

Анализ и перспективы применения методов машинного обучения для чрезвычайных ситуаций

О. З. Корабошев

Научно-исследовательский институт развития цифровых технологий и искусственного интеллекта
Ташкент, Узбекистан

Аннотация. Рассматривается использование методов машинного обучения для управления чрезвычайными ситуациями, такими как пожары, наводнения, землетрясения. Основное внимание уделяется прогнозированию бедствий, системам раннего предупреждения, мониторингу и реагированию на стихийные бедствия. Рассматриваются методы глубокого обучения, алгоритмы кластеризации и локальной оптимизации, а также стохастические алгоритмы.

Ключевые слова: машинное обучение, глубокое обучение, алгоритм кластеризации, алгоритмы локальной оптимизации, стохастические алгоритмы, управление чрезвычайными ситуациями, системы раннего предупреждения.

Для цитирования: Корабошев О. З. Применение методов машинного обучения в управлении чрезвычайными ситуациями: анализ и перспективы // *Интеллектуальные технологии на транспорте*. 2024. № 1 (37). С. 12–17. DOI: 10.20295/2413-2527-2024-137-12-17

ВВЕДЕНИЕ

Чрезвычайные ситуации, такие как пожары, наводнения, землетрясения, ежегодно приводят к гибели людей и разрушениям инфраструктуры. Управление такими бедствиями требует надежных решений, основанных на информационных технологиях и методах машинного обучения. В данной статье рассматривается применение методов машинного обучения для анализа и управления чрезвычайными ситуациями с акцентом на прогнозировании бедствий и системы раннего предупреждения.

Операции по управлению чрезвычайными ситуациями проводятся до, во время и после стихийного бедствия, чтобы предотвратить гибель людей, защитить людей и инфраструктуру, уменьшить воздействие на экономику и восстановить нормальную жизнь. Сложность стихийных бедствий, а также серьезность и сложность аварийных операций требует надежного принятия решений с помощью информационных технологий и в частности искусственного интеллекта. Эффективное и информированное управление стихийными бедствиями необходимо для преодоления масштабов и последствий стихийных бедствий, и в последние годы используются достижения в области машинного обучения и глубокого обучения.

АНАЛИЗ ЧРЕЗВЫЧАЙНЫХ СИТУАЦИЙ

В представленной таблице приведена классификация чрезвычайных ситуаций [1].

Области применения включают стихийные бедствия, такие как пожары, ураганы, землетрясения, наводнения, лесные пожары и оползни. Однако единого определения стихийного бедствия не существует. По другой классификации, бедствия делятся на стихийные и техногенные. Кроме того, в 2022 году стихийные бедствия, связанные с климатом, в основном стали причиной нескольких бедствий, зарегистрированных в этом году. Управление чрезвычайными ситуациями предотвращает стихийные бедствия с течением времени. Распространены четыре отдельных этапа: смягчение последствий, подготовка, реагирование и восстановление. Смягчение связано с действиями, которые предотвращают возникновение бедствия или уменьшают его последствия. Готовность включает мероприятия, которые подготавливают сообщества к реагированию на стихийное бедствие, такие как планирование действий в чрезвычайных ситуациях, заблаговременное размещение предметов снабжения, обучение и обучение населения тому, как лучше реагировать на стихийное бедствие или смягчать последствия стихийного бедствия. В обязанности входят операции по реализации планирования для защиты жизни и имущества, окружающей среды и социально-экономической структуры сообщества. Чрезвычайная помощь и реагирование также включают в себя такие действия, как планирование действий в чрезвычайных ситуациях, аварийно-спасательная и медицинская помощь, открытие убежищ и управление ими, распределение предметов снабжения и оценка ущерба. Это один из наиболее изученных этапов, поскольку именно на этом этапе люди и инфраструктура нуждаются в самой непосредственной поддержке. На этом этапе время имеет решающее значение, поэтому методы сосредоточены не только на высокоточных результатах, но и на быстродействующих и оптимизированных методах. Восстановление (реконструкция) предполагает длительные усилия, направленные на возвращение общества к нормальной жизни. Мероприятия на этом этапе включают финансовую помощь и реконструкцию, например, зданий и базовой инфраструктуры. Кроме того, активное участие местных сообществ в управлении стихийными бедствиями может привести к устойчивости сообщества [2].

Классификация чрезвычайных ситуаций

Виды чрезвычайных ситуаций	Территориальная принадлежность	Количество погибших, пострадавших
Локального характера	Территория организации (объекта)	Не более 10 человек
Муниципального характера	Территория одного муниципального образования	Не более 50 человек
Межмуниципального характера	Территория двух и более муниципальных образований	Не более 50 человек
Регионального характера	Территория одного субъекта	От 50 до 500 человек
Межрегионального характера	Территория двух и более субъектов	От 50 до 500 человек
Федерального характера	—	Свыше 500 человек

МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ

Методы искусственного интеллекта, используемые на всех этапах для помощи в управлении стихийными бедствиями, состоят из нескольких методов машинного обучения и глубокого обучения. Методы машинного обучения поддерживают векторную машину (SVM), методы Naïve Bayes (NB), деревья решений (DT), случайный лес (RF), логистическую регрессию (LR) и k-ближайший сосед (KNN), включая алгоритм кластеризации. С другой стороны, методы глубокого обучения включают в себя различные архитектуры искусственных нейронных сетей (ANN), такие как сверточные нейронные сети (CNN), многослойный перцептрон (MLP), рекуррентные нейронные сети (RNN), нейронные сети с долговременной кратковременной памятью (LSTM), архитектура преобразователя и генеративно-состязательные сети (GAN). Машинное обучение и глубокое обучение помогают разрабатывать системы, которые могут прогнозировать аварии на основе больших и сложных наборов данных, а также разрабатывать инструменты реагирования и восстановления, а также практические инструменты поддержки принятия решений после таких событий. Эти методы используют преимущества возможности мани-

пулировать различными типами данных из нескольких источников и выявлять закономерности, обеспечивающие интеллектуальную информацию, которая в противном случае не была бы раскрыта. Большие данные доступны из таких источников, как спутниковые снимки, беспилотные летательные аппараты (UAV), социальные сети, краудсорсинг (crowdsourcing), географические информационные системы (GIS) и сети беспроводных датчиков [3].

Для построения классификатора на основе нейронных сетей необходимо выполнить следующие этапы:

- предварительная обработка данных;
- выбор топологии сети;
- выбор способов определения количества скрытых слоев;
- выбор способов определения количества нейронов скрытых слоев;
- выбор способов инициализации начальных весов;
- выбор алгоритма обучения сети, выбор способов оценки работы сети.

На рис. 1 показан пошаговый процесс обучения нейронной сети.

Одним из ключевых этапов в работе нейронной сети является процесс обучения с целью подбора весовых

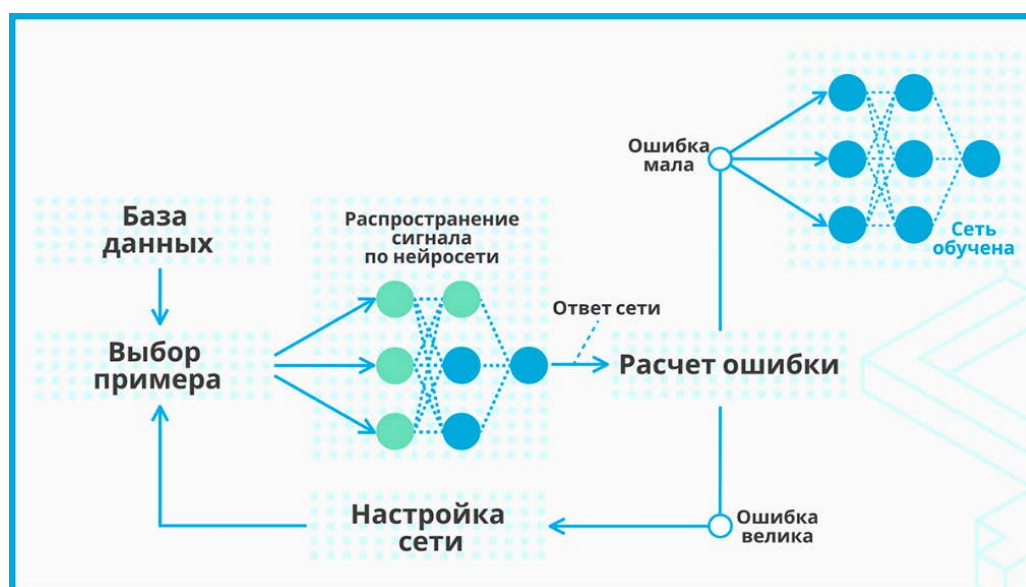


Рис. 1. Процесс обучения нейронной сети

Примерный набор данных о пожарах

Локация	Время суток	Причина пожара	Тип здания	Количество травм	Количество погибших
Объект 1	2:00 AM	Электрический	Высокий	3	0
Объект 2	11:00 PM	Кулинария	Маленькая семья	1	0
Объект 3	8:00 PM	Поджог	Склад	0	2
Объект 4	1:00 PM	Курение	Квартира	2	1
Объект 5	4:00 AM	Электрический	Офис	0	0
Объект 6	10:00 PM	Кулинария	Многоквартирный	4	3

коэффициентов. Математическая постановка задачи обучения нейронной сети — минимизация целевой функции ошибки нейронной сети. Широко распространенный метод градиентного спуска имеет ряд недостатков (низкая скорость сходимости, высокое число априорных показателей, проблема локального минимума). Альтернативой методу градиентного спуска является генетический алгоритм минимизации функции стоимости нейронной сети, который базируется на принципе естественного отбора и позволяет избежать многих проблем на этапе обучения сети. Также появляется возможность с помощью генетического алгоритма решить задачу выбора последовательности управляющих воздействий, при которой отклонение прогнозируемого значения комплексной оценки (или отдельного показателя электроэнергетической системы) от желаемого (требуемого значения показателя) минимально [4].

При обучении без учителя обучающее множество состоит лишь из входных векторов. Обучающий алгоритм подстраивает веса сети так, чтобы получались согласованные выходные векторы, то есть чтобы предъявление достаточно близких входных векторов давало одинаковые выходы. Процесс обучения, следовательно, выделяет статистические свойства обучающего множества и группирует сходные векторы в классы. Предъявление на вход вектора из данного класса даст определенный выходной вектор, но до обучения невозможно предсказать, какой выход будет производиться данным классом входных векторов. Следовательно, выходы подобной сети должны трансформироваться в некоторую понятную форму, обусловленную процессом обучения. Это не является серьезной проблемой. Обычно несложно идентифицировать связь между входом и выходом, установленную сетью [5].

Математически процесс обучения можно описать следующим образом: в процессе функционирования нейронная сеть формирует выходной сигнал Y , реализуя некоторую функцию $Y = G(X)$. Если архитектура сети задана, то вид функции G определяется значениями синаптических весов и смещенной сети. Пусть решением некоторой задачи является функция $Y = F(X)$, заданная параметрами входных-выходных данных, для которых $Y^k = F(X^k)$, ($k = 1, 2, \dots, N$). Обучение состоит в поиске (синтезе) функции G , близкой к F в смысле некоторой функции ошибки E . Если выбрано множество обучающих примеров — пар (X^n, Y^n)

(где $k = 1, 2, \dots, N$) и способ вычисления функции ошибки E , то обучение нейронной сети превращается в задачу многомерной оптимизации, имеющую очень большую размерность, при этом, поскольку функция E может иметь произвольный вид, обучение в общем случае — многоэкстремальная невыпуклая задача оптимизации. Для решения этой задачи могут использоваться следующие (итерационные) алгоритмы:

1. Алгоритмы локальной оптимизации с вычислением частных производных первого порядка: градиентный алгоритм (метод наискорейшего спуска); методы с одномерной и двумерной оптимизацией целевой функции в направлении антиградиента; метод сопряженных градиентов; методы, учитывающие направление антиградиента на нескольких шагах алгоритма.

2. Алгоритмы локальной оптимизации с вычислением частных производных первого и второго порядка: метод Ньютона; методы оптимизации с разреженными матрицами Гессе; квазиньютоновские методы; метод Гаусса — Ньютона; метод Левенберга — Марквардта и др.

3. Стохастические алгоритмы оптимизации: поиск в случайном направлении; имитация отжига; метод Монте-Карло (численный метод статистических испытаний).

4. Алгоритмы глобальной оптимизации (задачи глобальной оптимизации решаются с помощью перебора значений переменных, от которых зависит целевая функция) [6].

В табл. 2 представлен примерный набор данных о пожарах, где каждый инцидент описывается несколькими признаками, такими как местоположение, время суток, причина пожара, тип здания, количество травм и количество погибших.

На этом наборе данных можно обучить модель машинного обучения для прогнозирования вероятности травм или смертельных исходов в будущих пожарах на основе входных данных. Результатом модели может быть двоичный прогноз (например, травма или отсутствие травмы) или оценка вероятности, указывающая вероятность травм или смертельных исходов в данном инциденте с пожаром. Чтобы сделать прогноз с помощью модели машинного обучения на основе приведенной выше таблицы, нам сначала нужно обучить модель на большем наборе данных о пожарах с похожими характеристиками. Однако я могу привести гипотетический пример того, как модель машинного обучения можно использовать для прогнозирования на основе функций в таблице.

Модель машинного обучения

Локация Объект 1	Время суток (нормализованное)	Причина пожара (электрический)	Тип здания (высокий)
1	0,083	1	1

Предположим, у нас есть модель машинного обучения, обученная прогнозировать вероятность травм при пожаре на основе местоположения, времени суток, причины пожара и типа здания. Модель достигла точности 80 % на наборе данных проверки (табл. 3).

Конечный результат, полученный с использованием модели машинного обучения, будет зависеть от конкретной решаемой проблемы и показателей оценки, используемых для измерения производительности модели. Чтобы сделать прогноз с использованием алгоритма на основе приведенной выше таблицы, нам сначала нужно определить алгоритм и его правила. Для целей этого примера рассмотрим простой алгоритм, предсказывающий вероятность травм при пожаре на основе следующих правил:

- если причиной возгорания является приготовление пищи, высока вероятность травм;
- если тип здания многоэтажный, то вероятность травм умеренная;
- если тип здания представляет собой дом на одну семью или офисное здание, вероятность травм невелика;
- если время суток между 23:00 и 6:00 утра, вероятность травм высока;
- если время суток между 6:00 и 18:00, вероятность травм умеренная;
- если время суток между 18:00 и 23:00, вероятность травм низкая;
- если число погибших больше 0, вероятность травм высокая.

Основываясь на этих правилах, мы можем делать прогнозы для каждой строки таблицы следующим образом:

- ряд 1. Причина пожара — электрическая, тип здания — многоэтажный, поэтому вероятность травм умеренная;
- ряд 2. Причина пожара — приготовление пищи, тип здания — одноквартирный, поэтому вероятность травм низкая;
- ряд 3. Причина пожара — поджог, тип здания — склад, поэтому у нас недостаточно информации, чтобы сделать прогноз;
- ряд 4. Причина возгорания — курение, тип здания — квартира, поэтому вероятность травм умеренная;
- ряд 5. Причина возгорания — электричество, тип здания — офис, поэтому вероятность травм низкая;
- ряд 6. Причина пожара — приготовление пищи, тип здания — многоквартирный, поэтому вероятность травм умеренная.

Важно отметить, что точность прогнозов алгоритма будет зависеть от качества правил и допущений, сделанных в отношении взаимосвязи между входными характеристиками и вероятностью травм при пожаре. На практике модель машинного обучения может выявлять более

сложные закономерности в данных и делать более точные прогнозы, чем такой простой алгоритм.

Основываясь на этих особенностях, модель машинного обучения прогнозирует 75 % вероятность травм при пожаре. Этот прогноз основан на усвоенных моделях закономерностей из обучающего набора данных и предположениях, сделанных в отношении взаимосвязи между входными характеристиками и вероятностью травм при пожаре. Однако важно отметить, что это всего лишь гипотетический пример и точность прогноза будет зависеть от качества обучающих данных и производительности модели машинного обучения. Предлагается использовать модели, основанные на синтезе искусственных нейронных сетей и генетических алгоритмов, для выбора последовательности управляющих воздействий для различных ситуаций. Чрезвычайные ситуации являются одной из основных причин гибели людей и ущерба инфраструктуре и имуществу. Достижения в области машинного и глубокого обучения все чаще используются для управления сложными стихийными бедствиями. В этих случаях к различным пожарам, стихийным бедствиям, в том числе наводнениям, лавовым потокам, землетрясениям, тайфунам, ураганам, оползням, применялись различные методы машинного обучения и глубокого обучения. Рассмотренные исследования сосредоточены на пожарах, стихийных бедствиях и прогнозировании опасностей, оценке риска и уязвимости, обнаружении бедствий, системах раннего предупреждения, мониторинге бедствий, оценке ущерба и реагировании после бедствий, а также на прикладных исследованиях и приложениях.

ЗАКЛЮЧЕНИЕ

Будущие исследования должны сосредоточиться на использовании методов машинного обучения для повышения эффективности операций аварийного восстановления. Методы глубокого обучения и алгоритмы кластеризации могут помочь усилить меры по смягчению последствий стихийных бедствий, уменьшить уязвимость и оценить устойчивость инфраструктуры. Применение машинного обучения в управлении чрезвычайными ситуациями открывает новые перспективы для эффективного реагирования на бедствия и минимизации их негативных последствий.

ЛИТЕРАТУРА

1. Sun, W. Applications of Artificial Intelligence for Disaster Management / W. Sun, P. Bocchini, B.D. Davison // Natural Hazards. 2020. Vol. 103, Is. 3. Pp. 2631–2689. DOI: 10.1007/s11069-020-04124-3.

2. Drakaki, M. Investigating the Impact of Site Management on Distress in Refugee Sites Using Fuzzy Cognitive Maps / M. Drakaki, P. Tzionas // *International Journal of Disaster Risk Reduction*. 2021. Vol. 60. Art. No. 102282. 15 p. DOI: 10.1016/j.ijdr.2021.102282.

3. Drakaki, M. An Intelligent Multi-Agent Based Decision Support System for Refugee Settlement Siting / M. Drakaki, H.G. Gören, P. Tzionas // *International Journal of Disaster Risk Reduction*. 2018. Vol. 31. Pp. 576–588. DOI: 10.1016/j.ijdr.2018.06.013.

4. Воропай, Н. И. Интегрированные интеллектуальные энергетические системы / Н. И. Воропай, В. А. Стенников // *Известия Российской академии наук. Энергетика*. 2014. № 1. С. 64–73.

5. Галушкин, А. И. Нейронные сети: основы теории. — Москва: Горячая линия — Телеком, 2012. — 496 с.

6. Гафаров, Ф. М. Искусственные нейронные сети и их приложения: Учебное пособие / Ф. М. Гафаров, А. Ф. Галимянов. — Казань: Изд-во Казанского ун-та, 2018. — 121 с.

ИНФОРМАЦИЯ ОБ АВТОРЕ

Корабосhev Ойбек Зокирович — аспирант. Научно-исследовательский институт развития цифровых технологий и искусственного интеллекта, Ташкент, Узбекистан. E-mail: koraboshevoybek@gmail.com

Статья поступила в редакцию 07.12.2024; одобрена после рецензирования 10.03.2024.

Machine Learning in Emergency Management: Analysis and Methods

O. Z. Koraboshev

Digital Technologies and Artificial Intelligence Research Institute, Tashkent, Uzbekistan

Abstract. This article focuses on fire research, disaster and hazard forecasting, risk and vulnerability assessment, early detection of disasters, early warning systems, disaster monitoring, damage assessment and post-disaster response, and case studies.

Keywords: machine learning, deep learning, vector machine, clustering algorithm, local optimization algorithms, local optimization algorithms, stochastic algorithms.

For citation: Koraboshev O. Z. Machine Learning in Emergency Management: Analysis and Methods // *Intellectual Technologies on Transport. 2024. No. 1 (37). P. 12–17. (In Russian)* DOI: 10.20295/2413-2527-2024-137-12-17

REFERENCES

1. Sun W., Bocchini P., Davison B. D. Applications of Artificial Intelligence for Disaster Management, *Natural Hazards*, 2020, Vol. 103, Is. 3, Pp. 2631–2689. DOI: 10.1007/s11069-020-04124-3.
2. Drakaki M., Tzionas P. Investigating the Impact of Site Management on Distress in Refugee Sites Using Fuzzy Cognitive Maps, *International Journal of Disaster Risk Reduction*, 2021, Vol. 60, Art. No. 102282, 15 p. DOI: 10.1016/j.ijdr.2021.102282.

3. Drakaki M., Gören H. G., Tzionas P. An Intelligent Multi-Agent Based Decision Support System for Refugee Settlement Siting, *International Journal of Disaster Risk Reduction*, 2018, Vol. 31, Pp. 576–588. DOI: 10.1016/j.ijdr.2018.06.013.

4. Voropai N. I., Stennikov V. A. Integrated Smart Energy Systems [Integrirovannye intellektualnye energeticheskie sistemy], *Izvestiya Rossiyskoy akademii nauk. Energetika*, 2014, No. 1, Pp. 64–73.

5. Galushkin A. I. Neural networks: Fundamentals of theory [Neyronnye seti: osnovy teorii]. Moscow, Goryachaya liniya — Telekom Publishing House, 2012, 496 p.

6. Gafarov F. M., Galimyanov A. F. Artificial neural networks and their applications: Study guide [Iskusstvennye neyronnye seti i ikh prilozheniya: Uchebnoe posobie]. Kazan, Kazan Federal University, 2018, 121 p.

INFORMATION ABOUT AUTHOR

Koraboshev Oybek Zokirovich — postgraduate student. Digital Technologies and Artificial Intelligence Research Institute, Tashkent, Uzbekistan. E-mail: koraboshevoybek@gmail.com

The article was submitted 07.12.2024; approved after reviewing 10.03.2024.