

Технологии информационного общества

ОБЗОР ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА, ИСПОЛЬЗУЕМЫХ ДЛЯ ОЦЕНКИ УЩЕРБА ОТ ЧРЕЗВЫЧАЙНЫХ СИТУАЦИЙ ПРИРОДНОГО И ТЕХНОГЕННОГО ХАРАКТЕРА

Статья рекомендована к публикации членом редакционного совета М. А. Шахраманьяном 11.03.2024.

Загуменнова Марина Викторовна

*Всероссийский научно-исследовательский институт противопожарной обороны МЧС России,
начальник научно-исследовательского сектора отдела пожарной статистики
Балашиха, Российская Федерация
otdel-16@vniipro.ru*

Аннотация

В статье проведен анализ международного и отечественного опыта в области оценки ущерба от различных чрезвычайных событий (землетрясения, наводнения, пожары и т. п.) с применением искусственного интеллекта. Целью работы является обзор теоретических и практических научных подходов к оценке ущерба в результате природных и техногенных чрезвычайных ситуаций с использованием технологий искусственного интеллекта и перспективы развития этой сферы. Проведенный анализ показал, что для того, чтобы искусственный интеллект выполнял свою работу, необходимы хорошо подготовленные и надежные данные, которые помогут быстрому принятию решений и планированию необходимых мероприятий для управления стихийными бедствиями.

Ключевые слова

стихийные бедствия; ущерб; искусственный интеллект; машинное обучение; повреждение; здание

Введение

В настоящее время все чаще говорят об использовании искусственного интеллекта (далее – ИИ) в управлении рисками. Выделяются основные преимущества использования ИИ: результаты в режиме реального времени, обработка больших объемов информации; более четкая идентификация и оценка ущерба и т.п. Для повышения эффективности управления в целом требуется разработка и внедрение в практику новых методов подготовки принятия решений на основе полноценной и качественной информации. Благодаря использованию ИИ значительно повышается доверие к полученной информации. В настоящее время, во многих странах мира, в том числе и в России, разрабатываются передовые автоматизированные методы на основе технологий ИИ для различных сфер деятельности, в том числе и в области защиты территорий и населения от различных природных и техногенных бедствий (землетрясения, наводнения, пожары и т. д.).

1 Обзор международных и отечественных практик определения ущерба на основе искусственного интеллекта для различных типов бедствий

Усовершенствования технологий ИИ привели к повышенному интересу в области создания интеллектуальных систем для решения проблем, с которыми сталкиваются многие службы экстренного реагирования во всем мире. Модели и алгоритмы для определения повреждений после различных бедствий становятся все более популярными в поддержке принятия решений по мере того, как технологии ИИ расширяются. Эти модели и алгоритмы теперь могут принимать ряд визуальных входных данных, включая изображения со спутников, беспилотных летательных аппаратов, самолетов и даже могут объединять изображения из социальных сетей в качестве

© Загуменнова М. В., 2024

Производство и хостинг журнала «Информационное общество» осуществляется Институтом развития информационного общества.

Данная статья распространяется на условиях международной лицензии Creative Commons «Атрибуция — Некоммерческое использование — На тех же условиях» Всемирная 4.0 (Creative Commons Attribution – NonCommercial – ShareAlike 4.0 International; CC BY-NC-SA 4.0). См. <https://creativecommons.org/licenses/by-nc-sa/4.0/legalcode.ru>
https://doi.org/10.52605/16059921_2024_05_156

источников входных данных [1]. Растущая доступность различных изображений до и после бедствий, позволяет исследователям создавать модели для решения различных задач, в том числе и для обнаружения повреждений и оценки ущерба после чрезвычайных ситуаций (далее - ЧС). В основном, это касается обнаружения зданий и разделения их на различные категории в зависимости от степени повреждения. Обработку данных можно выполнять с помощью механизмов, основанных на методах машинного обучения, и в последнее время, методов глубокого обучения. Выходные данные этих методов могут быть использованы для предоставления информации, необходимой для поддержки принятия решений по управлению рисками. Оценка ущерба по спутниковым снимкам, особенно для разрозненных типов бедствий, является сложной задачей. На уровне интуиции, понятно, что разные бедствия, например, наводнения, землетрясения, пожары могут по-разному воздействовать на здания. Поэтому, для обучения ИИ и создания адекватных моделей оценки ущерба, критически важны наборы данных, которые могут предоставить изображения различных типов зданий с различной степенью тяжести повреждений. По-настоящему реализовать потенциал решений на основе ИИ, возможно при интеграции всех возможных источников данных. Это значительный объем информации, которым довольно сложно управлять. Чтобы увидеть конкретные условия повреждений, требуются изображения с высоким разрешением, но, поскольку стихийные бедствия охватывают большую территорию, аналитики должны анализировать огромный объем пикселей, чтобы локализовать и оценить ущерб. Хотя крупномасштабные бедствия наносят большой ущерб, они случаются относительно редко, поэтому доступность соответствующих данных невелика. Существующие наборы данных в виде спутниковых изображений, содержащие поврежденные здания, охватывают, как правило, отдельные типы бедствий с разными критериями маркировки поврежденных зданий.

1.1 Обзор международных практик

В исследовании [2] предлагается алгоритм обнаружения поврежденных зданий после землетрясения с использованием искусственной нейронной сети. В работе была исследована информация после землетрясения, на основе изображений с высоким разрешением, для оценки масштаба воздействия на здания для категорирования их на две группы: поврежденные и неповрежденные. В данной работе была выбрана искусственная нейронная сеть, благодаря которой формируется точная информация. Для всех категорий поврежденных зданий характерно различие в высоте с элементами, находящимися рядом. Кроме того, поврежденные и неповрежденные здания имеют разный цвет и текстуру. Эти данные, как отмечают авторы, имеют важное значение, так как, поврежденные здания отличаются грубой текстурой и низкими значениями серого цвета по сравнению с неповрежденными зданиями. В соответствии с разработанным алгоритмом искусственной нейронной сети в качестве первоисточника применяются данные о текстуре и цвете изображения зданий, а затем информация классифицирует ущерб по трем категориям: высокий, средний и низкий уровень повреждения. Важным элементом является то, что при использовании данного метода возможно быстрое построение карт повреждений, а соответственно происходит быстрое реагирование на последствия бедствий. Результаты применения алгоритма показали, что в большинстве случаев здания были идентифицированы правильно, а распределение их на поврежденные и неповрежденные было выполнено достаточно точно [2].

В работе [3] авторами предлагается помощь компьютерного зрения и спутниковых изображений оценить масштабы бедствия, связанного с наводнением. Исследователи предлагают метод на основе глубокого машинного обучения, при котором используются пары изображений до и после бедствия, для выявления территорий, наиболее пострадавших от бедствия. Модель использует разницу в характеристиках изображений до и после наводнения для прогнозирования ущерба и идентифицирует быстрое изменение строительных конструкций зданий. В результате исследований было показано, что используемая модель глубокого машинного обучения успешно выявляла локальные разрушения и показала точность 85,9 % при определении территорий с поврежденными зданиями [3].

Стоит сказать, что предлагаемая модель обучалась на наборе данных xBD [4], которые, содержат изображения до и после стихийных бедствий, а также описание зданий и шкалу повреждений зданий. Более того, набор данных xBD содержит ограничивающие рамки и метки для факторов окружающей среды, таких как огонь, вода и дым. На сегодняшний день xBD обладает крупнейшим набором данных для оценки повреждений зданий и содержит около 700 000 описаний зданий на площади более 5 000 кв. км изображений из 15 стран мира. Шкала повреждений зданий

xBD охватывает несколько типов повреждений: незначительное повреждение, крупное повреждение и разрушение. Представленная авторами статьи [3] модель оценки ущерба на основе данных xBD и глубокого машинного обучения помогает оптимизировать материальные и человеческие ресурсы и направить их в наиболее пострадавшие от бедствия районы, а также дает возможность определить наиболее приоритетные направления по оказанию помощи пострадавшим. Данная модель показала, что методы компьютерного обучения можно использовать для разработки стратегии реагирования на стихийные бедствия.

В проведенных исследованиях [5] в области обнаружения семантического изменения сценария до и после стихийного бедствия нейронная сеть не использовалась для создания многовременных изображений дистанционного зондирования с высоким разрешением. Вместо этого применялся метод визуального набора слов, основанный на функциях представления на спутниковых снимках до и после стихийного бедствия. Они применили метод опорных векторов (SVM), который активно используется для машинного обучения в рамках решения задач классификации, для прогнозирования поврежденных и неповрежденных объектов в небольшом регионе на основе объединения различных признаков. Им удалось достичь точности 91,7%, но их работа предполагала знание того, где находятся здания.

Достижения в области глубокого обучения вывели компьютерное зрение на новый уровень. Еще одним исследованием в области глубокого машинного обучения стала работа [6]. Автор предлагает использовать сверточные нейронные сети (CNN) для создания модели компьютерного зрения, основанной на глубоком обучении, для семантического вывода о величине ущерба, нанесенного отдельным зданиям после стихийных бедствий, на основе спутниковых изображений до и после стихийных бедствий. Существенным преимуществом CNN является их способность обрабатывать многоклассовую структуру в рамках одной модели. При разработке модели, которую потенциально можно было бы использовать для поддержки принятия решений, специалистам по ликвидации последствий стихийных бедствий авторами использовалось обучение на наборе данных спутниковых изображений с различными метками наземной достоверности в случае отсутствия повреждений, небольшого повреждения, умеренного повреждения и разрушения. Данные, используемые в этом исследовании, состоят из спутниковых изображений высокого разрешения, собранных в рамках программы Maxar Digital Globe [7]. Программа поддерживает открытую базу данных спутниковых изображений, которая охватывает стихийные бедствия с 2010 года по настоящее время для всех типов крупных стихийных бедствий по всему миру. Этот набор данных также охватывает несколько типов стихийных бедствий, включая изображения и данные о землетрясениях, цунами, наводнениях, извержениях вулканов, лесных пожарах и ураганах. Помимо типов стихийных бедствий, набор данных также имеет разнообразный набор местоположений. В этот набор включены изображения и данные о стихийных бедствиях в США, Мексике, Гватемале, Португалии, Индонезии, Индии и Австралии. Важным элементом набора данных в Maxar Digital Globe является шкала ущерба. Это важный аспект, поскольку шкала объединяет разные виды повреждений при различных стихийных бедствиях и обеспечивает средство для определения степени ущерба зданиям независимо от типа полученного ими ущерба. В шкале повреждений используются следующая кодировка:

- для обозначения отсутствия повреждений - 0;
- для незначительного ущерба, такого как небольшое повреждение конструкций огнем или водой -1;
- для умеренного (существенного) ущерба, такого как значительное повреждение конструкций огнем или водой - 2;
- для разрушения в случаях, когда здание было сожжено, рухнуло, затоплено или полностью отсутствовало - 3.

Как говорилось выше, задача предлагаемой модели классификации, состоит в том, чтобы сделать вывод о величине ущерба, нанесенного отдельным зданиям после стихийных бедствий. Это делается путем размещения модели компьютерного зрения на основе глубокого обучения, которая применяет метки к каждому зданию, введенному в модель, из шкалы повреждений. Стоит отметить, что существенные трудности в разработке модели вызвала классификация зданий с низким или умеренным повреждением, т.к. в сравнении с уничтожением или отсутствием повреждений разница между незначительным и умеренным повреждением более субъективна по своему характеру. Как следствие, это оставляет больше места для ошибок для обученной модели по сравнению с более определенными случаями «без повреждений» и «уничтожение». Что не менее

важно, в исследовании [6] определены параметры, которые оказывают большое влияние на обучение моделей, особенно при использовании методов глубокого обучения в компьютерном зрении для создания моделей определения повреждений по спутниковым изображениям. Было обнаружено, что увеличение изображения, снижение скорости обучения и трансферное обучение имеют большое значение.

Ученые Таиланда [8] предлагают свою модель определения ущерба от землетрясений, нанесенного зданиям, на основе географической информационной системы с использованием искусственного интеллекта. Тяжесть повреждений зданий, вызванных землетрясением, зависит от многих факторов, таких как магнитуда, расстояние от эпицентра и геологические условия, а также сейсмические характеристики здания. Исследование [8] направлено на разработку нового подхода с использованием модели адаптивной нейронечеткой системы вывода (ANFIS), для прогнозирования повреждений зданий в городском масштабе с учетом входных неопределенностей. Поскольку прогнозирование повреждений зданий связано с различными неопределенными факторами, то для оценки сейсмических повреждений была введена теория нечеткой логики. Однако недостатком нечеткой логики является то, что структура должна быть определена экспертом, и она не может обучаться самостоятельно. Тем не менее, с использованием предложенной методологии был проведен анализ сейсмических повреждений зданий для пяти типов землетрясений в муниципалитете Чиангмай в Таиланде. На первом этапе в создании обучающего набора данных о сейсмически поврежденных зданиях была обработана информация на основе оценки ущерба зданиям при различных комбинациях трех входных обучающих данных, таких как:

- шкала магнитуд землетрясения в диапазоне от 4 до 6,5;
- здания, классифицированные на восемь конструктивных типов: деревянное легкокаркасное здание, деревянное здание, здание монолитно-каркасное, здание со стальным каркасом, здание с легким стальным каркасом, бетонное монолитно-каркасное здание, здание с бетонными стенами и бетонное каркасное здание с неармированными стенами из каменной кладки;
- 1201 расстояние между зданием и эпицентром землетрясения, от 0 до 12 км. Максимальное расстояние 12 км представляет собой длину, охватывающую все здания муниципалитета Чиангмая. Ущерб определялся на каждые 0,01 км расстояния.

На втором этапе на основе входных обучающих данных была создана модель ANFIS для прогнозирования сейсмических повреждений зданий. Наконец, были сгенерированы 32 модели ANFIS, и модель ANFIS с самым низким среднеквадратичным отклонением, которая была предложена для прогнозирования различных сценариев повреждения зданий. На третьем этапе результаты оценки повреждений зданий по предложенной модели ANFIS сравнивались с данными разработанными для оценки повреждения зданий с использованием метода спектра мощности (CSM) [9]. Количество поврежденных зданий, полученное в результате сравнения, было одинаковым. Предлагаемая модель ANFIS обеспечивает два основных преимущества: входные неопределенности могут быть обработаны в функциях нечеткой логики, и функция может быть дополнительно адаптирована с помощью дополнительного нового правильного набора данных для обучения, например, реального ущерба от землетрясения. Работа в основном направлена на внедрение ANFIS для прогнозирования сейсмических повреждений зданий с одной глубиной, одним местоположением и различной магнитудой. Следовательно, необходимы дальнейшие исследования для рассмотрения большего количества возможных мест, включая близкие и отдаленные землетрясения.

Еще одним рассмотренным исследованием в области оценки ущерба от ЧС стала работа [10]. В статье представлена технологическая схема количественного определения разрушенных объектов в результате стихийного бедствия на примере фрагментарных космических снимков города Сендай (Япония). Целью данной работы является подсчет общего количества плоских объектов в городе Сендай, разрушенных после землетрясения, с помощью программного обеспечения ErdasImagine, а именно его отдельного модуля Delta Cue. На основе разработанной технологической схемы определялись количественные характеристики полученных результатов изменения объектов в результате стихийных бедствий на материалах многовременных космических снимков. С помощью специального программного модуля поиска многократных изменений Delta Cue определялось количество уничтоженных объектов с помощью трех различных фильтров. Технологическая схема определения разрушений объектов по многовременным космическим снимкам вследствие

стихийных бедствий позволяет оперативно выявлять зоны повреждений и оперативно рассчитывать приблизительные потери.

Одной из стратегий поддержки раннего предупреждения лесных пожаров является использование космических технологий и обработка изображений в реальном времени. В исследовании [11] изучалось использование спутниковых изображений для обучения и проверки степени повреждений и картирования масштабов крупных лесных пожаров на основе различных спутниковых изображений. В этом исследовании рассматривается использование субдециметровых гиперпространственных изображений, полученных с помощью небольшой беспилотной летательной системы (sUAS). Возможности sUAS позволяют получать изображения с пространственным разрешением в сантиметры и временным разрешением в минуты [12]. Для обучения алгоритмов машинного обучения картированию интенсивности и масштабов лесных пожаров использовались изображения системы Landsat. Landsat — единственная спутниковая система США, разработанная и эксплуатируемая для постоянного наблюдения за поверхностью земли в умеренном масштабе, которая показывает, как естественные, так и антропогенные изменения [13]. Для достижения цели этой работы было сделано преобразование гиперпространственных данных обучения с высоким разрешением в данные обучения с более низким разрешением с использованием нечеткой логики. Это позволило создать обучающие данные спутникового разрешения и позволило определить и проанализировать степень горения по спутниковым снимкам. Районы лесных пожаров, используемые в этом исследовании, представляют собой совокупность пожаров среднего и крупного масштаба. Хотя в эксперименте использовались изображения Landsat, этот метод не привязан к какому-либо конкретному спутнику наблюдения за Землей и может применяться к любым пространственным изображениям при условии правильного формата. Улучшенное картирование последствий пожаров в результате разработки данного метода, аналитических инструментов и показателей, приводящих к повышению точности картирования последствий пожаров, улучшит управление пожарами, что в значительной степени повлияет на планирование восстановления после пожара и другие операции по управлению. Однако большой объем данных, предоставляемых спутниковыми снимками, стоимость спутниковой технологии и сложность доступа к информации об удаленных местах затрудняют решение этой проблемы.

В работе [14] представлен тщательно подобранный набор данных с высоким разрешением после стихийного бедствия RescueNet, который включает подробную классификацию и аннотации семантической сегментации и позволяет всестороннее изучить обстановку, сложившуюся после стихийного бедствия. RescueNet включает изображения после стихийного бедствия, полученные с помощью беспилотных летательных аппаратов из нескольких пострадавших от урагана регионов. Уникальность RescueNet заключается в предоставлении изображений в высоком разрешении, которые сопровождаются подробным описанием для каждого изображения. В отличие от существующих наборов данных, которые предлагают описание, ограниченные конкретными элементами обстановки, такими как здания, RescueNet предоставляет описания на уровне пикселей для всех классов, включая здания, дороги, водные объекты, лесные насаждения и др. Применение RescueNet направлено на совершенствование существующих методологий оценки ущерба от стихийных бедствий.

1.2 Обзор отечественных практик

В Российской Федерации МЧС России в 2020 году разработана подсистема для сбора и анализа данных о лесных пожарах «Термические точки» в рамках информационной системы «Атлас опасностей и рисков» [15]. Подсистема разработана с применением технологий машинного обучения. «Термические точки» является платформой для визуального отображения данных, полученных с применением систем космического мониторинга ЧС. Специальный алгоритм круглосуточно обрабатывает данные со спутников. Для каждой термической точки выводятся данные по рискам возникновения пожара и его распространения, а также звуковое и текстовое оповещение. Подсистема обеспечивает раннее обнаружение очагов природных пожаров с целью оперативного реагирования и минимизации возможных рисков, защиты населенных пунктов, людей и материальных ценностей от влияния опасных факторов природных пожаров. Основным назначением приложения является: оперативное отображение данных о термических точках; доведение информации должностным лицам; категорирование термических точек; анализ

возможных рисков возникновения природных пожаров. Оценка последствий пожаров, в том числе и ущерба, в рамках данной подсистемы не осуществляется.

В работах [16, 17] рассмотрена возможность применения искусственных нейросетей, способных к формированию, в процессе обучения и адаптации, знаний о неизвестных характеристиках моделируемого объекта, для прогноза возникновения очагов лесных пожаров с учетом влияния природных и антропогенных факторов среды. Основным алгоритмом, обеспечивающим быструю сходимость процесса обучения, был выбран алгоритм случайного поиска. Эффективность различных его реализаций неоднократно подтверждена исследованиями [18]. При реализации системы прогнозирования вероятности лесных пожаров алгоритм случайного поиска является одним из приоритетов увеличения количества зависимых (прогнозируемых) параметров. Это связано с тем, что это ускоряет процесс обучения нейронной сети на 1–3 порядка. Преимущества такого подхода заключаются в том, что для объяснения физико-химических законов горения не требуется решать длинную систему дифференциальных уравнений. По сути, это оценка степени риска возникновения лесных пожаров, которая получается из произведения вероятности возникновения лесного пожара и размера ущерба, нанесенного лесным пожаром.

В Томском политехническом университете разработан нейросетевой алгоритм, который должен помочь пожарным службам обнаружить, локализовать и ликвидировать возгорание на объектах атомной промышленности [19]. Ученые университета создали базу данных на основе которой, обучили нейросеть с учетом специфики технологического процесса атомных объектов. Нейросеть может идентифицировать причину возгорания или другую внештатную ситуацию, местоположение, тип и характеристики очага пожара, а также спрогнозировать дальнейшую модель развития событий и выдать рекомендации по наиболее оптимальным механизмам и способам локализации и тушения возгорания. Нейросеть планируется использовать в качестве инструмента для выдачи рекомендаций пожарным службам по сценариям развития ЧС на атомном объекте и как инструмент определения наиболее эффективного механизма локализации и тушения возгорания, а также для расследования причин возгорания. Это позволит существенно минимизировать ущерб и снизить последующие риски от возгораний на различных промышленных и общественных объектах.

Ученые Томского государственного университета совместно с коллегами из Токийского столичного университета также разработали программное обеспечение, способное прогнозировать стихийные бедствия, такие как оползни и наводнения и предотвращать их [20]. В 2019 году функционал программы был расширен за счет нейронных сетей. Программа анализирует данные, собранные за 20 лет, чтобы выявить тенденции и сопоставить их с оперативными гидрометеорологическими данными. По результатам обработки нейросеть предоставляет информацию о динамике уровня воды в зоне риска и прогнозирует, какие территории могут быть затоплены. Этот информационный ресурс отображает реальную местность, дома и постройки, а также собирает данные о людях, оказавшихся в зонах затопления, в том числе о количестве детей. С появлением этого инструмента стало возможным более точно рассчитывать текущий уровень воды в различных точках местности и делать краткосрочные прогнозы на ближайшие два-три дня.

В 2022 году в России появился сервис дистанционной оценки технического состояния автомобилей на основе нейронных сетей и классического машинного обучения CarDamageTest [21]. ИИ помогает страховым компаниям оценить ущерб от дорожно-транспортного происшествия (далее – ДТП) по фото. CarDamageTest доступен в виде приложения для мобильных устройств. Для получения качественной входной информации было обработано 250 000 изображений автомобилей, среди которых были как целые, так и поврежденные автомобили. В дальнейшем, обученная нейронная сеть, произвела разметку изображений поврежденных автомобилей. Получив обработанный и структурированный массив данных из нескольких тысяч изображений, разработчики дообучили генеративно-состязательную сеть и получили возможность генерировать синтетические размеченные изображения, большинство из которых нуждается в минимальной корректировке. На сегодняшний день классификатор повреждений – это ансамбль трех алгоритмов, обученных как на подмножествах классов повреждений, так и на всех классах вместе. Результатом работы CarDamageTest является сообщение о том, что повреждения не найдены или указываются сегменты, на которых они найдены. По результатам работы формируется текстовое описание результатов оценки автомобиля, соответствующее требованиям страховых компаний, а для пользователя найденные повреждения дополнительно визуализируются.

Заключение

Исследования показали, что потенциал решений по оценке ущерба от различных природных и техногенных чрезвычайных ситуаций на основе ИИ безграничен. Проведенный обзор международных и отечественных разработок оценки ущерба на основе ИИ показал, что идет активное изучение этой сферы. Обнаружение и определение разрушений и повреждений при различных деструктивных событиях считаются важными элементами управления рисками. Рассмотренные модели и методы обнаружения повреждений зданий, транспортных средств и др. в результате различных чрезвычайных ситуаций на основе ИИ имеют как отдельные недостатки, так и преимущества. Модели на основе ИИ для обнаружения поврежденных зданий в основном определяют: существует ли здание после стихийного бедствия или нет. Модели компьютерного зрения, основанные на глубоком обучении, превзошли людей в задачах сравнительной классификации изображений. Для полноценной поддержки обучения ИИ и создания надежных моделей оценки ущерба необходимо следующее:

- 1) должны быть доступны наборы данных соответствующего объема, масштаба, размера и стандарта;
- 2) система сбора и категоризации данных является необходимой поддержкой обучения ИИ, поскольку неполные и недостоверные входные данные неизбежно влияют на качество результатов;
- 3) создание единой платформы сбора, хранения и анализа данных из различных информационных систем;
- 4) требуется разработать модель, которая может обеспечивать несколько степеней масштабности и определять шкалу повреждений от умеренной до высокой, которую потенциально можно было бы использовать для поддержки принятия решений, специалистам по ликвидации последствий стихийных бедствий, так как степень величины между неповрежденными и разрушенными объектами является субъективной, и случаи, которые граничат между двумя степенями величины, могут ввести модель в заблуждение и усложнить обучение;
- 5) необходим достаточно большой объем изображений, поврежденных от различных природных и техногенных чрезвычайных ситуаций (пожары, землетрясения, наводнения, и т.п.), зданий и других объектов для создания шкалы повреждений, с учетом определенных входных данных.

Конкретные решения все же остаются за экспертами. ИИ служит лишь для проведения анализа трудоемких процессов. Создание современных моделей и алгоритмов, способствующих решению таких задач, как оценка ущерба и прогнозирование рисков бедствий с применением ИИ, является актуальной и перспективной задачей.

Литература

1. Betul B. Ekici Detecting damaged buildings from satellite imagery // *Journal of Applied Remote Sensing* 15(3), P. 032004 (4 March 2021). <https://doi.org/10.1117/1.JRS.15.032004>
2. Sajjad Ahad Zadeh, Mohammad Javad Valadan Zoej, S. Sadeghian, Salman Ahmadi Detection of damaged buildings after an earthquake using artificial neural network algorithm. // *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. XXXVII. Part B8. P. 369-372 Beijing 2008 <https://www.researchgate.net/publication/237312703>.
3. Danu Kim, Eunji Lee, Jeongkyung Won, Kyung Ryul Park. Disaster assessment using computer vision and satellite imagery: Applications in detecting water-related building damages. *Frontiers in Environmental Science*. 10. P.1-14 DOI:10.3389/fenvs.2022.969758
4. Ritwik Gupta, Bryce Goodman, Nirav Patel, Richard Hosfelt, Sandra Sajeew, Eric Heim, Jigar Doshi, Keane Lucas, Howard Choset, Matthew Gaston. Creating xBD: A Dataset for Assessing Building Damage from Satellite Imagery. Carnegie Mellon University. Preprint posted on 2019-05-21. <https://doi.org/10.1184/R1/8135576>.
5. Tu Jihui, Li Deren, Feng Wenqing, Han Qinhu, Sui Haigang Detecting Damaged Building Regions Based on Semantic Scene Change from Multi-Temporal High-Resolution Remote Sensing Images. // *International Journal of Geo-Information* 6(5):2017 P. 1-13 DOI: 10.3390/ijgi6050131

6. Wheeler B.J., Karimi H.A. Deep Learning-Enabled Semantic Inference of Individual Building Damage Magnitude from Satellite Images. *Algorithms*, Algorithms 2020, 13(8), P.195. <https://doi.org/10.3390/a13080195>.
7. Maxar. 2020. Available online. <https://www.digitalglobe.com/ecosystem/open-data>.
8. Latcharote Panon, Hansapinyo Chayanon, Limkatanyu Suchart Seismic Building Damage Prediction From GIS-Based Building Data Using Artificial Intelligence System. *Front. Built Environ.*, 15 October 2020 Sec. Earthquake Engineering Volume 6 - 2020 <https://doi.org/10.3389/fbuil.2020.576919>
9. Zeng, Xiang & Lu, Xinzheng & Yang, Tony & Xu, Zhen. (2016). Application of the FEMA-P58 methodology for regional earthquake loss prediction. *Natural Hazards*. 83. DOI: 10.1007/s11069-016-2307-z
10. Chetverikov, B., Marusazh H. Method of determining distance building destruction after the earthquake using software ERDAS nterdepartmental scientific and technical collection "Geodesy, cartography and aerial photography" Vol 76, 2012 (p. 74-76).
11. Hamilton, Dale & Levandovsky, Enoch & Hamilton, Nicholas. (2020). Mapping Burn Extent of Large Wildland Fires from Satellite Imagery Using Machine Learning Trained from Localized Hyperspatial Imagery. *Remote Sensing*. 12(24) DOI:10.3390/rs12244097
12. Laliberte, A.S., Herrick J.E., Rango A., Winters C., Acquisition orthorectification, and object-based classification of unmanned aerial vehicle (UAV) imagery for rangeland monitoring. *Photogramm. Eng. Remote Sens.* 2010, 76, P.661-672.
13. National Aeronautics and Space Administration (NASA). Landsat Science. <https://landsat.gsfc.nasa.gov/satellites/landsat-9>.
14. Rahnemoonfar, M., Chowdhury, T. & Murphy, R. RescueNet: A High Resolution UAV Semantic Segmentation Dataset for Natural Disaster. *Damage Assessment. Sci Data* 10, 913 (2023) DOI:10.1038/s41597-023-02799-4
15. Методические рекомендации по порядку использования и применения мобильного приложения «Термические точки» (утверждены заместителем Министра МЧС России, генерал-полковником Яцуценко В.Н. от 6 мая 2021 года за номером 2-4-87-6-9) <https://fireman.club/literature/mr-termicheskie-tochki-2021>.
16. Ясинский, Ф.Н., д р мат. наук, Потёмкина О.В., канд. хим. наук, Сидоров С.Г., канд. техн. наук, Евсеева А.В., асп. Прогнозирование вероятности возникновения лесных пожаров с помощью нейросетевого алгоритма на многопроцессорной вычислительной технике. «Вестник ИГЭУ». Вып. 2. 2011 г.
17. Шахраманьян, М. А. Оценка возможности прогнозирования возникновения очагов лесных пожаров с применением систем искусственного интеллекта / М. А. Шахраманьян // Гражданская оборона на страже мира и безопасности: материалы V Международной научно-практической конференции, посвященной Всемирному дню гражданской обороны, Москва, 01 марта 2021 года. Том Часть IV. – Москва: Академия Государственной противопожарной службы Министерства Российской Федерации по делам гражданской обороны, чрезвычайным ситуациям и ликвидации последствий стихийных бедствий, 2021. – С. 191-198.
18. Сидоров, С. Г. Разработка ускоренных алгоритмов обучения нейронных сетей и их применение в задачах автоматизации проектирования: специальность 05.13.12 "Системы автоматизации проектирования (по отраслям)": диссертация на соискание ученой степени кандидата технических наук / Сидоров Сергей Георгиевич. – Иваново, 2003. – 161 с.
19. ТАСС <https://nauka.tass.ru/nauka/19178853>
20. ТАСС <https://nauka.tass.ru/nauka/5596509>
21. CarDamageTest <https://finolab.ru/>

REVIEW OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES USED TO ASSESS DAMAGE FROM NATURAL AND MAN-MADE EMERGENCIES

Zagumennova, Marina Victorovna

All-Russian Research Institute of Fire Defense, EMERCOM of Russia, Department of fire statistics, head of the research sector

Balashikha, Russian Federation

otdel-16@vniipo.ru

Abstract

The article analyses international and domestic experience in the field of damage assessment from various emergency events (earthquakes, floods, fires, etc.) using artificial intelligence. The purpose of the work is to review theoretical and practical scientific approaches to damage assessment as a result of natural and man-made emergencies using artificial intelligence technologies and the prospects for the development of this field. The analysis has shown that in order for artificial intelligence to do its job, well-prepared and reliable data are needed to help rapid decision-making and planning of necessary activities for disaster management.

Keywords

natural disasters; damage; artificial intelligence; machine learning; building

References

1. Betul B. Ekici Detecting damaged buildings from satellite imagery // Journal of Applied Remote Sensing 15(3), R. 032004 (4 March 2021). <https://doi.org/10.1117/1.JRS.15.032004>
2. Sajjad Ahad Zadeh, Mohammad Javad Valadan Zoj, S. Sadeghian, Salman Ahmadi Detection of damaged buildings after an earthquake using artificial neural network algorithm. // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B8. R. 369-372 Beijing 2008 <https://www.researchgate.net/publication/237312703>.
3. Danu Kim, Eunji Lee, Jeongkyung Won, Kyung Ryul Park. Disaster assessment using computer vision and satellite imagery: Applications in detecting water-related building damages. Frontiers in Environmental Science. 10. R.1-14 DOI:10.3389/fenvs.2022.969758
4. Ritwik Gupta, Bryce Goodman, Nirav Patel, Richard Hosfelt, Sandra Sajeev, Eric Heim, Jigar Doshi, Keane Lucas, Howard Choset, Matthew Gaston. Creating xBD: A Dataset for Assessing Building Damage from Satellite Imagery. Carnegie Mellon University. Preprint posted on 2019-05-21. <https://doi.org/10.1184/R1/8135576>.
5. Tu Jihui, Li Deren, Feng Wenqing, Han Qinhu, Sui Haigang Detecting Damaged Building Regions Based on Semantic Scene Change from Multi-Temporal High-Resolution Remote Sensing Images. // International Journal of Geo-Information 6(5):2017 R. 1-13 DOI: 10.3390/ijgi6050131
6. Wheeler B.J., Karimi H.A. Deep Learning-Enabled Semantic Inference of Individual Building Damage Magnitude from Satellite Images. Algorithms, Algorithms 2020, 13(8), R.195. <https://doi.org/10.3390/a13080195>.
7. Maxar. 2020. Available online. <https://www.digitalglobe.com/ecosystem/open-data>.
8. Latcharote Panon, Hansapinyo Chayanon, Limkatanyu Suchart Seismic Building Damage Prediction From GIS-Based Building Data Using Artificial Intelligence System. Front. Built Environ., 15 October 2020 Sec. Earthquake Engineering Volume 6 - 2020 <https://doi.org/10.3389/fbuil.2020.576919>
9. Zeng, Xiang & Lu, Xinzheng & Yang, Tony & Xu, Zhen. (2016). Application of the FEMA-P58 methodology for regional earthquake loss prediction. Natural Hazards. 83. DOI: 10.1007/s11069-016-2307-z
10. Chetverikov, B., Marusazh H. Method of determining distance building destruction after the earthquake using software ERDAS Interdepartmental scientific and technical collection. "Geodesy, cartography and aerial photograph" Vol 76, 2012 (p. 74-76).
11. Hamilton, Dale & Levandovsky, Enoch & Hamilton, Nicholas. (2020). Mapping Burn Extent of Large Wildland Fires from Satellite Imagery Using Machine Learning Trained from Localized Hyperspatial Imagery. Remote Sensing. 12(24) DOI:10.3390/rs12244097

12. Laliberte, A.S., Herrick J.E., Rango A., Winters C., Acquisition orthorectification, and object-based classification of unmanned aerial vehicle (UAV) imagery for rangeland monitoring. *Photogramm. Eng. Remote Sens.* 2010, 76, R.661–672.
13. National Aeronautics and Space Administration (NASA). Landsat Science. <https://landsat.gsfc.nasa.gov/satellites/landsat-9>.
14. Rahnemoonfar, M., Chowdhury, T. & Murphy, R. RescueNet: A High Resolution UAV Semantic Segmentation Dataset for Natural Disaster. *Damage Assessment. Sci Data* 10, 913 (2023) DOI:10.1038/s41597-023-02799-4
15. Metodicheskie rekomendacii po poryadku ispol'zovaniya i primeneniya mobil'nogo prilozheniya «Termicheskie tochki» (utverzhdeny zamestitelem Ministra MChS Rossii, general-polkovnikom Yacucenko V.N. ot 6 maya 2021 goda za nomerom 2-4-87-6-9) <https://fireman.club/literature/mr-termicheskie-tochki-2021>.
16. Yasinskij, F.N., d r mat. nauk, Potyomkina O.V., kand. him. nauk, Sidorov S.G., kand. tekhn. nauk, Evseeva A.V., asp. Prognozirovanie veroyatnosti vozniknoveniya lesnyh pozharov s pomoshch'yu nejrosetevogo algoritma na mnogoprocessornoj vychislitel'noj tekhnike. «Vestnik IGEU». Vyp. 2. 2011 g.
17. Shahraman'yan, M. A. Ocenka vozmozhnosti prognozirovaniya vozniknoveniya ochagov lesnyh pozharov s primeneniem sistem iskusstvennogo intellekta / M. A. Shahraman'yan // *Grazhdanskaya oborona na strazhe mira i bezopasnosti: materialy V Mezhdunarodnoj nauchno-prakticheskoy konferencii, posvyashchennoj Vsemirnomu dnyu grazhdanskoj oborony, Moskva, 01 marta 2021 goda. Tom Chast' IV. – Moskva: Akademiya Gosudarstvennoj protivopozharnoj sluzhby Ministerstva Rossijskoj Federacii po delam grazhdanskoj oborony, chrezvychajnym situacijam i likvidacii posledstvij stihijnyh bedstvij, 2021. – S. 191-198.*
18. Sidorov, S. G. Razrabotka uskorennyh algoritmov obucheniya nejronnyh setej i ih primenenie v zadachah avtomatizacii proektirovaniya: special'nost' 05.13.12 "Sistemy avtomatizacii proektirovaniya (po otraslyam)": dissertaciya na soiskanie uchenoj stepeni kandidata tekhnicheskikh nauk / Sidorov Sergej Georgievich. – Ivanovo, 2003. – 161 s.
19. TASS <https://nauka.tass.ru/nauka/19178853>
20. TASS <https://nauka.tass.ru/nauka/5596509>
21. CarDamageTest <https://finolab.ru/>