картину производительности классификатора по сравнению с другими метриками, такими как оценка F1, которая игнорирует истинно отрицательные [Chicco, Jurman 2020].

### Заключение

В современном мире, где различные чрезвычайные ситуации, такие как природные катастрофы или технические аварии, могут привести к разрушению объектов жилой инфраструктуры, использование алгоритмов машинного обучения для оценки степени повреждений становится все более актуальным и перспективным подходом. Мы видим, что с помощью машинного обучения можно эффективно классифицировать и оценивать степень повреждений объектов жилой инфраструктуры после таких событий. Это позволяет быстро и точно определить, какие объекты нуждаются в наиболее срочном восстановлении и ремонте, что важно для обеспечения жилья и безопасности людей.

Перспективы использования машинного обучения для оценки повреждений после чрезвычайных ситуаций очень обнадеживающие. Автоматизированные методы позволяют ускорить процесс оценки и восстановления жилой инфраструктуры, снизить человеческий фактор и повысить точность оценки. Это особенно важно в условиях кризисных ситуаций, когда скорость реагирования и эффективность действий играют решающую роль.

Значимость автоматизированных методов восстановления жилой инфраструктуры неоспорима. Они позволяют оптимизировать расходы на восстановление, ускорить процесс принятия решений и обеспечить более точное планирование работ. Это способствует более эффективному использованию ресурсов и повышению качества жизни людей, находящихся в зоне чрезвычайных ситуаций.

Таким образом, использование алгоритмов машинного обучения для оценки повреждений объектов жилой инфраструктуры после чрезвычайных ситуаций открывает новые возможности для эффективного и быстрого восстановления после катастрофических событий. Этот подход является ключевым элементом современной стратегии обеспечения безопасности и благополучия населения в условиях кризисных ситуаций.

### References

- Chachra G., Kong Q., Huang J., Korlakunta S., Grannen J., Robson A., Allen R.M. 2022. Detecting damaged buildings using real-time crowdsourced images and transfer learning. *Scientific reports*, 12(1), 8968. DOI: 10.1038/s41598-022-12965-0.
- Chicco D., Jurman G. 2020. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*, 21, 1–13. DOI: 10.1186/s12864-019-6413-7.
- Creswell A., White T., Dumoulin V., Arulkumaran K., Sengupta B., Bharath A.A. 2018. Generative adversarial networks: An overview. *IEEE signal processing magazine*, 35(1), 53–65. DOI: 10.1109/MSP.2017.2765202.
- Han K., Wang Y., Tian Q., Guo J., Xu C. 2020. Ghostnet: More features from cheap operations. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 1580–1589). DOI: 10.48550/arXiv.1911.11907.
- Hansen J.G., de Figueiredo R.P. 2024. Active Object Detection and Tracking Using Gimbal Mechanisms for Autonomous Drone Applications. *Drones*, 8(2), 55. DOI: 10.3390/drones8020055.

- Haryono A., Jati G., Jatmiko W. 2024. Oriented object detection in satellite images using convolutional neural network based on ResNeXt. *ETRI Journal*, 46(2), 307–322. DOI: 10.4218/etrij.2022-0446.
- Henderson P., Ferrari V. 2017. End-to-end training of object class detectors for mean average precision. In *Computer Vision–ACCV 2016: 13th Asian Conference on Computer Vision*, Taipei, Taiwan, November 20–24, 2016, Revised Selected Papers, Part V 13 (pp. 198–213). Springer International Publishing. DOI: 10.1007/978-3-319-54193-8\_13.
- Hu S., Wang P., Hoare C., O'Donnell J. 2022. Building occupancy detection and localization using CCTV camera and deep learning. *IEEE Internet of Things Journal*, 10(1), 597–608. DOI: 10.1109/JIOT.2022.3201877.
- Indumathi, C. P., Santhoshsivan, V., Selvakumar, R. (2024). ResNet and ResNeSt-Based Deep-Learning. In *Digital Geography: Proceedings of the International Conference on Internet and Modern Society (IMS 2023)* (p. 215). Springer Nature. DOI: 10.1007/978-3-031-67762-5\_17.
- Jiang P., Ergu D., Liu F., Cai Y., Ma B. 2022. A Review of Yolo algorithm developments. *Procedia computer science*, 199, 1066–1073. DOI: 10.1016/j.procs.2022.01.135.
- Kallas J., Napolitano R. 2023. Automated large-scale damage detection on historic buildings in post-disaster areas using image segmentation. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 48, 797–804. DOI: 10.5194/isprs-archives-XLVIII-M-2-2023-797-2023.
- Karacı A. 2022. VGGCOV19-NET: automatic detection of COVID-19 cases from X-ray images using modified VGG19 CNN architecture and YOLO algorithm. *Neural Computing and Applications*, 34(10), 8253–8274.
- Kaur R., Singh S. 2023. A comprehensive review of object detection with deep learning. *Digital Signal Processing*, 132, 103812. DOI: 10.1016/j.dsp.2022.103812.
- Khan S., Naseer M., Hayat M., Zamir S. W., Khan F. S., Shah, M. 2022. Transformers in vision: A survey. *ACM computing surveys (CSUR)*, 54(10s), 1–41. DOI: 10.1145/3505244.
- Krizhevsky A., Sutskever I., Hinton G.E. 2012. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25. DOI: 10.1145/3065386.
- Krizhevsky, A., Sutskever, I., Hinton, G.E. 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. DOI: 10.1145/3065386.
- Li X., Caragea D., Zhang H., Imran M. 2018. Localizing and quantifying damage in social media images. In *2018 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)* (pp. 194–201). IEEE. DOI: 10.1109/ASONAM.2018.8508298.
- Lin C.L., Wu K.C. 2023. Development of revised ResNet-50 for diabetic retinopathy detection. *BMC bioinformatics*, 24(1), 157. DOI: 10.1186/s12859-023-05293-1.
- Liu C., Sui H., Wang J., Ni, Z., Ge L. 2022. Real-time ground-level building damage detection based on lightweight and accurate YOLOv5 using terrestrial images. *Remote Sensing*, 14(12), 2763. DOI: 10.3390/rs14122763.
- Mikołajczyk A., Grochowski M. 2018. Data augmentation for improving deep learning in image classification problem. In *2018 international interdisciplinary PhD workshop (IIPHDW)* (pp. 117–122). IEEE. DOI: 10.1109/IIPHDW.2018.8388338.
- Selvaraju R.R., Cogswell M., Das A., Vedantam, R., Parikh, D., Batra, D. 2017. Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision* (pp. 618–626). DOI: 10.1007/s00521-022-06918-x.
- Van Etten, A. 2018. You only look twice: Rapid multi-scale object detection in satellite imagery. DOI: 10.48550/arXiv.1805.09512.
- Woo S., Park J., Lee J.Y., Kweon I.S. 2018. Cbam: Convolutional block attention module. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 3–19). DOI: 10.48550/arXiv.1807.06521
- Zhang Q. 2022. A novel ResNet101 model based on dense dilated convolution for image classification. *SN Applied Sciences*, 4, 1–13. DOI: 10.1007/s42452-021-04897-7.
- Zhao D., Shao F., Liu Q., Yang L., Zhang H., Zhang, Z. 2024. A Small Object Detection Method for Drone-Captured Images Based on Improved YOLOv7. *Remote Sensing*, 16(6), 1002. DOI: 10.3390/rs16061002.
- Zhu T., Chen J., Zhu R., Gupta G. 2023. StyleGAN3: generative networks for improving the equivariance of translation and rotation. *arXiv preprint arXiv:2307.03898*. DOI: 10.48550/arXiv.2307.03898.



**Конфликт интересов:** о потенциальном конфликте интересов не сообщалось.  
**Conflict of interest:** no potential conflict of interest related to this article was reported.

Поступила в редакцию 15.02.2025  
Поступила после рецензирования 03.03.2025  
Принята к публикации 04.03.2025

Received February 15, 2025  
Revised March 03, 2025  
Accepted March 04, 2025

#### ИНФОРМАЦИЯ ОБ АВТОРАХ

#### INFORMATION ABOUT THE AUTHORS

**Головко Ярослав Юрьевич**, аспирант,  
Белгородский государственный национальный  
исследовательский университет, г. Белгород,  
Россия

**Yaroslav Yu. Golovko**, Postgraduate Student of  
Belgorod State National Research University,  
Belgorod, Russia

**Ильинская Елена Владимировна**, кандидат  
экономических наук, доцент кафедры прикладной  
информатики и информационных технологий,  
Белгородский государственный национальный  
исследовательский университет, г. Белгород,  
Россия

**Elena V. Pyinskaya**, Candidate of Economic  
Sciences, Associate Professor of the Department  
of Applied Informatics and Information  
Technology, Belgorod State National Research  
University, Belgorod, Russia