

Научная статья
УДК 614.872
doi: 10.34987/vestnik.sibpsa.2022.66.55.013

К вопросу о подходе к разработке цифровой системы мониторинга общей обстановки и ЧС в мирное и военное время

Илья Александрович Шереметьев¹
Александр Михайлович Костецкий¹
Петр Максимович Юданов¹
Игорь Станиславович Каторжин¹
Иван Юрьевич Сергеев²

¹Академия гражданской защиты МЧС России, Химки, Россия

²Сибирская пожарно-спасательная академия ГПС МЧС России, Железногорск, Россия
Автор, ответственный за переписку: Петр Максимович Юданов repo128@yandex.ru

Аннотация. Данная статья посвящена вопросу применимости нейронных сетей для автоматического анализа изображений с камер видеонаблюдения в режиме реального времени для оперативного реагирования на чрезвычайные ситуации (далее - ЧС), возникающие от схода оползней и селей. Для проектирования архитектуры нейронной сети и управления её параметрами была использована высокоуровневая программная платформа tensorflow keras (далее – платформа). Для компенсации малого объема набора обучающих данных при решении задачи была показана применимость десятикратной аугментации изображений, использование чередования свёрточных слоёв и определённые значения оптимизатора Adam. Метрика полноты (recall) на уровне 94.4% показывает успешность выбранного подхода. Результаты данной работы могут быть использованы при разработке специализированного программного обеспечения для предупреждения чрезвычайных ситуаций в селе- и лавиноопасных регионах и в разработке цифровой системы мониторинга общей обстановки ЧС в мирное время, благодаря которой ускорится обработка информации, а также уменьшится время доведения оперативной информации до органов управления и спасательных подразделений МЧС России.

Ключевые слова: нейронная сеть, чрезвычайная ситуация, программная платформа, ограниченный набор обучающих данных

Для цитирования: Шереметьев И.А., Костецкий А.М., Юданов П.М., Каторжин И.С., Сергеев И.Ю. К вопросу о подходе к разработке цифровой системы мониторинга общей обстановки и ЧС в мирное и военное время // Сибирский пожарно-спасательный вестник. 2022. № 4 (27). С. 75-81. <https://doi.org/10.34987/vestnik.sibpsa.2022.66.55.013>.

TO THE PROBLEM OF THE DEVELOPMENT OF A DIGITAL SYSTEM FOR MONITORING THE GENERAL SITUATION AND EMERGENCIES IN TIME OF PEACE AND WAR

Ilya A. Sheremetiev¹
Alexander M. Kostetsky¹
Petr M. Yudanov¹
Igor S. Katorzhin¹
Ivan Yu. Sergeev²

¹Civil Defence Academy of Emercom of Russia, Khimki, Russia

²*Siberian Fire and Rescue Academy EMERCOM of Russia, Zheleznogorsk, Russia*

Corresponding author: Petr M. Yudanov, reno128@yandex.ru

Abstract. This article is devoted to the applicability of neural networks for automatic analysis of images from CCTV cameras in real time for rapid response to emergencies (hereinafter referred to as emergencies) arising from landslides and mudflows. To design the architecture of the neural network and control its parameters, the high-level software platform tensorflow keras (hereinafter referred to as the platform) was used. The completeness metric (recall) at the level of 94.4% shows the success of the chosen approach. The results of this work can be used in the development of specialized software for the prevention of emergencies in rural areas and avalanche-prone regions and in the development of a digital system for monitoring the general situation of emergencies in peacetime, which will speed up the processing of information, as well as reduce the time for bringing operational information to the authorities and rescue units of the EMERCOM of Russia.

Keywords: neural network, emergency, software platform, limited set of training data

For citation: Sheremetiev I.A., Kostetsky A.M., Yudanov P.M., Katorzhin I.S., Sergeev I.Yu. To the problem of the development of a digital system for monitoring the general situation and emergencies in time of peace and war // Siberian Fire and Rescue Bulletin.2022;4(27):75-81. (In Russ.). <https://doi.org/10.34987/vestnik.sibpsa.2022.66.55.013>.

На сегодняшний день на территории Российской Федерации происходит большое количество ЧС, которые отслеживаются с использованием различных систем, аппаратуры, в том числе и с учетом данных, представленных очевидцами и свидетелями. В данном случае решающее значение имеет человеческий фактор.

В соответствии с Федеральным законом от 21 декабря 1994 г. № 68-ФЗ «О защите населения и территорий от ЧС природного и техногенного характера» органы управления и силы РСЧС функционируют в режимах повседневной деятельности, повышенной готовности и ЧС, порядок организации деятельности которых и уровень реагирования (объектовый, местный, региональный и федеральный) определяются в зависимости от классификации ЧС, характера ее развития, привлекаемых сил и средств, а также других факторов. Уровень реагирования определяется решением соответствующего руководителя органа государственной власти, в ведении которого находится территория, подвергшаяся угрозе или воздействию ЧС. [5].

Порядок определения и реагирования на ЧС природного и техногенного характера следующий:

- 1) Обнаружение ЧС.
- 2) Передача информации в дежурное отделение МЧС России по месту возникновения ЧС.
- 3) Обработка полученной информации сотрудниками отдела.
- 4) Оценка обстановки на территории ЧС.
- 5) Планирование действий по ликвидации ЧС.
- 6) Направление сотрудников МЧС России на территорию ЧС для её ликвидации.

Чтобы выполнить все пункты данного плана, необходимо привлечение определенного количества сотрудников и временных затрат. Машинный труд ускорит обработку информации, а также уменьшит время доведения информации до непосредственных исполнителей. Это поможет выйти на новый уровень качества мониторинга и реагирования специальных служб.

В последнее время, все чаще для обработки и обобщения больших объемов информации используются нейронные сети. Их использование может серьезно ускорить и облегчить выполнение различных задач за счёт автоматизации действий, которые ранее были под силу только человеку.

Авторами предлагается подход по мониторингу и предупреждению последствий сходов селей и лавин с использованием камер наружной фиксации с последующей обработкой и передачей полученной информации на пункты управления.

Нейронная сеть представляет собой совокупность математических алгоритмов большого размера, способных на обобщение и выявление закономерностей в большом объеме данных, где фактически невозможно вывести аналитическую (формульную) зависимость между признаками полученных данных (в нашем случае – расположением и цветом отдельных пикселей на изображении) и итоговым исходом – вероятностью наличия оползня в данном районе. Перед использованием нейронной сети, её необходимо обучить, то есть сообщить систематизированные размеченные данные, для которых известно где есть оползень, а где – нет, рисунок 1. Средний объем данных для подобных задач обычно исчисляется тысячами специальным образом подготовленных людьми экземпляров (в нашем случае – пар изображений), что совершенно нивелирует экономию времени [6].



Рис. 1. Пара обучающих изображений до и после оползня

Для решения этой проблемы, в данной работе была использована свёрточная нейронная сеть и определённые подходы к предобработке изображений.

В связи с необходимостью переходить на отечественное программное обеспечение (Приказ Минкомсвязи России от 20.09.2018 №486), нами была использована библиотека глубокого обучения tensorflow keras на языке программирования python, запускаемая в любой среде разработки, входящей в «Реестр отечественного ПО», например, CUBA Studio на операционной системе «Роса».

Целевая установка данной работы - оценка способности выбранной нейронной сети с обучающей выборкой всего в 150 пар изображений предсказывать бинарный исход: наличие или отсутствие оползня с достаточной вероятностью, которая определялась по стандартным метрикам качества нейронной сети - полноте (recall) и точности (precision).

Нейронная сеть является математической моделью с совокупностью нейронов, которые соединены между собой определенным образом. [2]

Из набора сигналов, которые поступают на вход сети, в результате умножения на веса каждого нейрона и применения функции активации формируется один или несколько выходных сигналов, в нашем случае выходной сигнал бинарный, то есть «0», есть оползень или «1» нет оползня.

Для проверки качества обучения нейронной сети размер валидационной выборки был принят на стандартном уровне в 17% (25 пар изображений) [4]. Изображения валидационной выборки несколько раз подаются в обученную сеть для сравнения разметки и отклика сети и таким образом оценки вероятности её ошибки.

В данной работе каждая пара изображений была приведена к чёрно-белому виду и единому разрешению 500 на 500 пикселей и представлена в виде двумерного массива чисел 500*500, где каждое число отвечает за цвет конкретной точки: 0 это полностью чёрная точка, а 255 это белая. Полученная матрица целых чисел и была подана на вход в нейронную сеть.

Работа по ручному сбору и первичной обработке 350 изображений заняла у авторов данной статьи около 15 часов.




Рис. 2. Часть базы данных изображений

Для снижения требуемого количества оригинальных изображений для обучения, был использован метод аугментации изображений. Он заключается в одинаковом искажении пары изображений (поворота, растяжения или сжатия вдоль оси, смещения или зеркального отражения), за счёт чего нейронная сеть будет «видеть» эту пару как новую. Данную функцию стало возможным реализовать в автоматическом режиме с использованием выбранной платформы. Для каждой пары изображений было проведено по 10 аугментаций. Большее количество аугментаций было бы неэффективным, так как привело бы к переобучению сети. [2]

Для большего снижения количества требуемых данных и повышения эффективности работы сети была использована свёрточная (convolutional) нейронная сеть. Свёрточная сеть состоит из нескольких свёрточных слоёв, которые понижают размерность матрицы данных, выделяя основные признаки: типичную форму и сопутствующий ей градиент цвета на изображении. Свёрточные слои снижают качество изображения и количество пикселей в нём и их применение оправдано в нашем случае, потому что один конкретный пиксель на изображении с оползнем не несёт в себе никакой полезной информации, по нему нельзя сделать вывод о статусе всего изображения. Важные признаки локальны – основываются на данных в некоторой окрестности пикселя. И вся эта локальная область в результате свёртки превращается в один пиксель промежуточного изображения, этот процесс повторяется несколько раз, после чего результат сжимается (flatten) в одномерный вектор и подаётся в полно связную нейронную сеть для обработки и формирования ответа. Далее показано случайное ядро свёртки, коэффициенты которого в нашем случае обучаются самой нейронной сетью, и примерное выделение признаков на изображении собаки, рис. 3.




Рис. 3. Выделение признаков (линий и форм максимального градиента цвета) с помощью ядра свёртки

После анализа литературы [8,9] и специфики и масштаба изображений с оползнем, было выбрано 3 свёрточных слоя с матрицей свёртки 3*3 и страйдингом (striding) в 2 единицы, каждый из которых понижает разрешение в 2 раза. Таким образом промежуточные изображения будут иметь разрешение 62*62 пикселя, и как видно на рисунке, явно отражают признаки оползня.

Архитектура нейронной сети строилась авторами также исходя из вычислительной мощности компьютера среднего уровня 2010-2015 годов выпуска – подобные компьютеры сейчас составляют большинство в государственных учреждениях в том числе в системе МЧС России. Данную нейронную сеть также возможно обучать в режиме онлайн с использованием облачных сервисов типа Google colab. Время обучения на любой платформе составляет не более 30 минут.




Рис. 4. Архитектура созданной нейронной сети

Изображения представлены массивом 500x500 со значениями пикселей от 0 до 255. Метки являются массивом целых чисел со значениями (0;1), которые соответствуют одному из 2 типов обстановки.

Для начала данные должны быть обработаны перед обучением сети. В изображении тренировочного набора значения пикселей попадают в диапазон от 0 до 255. Нормализуем их, приведя к диапазону от 0 до 1, прежде чем передавать их в модель нейронной сети. Для этого мы делим значения на максимальное – 255.

Обработанные изображения поступают в «ядро» нейронной сети, которое было реализовано на языке программирования Python с подключением API tf.keras.

Обучение нейронной сети происходит за счёт сличения выходного сигнала с меткой реального изображения с использованием функции потерь. Функция потерь может зависеть от некоторых переменных, таких как веса и смещения в случае линейной функции активации нейрона и обновление весов нейронной сети идёт в сторону наибольшего отрицательного градиента данной функции. [2]

В нашей работе используется функция потерь бинарной перекрестной энтропии (BinaryCategoricalCrossentropy), которая вычисляет потери перекрестной энтропии между метками и предсказаниями при всего двух возможных значениях выходного сигнала.

Метод обучения с помощью стохастического градиентного спуска по функции потерь был выполнен с помощью оптимизатора Adam с перебором различных параметров и выбором оптимальных, рис. 5.

```
tf.keras.optimizers.Adam(  
    learning_rate=0.001,  
    beta_1=0.9,  
    beta_2=0.999,  
    epsilon=1e-07,  
    amsgrad=False,
```

Рис. 5. Оптимальные параметры Adam

Согласно [3], метод вычислительно эффективен, имеет мало требований к памяти, инвариантен к диагональному масштабированию градиентов и хорошо подходит для задач, которые велики с точки зрения данных параметров.

Для определения качества работы нейронной сети авторами была выбрана полнота (recall), а не точность (precision) в качестве метрики качества, расчёт которых проводится по формулам (1) и (2).

$$\text{Precision} = \frac{TP}{TP + FP} \tag{1}$$

$$\text{Recall} = \frac{TP}{TP + FN} \tag{2}$$

где:

TP – вероятность истинно положительных ответов сети;

FP – вероятность ложноположительных;

FN – вероятность ложноотрицательных.

Данный выбор был связан с тем, что в нашем случае намного важнее минимизировать количество ложноотрицательных ответов сети: ответов, что оползня нет, когда на самом деле он есть, что увеличит время реагирования и, соответственно, ущерб, чем ложноположительных, которые просто потребуют несколько минут времени на проверку.

На рисунке 6 показано изображение местности, не входящее в обучающий датасет и предсказание его метки нейросетью со степенью уверенности (вероятности).

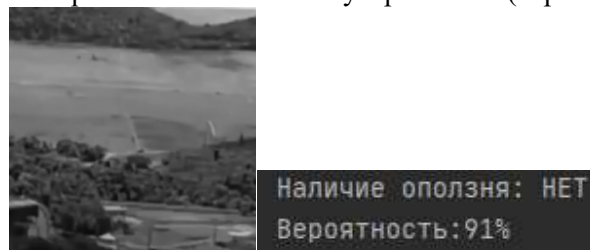


Рис. 6. Изображение и отклик на него нейронной сети

Выводы

Использование нейронной сети предложенной архитектуры, чередование свёрточных и тахрулинг слоёв, а также десятикратной аугментации в качестве предобработки позволяет эффективно использовать нейросетевое предсказание наличия оползня на определённой территории на уменьшенном наборе обучающих данных в автоматическом режиме с достаточно высокой метрикой полноты – 94.4%.

Это значение метрики превосходит вероятность истинного ответа при опросе свидетелей и ручном анализе изображений с камер, где по разным оценкам наблюдается до 10% ложных результатов.

Предложенный авторами подход по использованию высокоуровневой программной платформы tensorflow keras для обучения нейронной сети позволяют проводить один проход обучения на полном наборе данных меньше чем за 30 минут как на используемых в системе МЧС компьютерах, так и в облачных сервисах типа Google colab, что в свою очередь в разы сокращает время.

Перспективы дальнейшей работы в данном направлении

Нами планируется собрать больший объём изображений оползней на различных территориях и провести эксперимент по определению минимально достаточного объёма тренировочных данных на изображениях такого типа. Также планируется реализовать программу в виде приложения под операционную систему Windows с регулируемыми параметрами и архитектурой нейронной сети и оптимизатора, что позволит использовать её в других областях для более широкого круга задач. Ведётся также работа по оценке увеличения оперативности реагирования на ЧС при внедрении систем автоматизированной обработки изображений, выражаемой в снижении риска для населения.

Список источников

1. Модели машинного обучения производственного уровня. [Электронный ресурс] URL: <http://www.tensorflow.org>

2. Ф.М.Гафаров, А.Ф.Галимянов “Искусственные нейронные сети и их приложения” Казань - 2018

3. Высокоуровневый framework keras tensorflow [Электронный ресурс] URL: <http://www.keras.io>

4. Ростовцев В.С. Искусственные нейронные сети: учебник / В.С. Ростовцев. – Киров: Изд-во ВятГУ, 2014.

5. Сайт министерства МЧС России [Электронный ресурс] URL: <http://www.mchs.gov.ru>

6. Motion Blur Identification in Noisy Images Using Feed-Forward Back Propagation Neural Network By: Cho, C.-M.; Don, H.-S.. In: [Proceedings] 1991 IEEE International Joint Conference on Neural Networks Neural Networks, 1991.

7. Fruit Disease Classification using Convolutional Neural Network By: N, Pradheep; G, Praveen Raj K; Chanduru N M, Purna; N, Kalaivani; V, Nandalal. In: 2022 3rd International Conference on Electronics and Sustainable Communication Systems (ICESC) pp.1052-1057 Aug, 2021

8. Performance Evaluation of Low-Precision Quantized LeNet and ConvNet Neural Networks By: Tatar, Guner; Bayar, Salih; Cicek, Ihsan. In: 2022 International Conference on INnovations in Intelligent SysTems and Applications (INISTA) INnovations in Intelligent SysTems and Applications (INISTA), 2022 International Conference on. :1-6 Aug, 2022

9. Convolutional neural network model for gait classification of flexible lower limb exoskeleton By: Sun, Lei; Li, Chenghui. In: 2022 IEEE International Conference on Mechatronics and Automation (ICMA) pp.1178-1182 Aug, 2022.

List of sources

1. Production-level machine learning models. URL: <http://www.tensorflow.org>

2. F.M.Gafarov, A.F.Galimyanov «Artificial neural networks and their applications» Kazan- 2018

3. High-level framework keras tensorflow URL: <http://www.keras.io>

4. Rostovtsev V.S. Artificial neural networks: textbook / V.S. Rostovtsev. - Kirov: VyatGU Publishing House, 2014.

5. Website of EMERCOM of Russia URL: <http://www.https47.mchs.gov.ru>

6. Motion Blur Identification in Noisy Images Using Feed-Forward Back Propagation Neural Network By: Cho, C.-M.; Don, H.-S.. In: [Proceedings] 1991 IEEE International Joint Conference on Neural Networks Neural Networks, 1991.

7. Fruit Disease Classification using Convolutional Neural Network

By: N, Pradheep; G, Praveen Raj K; Chanduru N M, Purna; N, Kalaivani; V, Nandalal. In: 2022 3rd International Conference on Electronics and Sustainable Communication Systems (ICESC) pp.1052-1057 Aug, 2021

8. Performance Evaluation of Low-Precision Quantized LeNet and ConvNet Neural Networks By: Tatar, Guner; Bayar, Salih; Cicek, Ihsan. In: 2022 International Conference on INnovations in Intelligent SysTems and Applications (INISTA) INnovations in Intelligent SysTems and Applications (INISTA), 2022 International Conference on. :1-6 Aug, 2022

9. Convolutional neural network model for gait classification of flexible lower limb exoskeleton By: Sun, Lei; Li, Chenghui. In: 2022 IEEE International Conference on Mechatronics and Automation (ICMA) pp.1178-1182 Aug, 2022.

Информация об авторах

П.М. Юданов- кандидаты технических наук

И.С. Каторжин- кандидаты технических наук

И.Ю.Сергеев - кандидаты технических наук

Information about the authors

P.M. Yudanov - Ph.D. of Engineering Sciences

I. S. Katorzhin - Ph.D. of Engineering Sciences

I. Yu. Sergeev - Ph.D. of Engineering Sciences

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.

Статья поступила в редакция 28.11.2022; одобрена после рецензирования 20.12.2022; принята к публикации 21.12.2022.

The article was submitted 28.11.2022, approved after reviewing 20.12.2022, accepted for publication 21.12.2022.