

Научная статья
УДК 65.012.76
doi:10.34987/vestnik.sibpsa.2025.22.89.004

Некоторые особенности применения нейросетевых классификаторов текстов в деятельности пожарно-спасательных подразделений

Алексей Михайлович Авдеенко¹

Алексей Петрович Сатин²

Евгений Викторович Гаврилюк³

^{1,2}Академия Государственной противопожарной службы МЧС России, Москва, Россия

³Ногинский ордена Жукова спасательный центр МЧС России, Московская область, Ногинск, Россия

¹<https://orcid.org/0000-0003-2410-8510>

Автор, ответственный за переписку: Алексей Петрович Сатин, satin32@yandex.ru

Аннотация. Рассматривается возможность построения нейросетевого классификатора текстов, описывающих чрезвычайные ситуации различного типа. В основу положено построение многослойной нейронной сети для обучения на предварительно лематизированных текстах с использованием алгоритма tf-idf. Сеть обучена распознавать описание девяти чрезвычайных ситуаций и после их классификации присоединять к ним необходимые материалы от нормативных актов до прецедентов. Надежность классификации 0.89-0.90. Классификатор имеет два дополнительных модуля – модуль парсинга информационных источников (телеграмм-каналов и новостных ресурсов) и модуль геопарсинга, позволяющий при наличии упоминаний о географических наименованиях выдавать карту места происшествия географические координаты и, при необходимости, проводить статистический и кластерный анализ данных. Предлагается методика повышения производительности труда должностных лиц и оперативности реагирующих подразделений на местах. Определена топология нейронной сети как нейросетевая модель классификации чрезвычайных ситуаций и разработан механизм системы парсинга и обработки информации. Проведено сравнение с общеизвестными системами ChatGPT, Deepseek, получены лучшие результаты по точности предсказаний, учтены требования по защите информации. Практическое применение позволит сократить время обработки информации о пожарах и чрезвычайных ситуациях.

Ключевые слова: нейронная сеть, классификатор текстов, чрезвычайная ситуация, управление, парсинг данных

Для цитирования: Авдеенко А.М., Сатин А.П., Гаврилюк Е.В. Некоторые особенности применения нейросетевых классификаторов текстов в деятельности пожарно-спасательных подразделений // Сибирский пожарно-спасательный вестник. 2025. № 4 (39). С. 42-53. <https://doi.org/10.34987/vestnik.sibpsa.2025.22.89.004>.

Original article.

Some features of the use of neural network text classifiers in the activities of fire and rescue units

*Alexey M. Avdeenko*¹

*Alexey P. Satin*²

*Evgeniy V. Gavriluk*³

^{1,2}*Academy of the State Fire Service of the Ministry of Emergency Situations of Russia, Moscow, Russia*

³*Noginsk Order of Zhukov Rescue Center of the Russian Ministry of Emergency Situations, Moscow Region, Noginsk, Russia*

¹<https://orcid.org/0000-0003-2410-8510>

Corresponding author: *Alexey P. Satin, satin32@yandex.ru*

Abstract. The possibility of building a neural network classifier of texts describing emergency situations of various types is considered. The basis is the construction of a multi-layer neural network for training on pre-lemmatized texts using the tf-idf algorithm. The network is trained to recognize the description of nine emergency situations and, after their classification, to attach the necessary materials, from regulations to precedents. The classification reliability is 0.89-0.90. The classifier has two additional modules: a module for parsing information sources (telegram channels and news resources), and a module for geoparsing, which allows you to display a map of the incident location and its geographical coordinates, as well as perform statistical and cluster analysis of the data, if necessary. A method is proposed to increase the productivity of officials and the efficiency of field response units. The topology of a neural network is defined as a neural network model for classifying emergency situations, and a mechanism for parsing and processing information is developed. A comparison is made with well-known systems such as ChatGPT and DeepSeek. The results show better accuracy in predictions and take into account information security requirements. Practical application will reduce the time it takes to process information about fires and emergencies.

Keywords: neural network, text classifier, emergency, management, data parsing

For citation: Avdeenko A.N., Satin A.P., Gavriluk E.V. Some features of using neural network text classifiers for fire and rescue units // *Siberian Fire and Rescue Bulletin*. 2025. № 4 (39). С. 42-53. (In Russ.) <https://doi.org/10.34987/vestnik.sibpsa.2025.77.26.005>.

Введение

При управлении подразделениями МЧС России для принятия решений и организации межведомственного взаимодействия возникает необходимость анализа большого объема слабоструктурированной информации, не позволяющей чётко и однозначно интерпретировать нужные параметры управления. Анализ таких данных может быть определён как процесс поиска скрытых закономерностей и генерации новых знаний. К основным задачам анализа данных можно отнести прогнозирование, классификацию, поиск схожих черт, выдачу рекомендаций, выявление отклонений. Перечисленные задачи могут решаться при помощи специальной интеллектуальной системы, позволяющей проанализировать имеющуюся информацию, классифицировать ее, связать с существующими прецедентами и выдать рекомендации должностным лицам. Предлагается использовать специальный нейросетевой классификатор текстов (информации о чрезвычайной ситуации, проблемах организации межведомственного взаимодействия и т.д.), позволяющий обрабатывать и классифицировать большие объёмы данных, прецедентов и другой информации, в том числе получаемой в процессе мониторинга.

Нейросетевые технологии анализа текстов широко используются в силовых структурах, входящих в состав единой государственной системы предупреждения и ликвидации чрезвычайных ситуаций, в разных областях от оперативно-розыскных мероприятий до анализа предпочтений [1-4]. Подобные системы могут быть широко использованы в подразделениях МЧС России: кадровые службы, материально-техническое обеспечение, аналитические

и научные отделы, противопожарная профилактика, воспитательная работа, подготовка спасателей в спасательных центрах.

При этом, с учётом современных угроз, следует принимать во внимание проблемы защиты речевой акустической информации [5] и при приёме сообщения о деструктивном событии или мониторинге информации о чрезвычайных ситуациях в социальных сетях принимать во внимание возможные вербальные агрессии для защиты граждан и личного состава МЧС России [6].

Концепция применения нейросетевых классификаторов слабоструктурированной информации для пожарно-спасательных подразделений

Предлагаемый нейросетевой классификатор текстов может быть использован по следующему алгоритму. На первом шаге для работы модели на входе предлагается использовать информацию, содержащую подробное описание чрезвычайной ситуации (пожара, подтопления или гуманитарной операции) или результаты мониторинга выбранных параметров управления (в зависимости от исследуемой организационной подсистемы, входящей в МЧС России). Эти описания формируют базу прецедентов, накапливаемых в структурных подразделениях (например, по пожарам в отделе служебно-боевой подготовки, проводящем разбор пожаров, данные по чрезвычайным ситуациям могут накапливаться в том числе в Ногинском спасательном центре и использоваться для подготовки спасателей на полигонах центра и т.д.). При этом должны соблюдаться требования к лингвистическому обеспечению информационной системы [7].

Схематично, процесс нейросетевого анализа текста представлен на Рис.1.



Рис.1. Перспективная схема нейросетевого анализа текстов

На следующем шаге информация обрабатывается нейронной сетью, обученной на основе претендентов.

На третьем шаге, после классификации прецедента формируется запрос к базе знаний принятым ранее решениям.

Ожидается что это позволит сократить время поиска нужной информации и использовать накопленный опыт тушения пожаров и проведения спасательных операций в практической деятельности.

Используемые для работы базы данных предлагается делить на три или более раздела:

- нормативы (в классическом понимании это справочники, позволяющие определить область допустимых значений при принятии решений);
- существующие прецеденты;
- шаблоны предпочтительных решений (рекомендации по ресурсам, скорректированный план выезда, рассылки распорядительной документации, форматы приказов и распоряжений, путевых листов, маршрутных карт и т.д.).

Дополнительно может быть подключен модуль топопривязки и, при наличии, специальный модуль 3d-визуализации объекта.

После решения задачи классификации, при необходимости предлагается использовать расширение подключенных баз данных, статистический анализ полученных результатов и использование когнитивной графики.

Нейросетевой классификатор слабоструктурированной информации

В качестве простейшей модели нейросетевого классификатора использовали многослойную нейронную сеть прямого распространения. База обучения была создана база из девяти принципиально различных чрезвычайных ситуаций (ЧС), представленная в Табл.1.

Табл.1. Обучающие и присоединенные данные для различных типов ЧС

| № п/п | Тип ЧС | Данные для обучения (строк) | Приказы, нормативные акты и прецеденты (страниц) |
|-------|-------------------------------|-----------------------------|--|
| 1. | Разминирование | 125 | 106 |
| 2. | Пожар | 137 | 26 |
| 3. | Наводнение | 68 | 26 |
| 4. | Ураган | 51 | 9 |
| 5. | Поисковые спасательные работы | 51 | 22 |
| 6. | Химическая авария | 94 | 21 |
| 7. | Радиационная авария | 88 | 1 |
| 8. | ДТП | 56 | 6 |
| 9. | Доставка гуманитарных грузов | 41 | 527 |

Обучающие тексты предварительно лематизировали и разделяли на абзацы 1-10 строк (5-50 слов). Всего использовалось от 50 строк для каждого типа чрезвычайной ситуации (в дальнейшем класса или категории ЧС).

Определялся и упорядочивался общий словарь всего корпуса текстов [7], каждому слову в соответствии с алгоритмом *tf-idf* ставилось в соответствие характеристика:

$$x_{ij} = \frac{n_{ij}}{N_j} \ln \frac{N}{n_{i+1}} \quad (1)$$

где, N – длина общего словаря корпуса текстов, N_i – словарь текстов класса i , n_{ij} – количество слов j в тексте класса i .

Величина x_{ij} характеризует степень принадлежности слова i классу j , чем чаще слово i встречается в классе j и реже в других классах, тем она больше.

Длина абзаца и величина словаря обучения определены в качестве переменных параметров обучающих текстов. Ранее было показано, что при описании ЧС классификация

возможна для абзацев более пяти строк и при словаре не менее 0.8 от общего словаря корпуса текстов [8].

Для распознавания классов текстов использовалась сеть с несколькими скрытыми слоями с линейной функцией активации и классифицирующий выходной слой с активацией *softmax*:

$$V(z_i) = \frac{e^{z_i}}{\sum_{i=0}^{Q-1} e^{z_i}}, \quad (2)$$

где, z_i - значение входа в i - нейрона выходного слоя, Q - количество классов обучения.

Было реализовано пакетное обучение – размер пакета $q=0.1$, размер тестирования $p = 0.3$ от общей базы.

В качестве меры качества обучения использовалась категориальная кросс-энтропия:

$$W(z_i) = - \sum_{i=0}^{Q-1} y_i \log(z_i), \quad (3)$$

где, y_i - ожидаемый выход; z_i - реализованный выход.

Полученная опытным путём оптимальная схема двухслойной нейронной сети представлена на Рис.2.

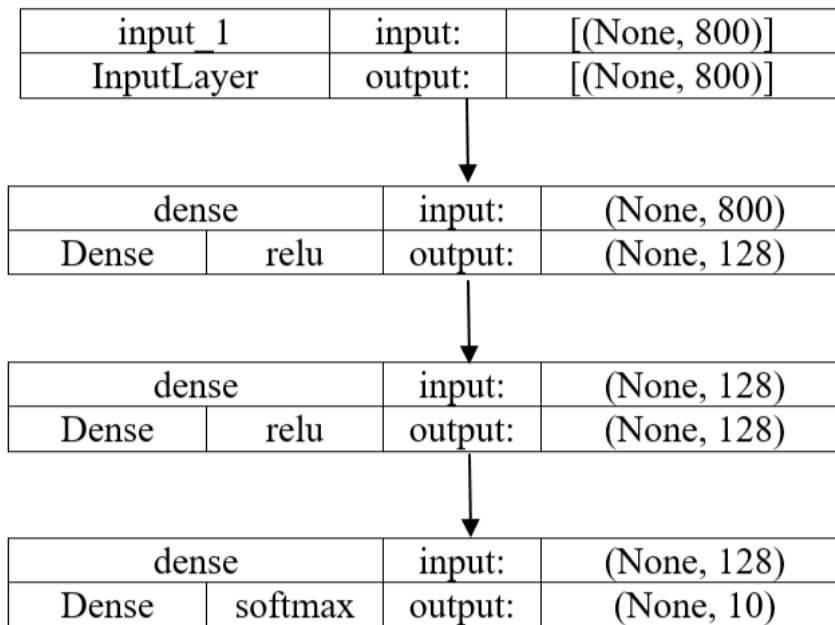


Рис.2. Топология нейронной сети для решения задач классификации текстов при документальном обеспечении и сопровождении чрезвычайной ситуации

В работах [3,8,9] сделан вывод, что данная методика не повышает вероятность правильного распознавания текста. В связи с чем выбран метод обратного распространения с использованием стохастической градиентной оптимизации [1-4]. Размерность скрытых слоев составила 128 нейронов, при количестве слоев равном 2. Увеличение, как количества слоев, так и их размерности существенно не улучшило описание.

При вычислительном эксперименте был использован общий словарь корпуса текстов [7], размерностью порядка 1000 слов. Для оценки эффективности нейронной сети после обучения выбрана величина p – доля правильно предсказанных кластеров на тестовой последовательности. При обучении нейронной сети использованы 800 первых, наиболее часто встречающихся слов. Проведён эксперимент по определению количества эпох обучения от 50 до 5000.

Было установлено, что для двуслойной сети по 128 нейронов при 5000 эпох обучения остаточная ошибка снижается более чем в 120 раз по сравнению с исходным состоянием (Табл.2). Сделан вывод о достаточности эпох обучения для решения задач правильного предсказания типа чрезвычайных ситуаций по результатам обработки тестовых данных.

Табл.2. Сравнение топологий нейронной сети

| K | P | | |
|---------|-------|-------|--------|
| | S=50 | S=500 | S=5000 |
| 64 | 0,611 | 0,671 | 0,719 |
| 128 | 0,550 | 0,684 | 0,737 |
| 128+128 | 0,570 | 0,698 | 0,955 |

где, K – число нейронов, S - число эпох обучения.

Зависимость кросс-категориальной энтропии, по результатам обучения нейронной сети оптимальной топологии, представлена на Рис.3.




Рис.3. Кривая обучения двухслойной нейронной сети со 128 нейронами в каждом слое; выполнена классификация 9 чрезвычайных ситуаций

После обучения выводилась вся необходимая статистика процесса: общие метрики принадлежности, точность, полнота и категориальные метрики. Дальнейшее уточнение модели классификации реализовывалось следующим образом: происходила нормализация размеров текстов и вычислялась вероятность принадлежности словаря критических терминов к тексту данного класса. Конечная мера принадлежности — это взвешенная величина между мерой, оцененной нейроклассификатором и этой вероятностью с весовыми коэффициентами, подобранными эмпирическим путем: они составили 0.7 и 0.3 соответственно.

Типичные результаты классификации представлены на Табл.3. Указана взвешенная мера принадлежности текста к заданному классу.

Табл.3. Меры принадлежности точность и полнота по категориям для сети оптимальной топологии

| Категория | Мера принадлежности | Точность | Полнота |
|-------------------------------|---------------------|----------|---------|
| Наводнение | 0.921 | 0.941 | 0.910 |
| Пожар | 0.892 | 0.913 | 0.880 |
| Химическая авария | 0.874 | 0.894 | 0.861 |
| Радиационная авария | 0.910 | 0.935 | 0.902 |
| ДТП | 0.883 | 0.902 | 0.873 |
| Ураган | 0.863 | 0.881 | 0.851 |
| Разминирование | 0.901 | 0.923 | 0.89 |
| Поисковые спасательные работы | 0.855 | 0.878 | 0.844 |
| Доставка гуманитарных грузов | 0.884 | 0.902 | 0.874 |

Если текст не классифицирован по критериям пользователя, то он может быть использован для переобучения системы на новые классы. Так же при избыточном количестве текстов, отнесенных к одному классу, возможно введение подклассов с последующим переобучением сети.

Функционирование, представленной на Рис.2 нейронной сети, сравнивали с результатами работы нейронных сетей *Deepseek* и *ChatGPT*, доступных в интернете [15,16]. Результаты сравнения представлены в Табл.4.

Табл.4. Оценка качества работы нейронных сетей

| Качество прогноза | Предложенная сеть | ChatGPT | Deepseek |
|-------------------|-------------------|---------|----------|
| p | 0,945 | 0,821 | 0,823 |

В качестве параметра сравнения использовали долю правильно предсказанных категорий p. Тестовая выборка состояла из 18 различных текстов 9 категорий. Результаты свидетельствуют о корректной работе каждой сети. Однако, надежность прогноза разработанной нейронной сети выше, чем в сетях доступных в интернете.

Сравнение с сетью Bert не проводилось поскольку реализована принципиально иная концепция. В предложенном варианте каждая новая категория требует переобучения всей сети и, как следствие, происходит перенормировка принадлежностей данного текста ко всем категориям в отличие от Bert, решающем задачу парной классификации («принадлежит-не принадлежит»). Преимущество Bert в возможности неограниченного наращивания числа обучаемых категорий, время на обучение линейно по их количеству. Однако, для задачи классификации ЧС существует возможность принадлежности текста к разным категориям со близкой метрикой. Например, ЧС «Наводнение» может сопровождаться категорией «Доставка гуманитарных грузов» поэтому баланс метрик позволяет более эффективно и точно оценивать поступающую информацию и принимать управленческие решения.

Графический интерфейс пользователя и вспомогательные модули системы

Система нейроклассификации с помощью простейшей нейронной сети является ядром предполагаемой системы парсинга и обработки информации для нужд МЧС России. Для её функционирования необходимо реализовать автоматизированный поиск информационных источников [19-22]. Что было реализовано путём вычислительного эксперимента последовательно двумя способами. Во-первых, система включает модули для сбора данных из различных источников: Telegram-каналы, для которых используется библиотека ruogram, позволяющая аутентифицироваться в Telegram через API и получать сообщения из открытых и закрытых каналов, далее новостные сайты и другие веб-источники. Также реализована возможность парсинга по ссылкам из Excel-файлов с региональной локализацией, с использованием библиотек BeautifulSoup или Scrapy для извлечения контента веб-страниц [13]. Во-вторых, при наличии в собранных данных упоминания географических наименований, реализована надстройка геопарсинга на основе модуля Geoparser с использованием YandexMaps.

Графический интерфейс пользователя (GUI) реализован с использованием кросс-платформенного фреймворка *Kivy*. Первая страница интерфейса представлена на Рис.4.

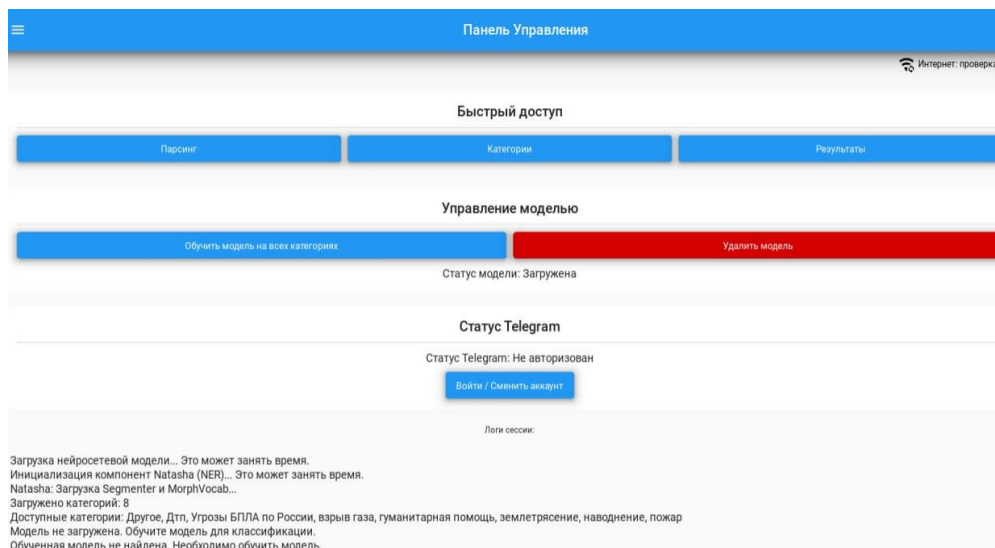


Рис.4. Графический интерфейс пользователя системы интеллектуального парсинга информационных источников

В ряде случаев возможно выполнение статистических процедур, в частности, при наличии информации о пожарах за определенный период времени возможно создание карты возгораний, вычисление координат и решение задачи кластерного анализа: определяется центр кластера пожаров, возможных маршрутов от предварительно заданных адресов ближайших пожарных частей до очагов возгорания либо центров кластеров. Данные парсинга при статистическом анализе могут быть дополнены информацией из журнала вызовов на пожары или по карточке системы 112.

Реализация геопарсинга и кластерного анализа на примере Московской области представлена на Рис.5.

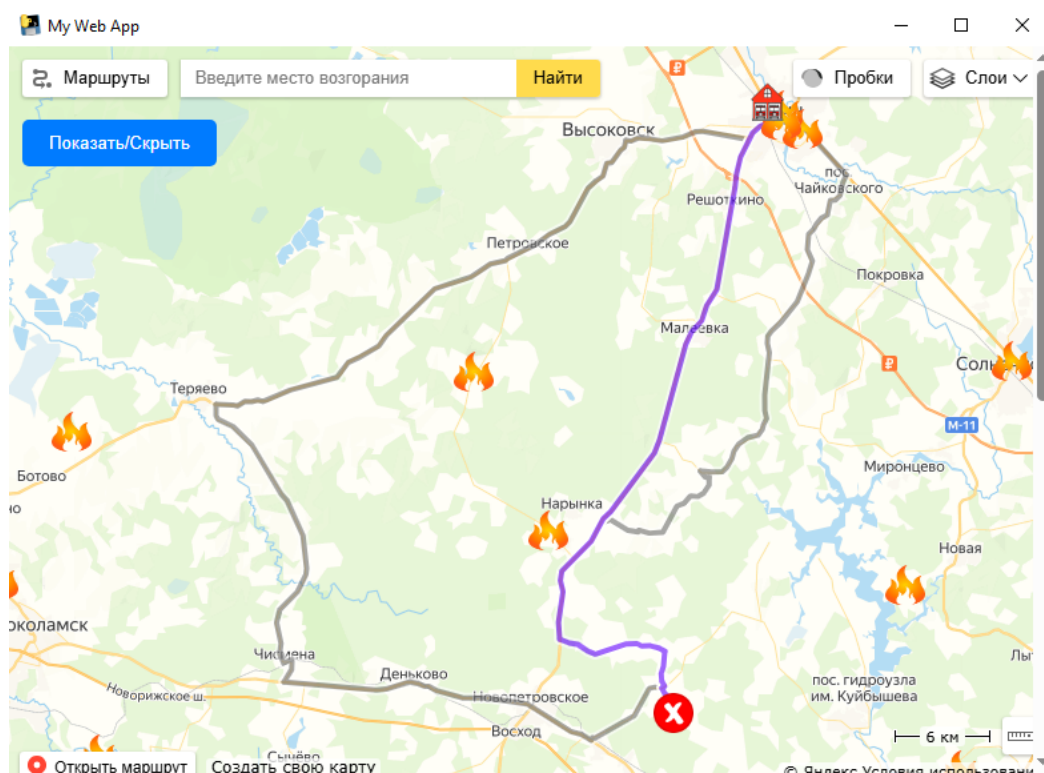


Рис.5. Парсинг очагов возгорания, указаны центры кластеров возгорания и маршруты до ближайших пожарных частей

Интерфейс обеспечивает возможность запуска приложения на различных операционных системах (*Windows, macOS, Linux*) без изменения кодовой базы. Вход в систему реализуется с помощью QR-кода. Использование интерфейса включает в себя возможность получения информации об уже обученной на распознавание ряда категорий нейросети, возможность выбора типа источников (ТГ-каналы или новостные сайты), обучение сети на распознавание новых категорий, задание числа анализируемых сообщений и, при необходимости, ключевых слов, сохранение результатов парсинга в удобной для дальнейшего анализа форме. В связи с участившимися в последнее время угрозами атаки БПЛА, добавлена советующая категория деструктивного события.

Обсуждение результатов и дальнейшие перспективы

Полученные результаты свидетельствуют о возможности построения нейросетевого классификатора текстов, описывающих чрезвычайные ситуации различного типа с последующим подключением парсинга как информационных источников, так и геопарсинга. В настоящее время в Академии ГПС МЧС России совместно с Ногинским спасательным центром проводятся дополнительные исследования о возможности прикрепления к классифицируемому тексту нормативных актов, классифицируемых на две группы - федерального и отраслевого уровня [13].

По итогам выполненной работы предлагается гипотеза о том, что при накоплении достаточной информации о чрезвычайной ситуации, в присоединяемом блоке прецедентов возможно агрегирование следующих групп, описывающих исследуемые чрезвычайные ситуации и принятые меры:

1. Группа географической локализации и топопривязки места возникновения чрезвычайной ситуации.
2. Группа текстов, описывающих физический уровень описания чрезвычайной ситуации (весеннего паводка - уровень поднятия воды, территория затопления, необходимость эвакуации населения и т.д., защита дачных посёлков во время природных пожаров – геометрические размеры проездов, параметры техники и т. д).
3. Группа текстов, описывающих социально-экономические последствия (пострадавшие, материальный ущерб, общественное мнение и реакция блогосферы, средств массовой информации и населения на действия сотрудников МЧС и др.).
4. Группа текстов, описывающих управленческие решения различных должностных лиц (оценка ситуации по внешним признакам, оценка потребности в силах и средствах в рамках межведомственного взаимодействия, оценка времени реагирования и эффективности принятых мер, анализ ошибок, допущенных при ликвидации последствий ситуации). Тексты, содержащие организационные и иные выводы, принятые на разных уровнях управления.

Заключение

В Академии ГПС МЧС России совместно с Ногинским спасательным центром МЧС России проводятся исследования по возможности применения методов искусственного интеллекта в том числе использованию нейросетевых классификаторов текстов для целей повышения производительности труда лиц, принимающих решения и оперативности реагирующих подразделений на местах. Экспериментальным путём определена топология нейронной сети как нейросетевая модель классификации чрезвычайных ситуаций и разработан механизм системы парсинга и обработки информации для нужд МЧС России.

По результатам работы авторы пришли к следующим выводам:

1. Предложена нейролингвистическая модель классификации чрезвычайных ситуаций по их текстовому описанию в виде трехслойной нейронной сети (два скрытых слоя и один классифицирующий). Обучение сети предлагается производить на предварительно леманизированных текстовых файлах, упорядоченных по вероятности встречи слов общего

словаря корпуса текстов. Достаточным является словарь, превышающий 0.8 от всего словаря корпуса текстов.

2. В качестве входных перерешенных обучения сети предложено использовать количественные характеристика слов корпуса текстов, обработанные в соответствии с алгоритмом *tf-idf*. Надежность предсказания отнесения одного из девяти типов чрезвычайных ситуаций к заданному типу определена в интервале 0.89-0.92 при 5000 эпохах обучения.

3. Сравнение предлагаемой информационной системы с общеизвестными системами ChatGPT, Deepseek показали лучшие результаты по точности предсказаний и с учётом требований по защите информации позволяют сделать заключение о жизнеспособности и востребованности таких систем в силовых ведомствах.

4. Разработана надстройка к предложенной системе нейросетевого классификатора позволяющая осуществлять автоматизированный парсинг информационных источников совместно с геопарсингом и последующим статистическим анализом данных. Создан удобный и функциональный интерфейс пользователя.

5. К результатам классификации могут быть добавлены нормативные акты приказы и прецеденты соответствующего типа, что позволяет ускорить принятие управленческого решения с учётом принятых ограничений организационной системы управления.

Список источников

1. Jones K.S. A statistical interpretation of term specificity and its application in retrieval (англ.) // Journal of Documentation: журнал. – MCB University: MCB University Press, 2004. – Vol. 60, no. 5. – P. 493 – 502. – ISSN 0022-0418.
2. Авдеенко А.М., Мельниченко А.С., Хабибулин Р.Ш. Введение в теорию интеллектуального анализа данных. – М.: Академия ГПС МЧС России, 2018. – 143 с.
3. Keras. Built-in loss functions. [Электронный ресурс] URL: <https://github.com/keras-team/keras/blob/master/keras/losses.py> (дата обращения: 27.06.2025).
4. Tensorflow/python/keras/backend.py. [Электронный ресурс] URL: <https://github.com/tensorflow/tensorflow/blob/r1.12/tensorflow/python/keras/backend.py> (дата обращения: 29.06.2025).
5. Волков Н.А., Иванов А.В. Подход к оценке защищенности речевой акустической информации с применением нейронных сетей // Вестник СибГУТИ. 2024. Т. 18, № 2. С. 43–56. <https://doi.org/10.55648/1998-6920-2024-18-2-43-56>.
6. Воронина И.Е., Пастревич М.К. Модель классификации вербальной агрессии в неструктурированных текстах // Вестник СибГУТИ. 2025. Т. 19, № 2. С. 81–88. <https://doi.org/10.55648/1998-6920-2025-19-2-81-88>.
7. Перцев И.В., Ситняковская Е.И. Лингвистическое обеспечение информационных систем и процессов // Вестник СибГУТИ. 2024. Т. 18, № 1. С. 70–77. <https://doi.org/10.55648/1998-6920-2024-18-1-70-77>.
8. L. Bourdev and J. Malik. Poselets: Body part detectors trained using 3d human pose annotations. In International Conference on Computer Vision (ICCV), 2009. DOI:10.1109/ICCV.2009.5459303.
9. H. Cai, Q. Wu, T. Corradi, and P. Hall. The crossdepiction problem: Computer vision algorithms for recognising objects in artwork and in photographs. arXiv preprint arXiv:1505.00110,2015.doi.org/10.48550/arXiv.1505.00110.
10. T. Dean, M. Ruzon, M. Segal, J. Shlens, S. Vijayanarasimhan, J. Yagnik, et al. Fast, accurate detection of 100,000 object classes on a single machine. In Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on, pages 1814–1821. IEEE, 2013. DOI:10.1109/CVPR.2013.237.
11. J. Donahue, Y. Jia, O. Vinyals, J. Hoffman, N. Zhang, E. Tzeng, and T. Darrell. Decaf: A deep convolutional activation feature for generic visual recognition. arXiv preprint arXiv:1310.1531, 2013. <https://doi.org/10.48550/arXiv.1310.1531>.
12. J. Dong, Q. Chen, S. Yan, and A. Yuille. Towards unified object detection and semantic segmentation. In Computer Vision–ECCV 2014, pages 299–314. Springer, 2019. DOI:10.1007/978-3-319-10602-1_20.

13. А.М. Авдеенко, А.П. Сатин, Е.В. Гаврилюк. Поддержка принятия управленческих решений на основе нейросетевых классификаторов текстов/«Информатика: проблемы, методы, технологии» (IPMT), Новосибирск 7-10 .2, 2024 г.
14. Приказ МЧС России от 28 декабря 2022 г. № 1333 «Об утверждении Порядка организации деятельности профессиональных аварийно-спасательных формирований МЧС России, выполняющих поисково-спасательные работы».
15. Электронный ресурс <https://chat.deepseek.com/>(дата обращения: 18.07.2025).
16. Электронный ресурс <https://chatgpt.com/>(дата обращения: 18.07.2025).
17. ChatGPT and Other Large Language Models Are Double-edged Swords / Y. Shen [et.al.] // New York University, Center for Data Science, 2023 – P. 5-9.
18. Градюшко, А.А. Чат-бот в Telegram как новый источник информации для журналистов / А. А. Градюшко. – Текст: непосредственный // MEDIAОбразование: медиа 80 как тотальная повседневность: материалы V Международной научной конференции (24 25 ноября 2020 года, Челябинск). / под ред. А.А. Морозовой. – Челябинск: Издательство Челябинского государственного университета, 2020. – С. 305–309.
19. Frank A., Asuncion A. UCLMachineLearn ingRepository. University of California, School of Information and Computer Science. Irvine, 2010. [Электрон. ресурс] Режим доступа: <http://arhive.ics.uci.edu/ml> (дата обращения: 17.07.2025).
20. А.В. Бахтизин, В.В. Кораблев, А.Н. Морозов и др. Искусственный интеллект в нефтегазовой промышленности: проблемы и перспективы // Нефтегазовое дело. 2019. Т. 17. № 1. С. 5-11.
21. Абу-Абед Ф.Н. «Построение нейросетевого классификатора для обнаружения нештатных ситуаций в процессе промышленного бурения нефтяных скважин». ТЕРРИТОРИЯ НЕФТЕГАЗ // Бурение \выпуск № 6 \ июнь - 2012. – Москва, 2012. – С. 16-19.
22. Kosinski M., Stillwell D., Graepel T. Private traits and attributes are predictable from digital records of human behavior // Proceedings of the National Academy of Sciences (PNAS). 2013. Vol. 110, N 15. P. 5802 5805.

References

1. Jones K.S. A statistical interpretation of term specificity and its application in retrieval // Journal of Documentation: journal. – MCB University: MCB University Press, 2004. – Vol. 60, no. 5. – P. 493 – 502. – ISSN 0022-0418.
2. Avdeenko A.M., Melnichenko A.S., Khabibulin R.Sh. Introduction to the Theory of Data Mining. Moscow: Academy of the State Fire Service of the Ministry of Emergency Situations of Russia, 2018. 143 p.
3. Keras. Built-in loss functions. [Electronic resource] URL: <https://github.com/keras-team/keras/blob/master/keras/losses.py> (accessed: 27.06.2025).
4. Tensorflow/python/keras/backend.py. [Electronic resource] URL: <https://github.com/tensorflow/tensorflow/blob/r1.12/tensorflow/python/keras /backend.py> (accessed: 29.06.2025).
5. Volkov N.A., Ivanov A.V. Approach to assessing the security of speech acoustic information using neural networks // Vestnik SibGUTI. Т. 18, № 2. С. 43–56. <https://doi.org/10.55648/1998-6920-2024-18-2-43-56>.
6. Voronina I.E., Pastrevich M.K. Classification Model of Verbal Aggression in Unstructured Texts // Vestnik SibGUTI. 2025. Т. 19, № 2. С. 81–88. <https://doi.org/10.55648/1998-6920-2025-19-2-81-88>.
7. Pertsev I.V., Sitnyakovskaya E.I. Linguistic Support for Information Systems and Processes // Vestnik SibGUTI. 2024. Т. 18, № 1. С. 70–77. <https://doi.org/10.55648/1998-6920-2024-18-1-70-77>.
8. L. Bourdev and J. Malik. Poselets: Body part detectors trained using 3d human pose annotations. In International Conference on Computer Vision (ICCV), 2009. DOI:10.1109/ICCV.2009.5459303.
9. H. Cai, Q. Wu, T. Corradi, and P. Hall. The crossdepiction problem: Computer vision algorithms for recognising objects in artwork and in photographs. arXiv preprint arXiv:1505.00110,2015.doi.org/10.48550/arXiv.1505.00110.

10. T. Dean, M. Ruzon, M. Segal, J. Shlens, S. Vijayanarasimhan, J. Yagnik, et al. Fast, accurate detection of 100,000 object classes on a single machine. In Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on, pages 1814–1821. IEEE, 2013. DOI:10.1109/CVPR.2013.237.
11. J. Donahue, Y. Jia, O. Vinyals, J. Hoffman, N. Zhang, E. Tzeng, and T. Darrell. Decaf: A deep convolutional activation feature for generic visual recognition. arXiv preprint arXiv:1310.1531, 2013. <https://doi.org/10.48550/arXiv.1310.1531>.
12. J. Dong, Q. Chen, S. Yan, and A. Yuille. Towards unified object detection and semantic segmentation. In Computer Vision–ECCV 2014, pages 299–314. Springer, 2019. DOI:10.1007/978-3-319-10602-1_20.
13. A.M. Avdeenko, A.P. Satin, and E.V. Gavriilyuk. Support for Management Decision-Making Based on Neural Network Text Classifiers/«Informatics: Problems, Methods, Technologies (IPMT), Novosibirsk, 7-10 .2, 2024.
14. Order No. 1333 of the Ministry of Emergency Situations of Russia dated December 28, 2022, "On Approval of the Procedure for Organizing the Activities of Professional Emergency Response Units of the Ministry of Emergency Situations of Russia Performing Search and Rescue Operations».
15. Electronic resource <https://chat.deepseek.com/>(accessed: 18.07.2025) .
16. Electronic resource <https://chatgpt.com/>(accessed: 18.07.2025).
17. ChatGPT and Other Large Language Models Are Double-edged Swords / Y. Shen [et.al.] // New York University, Center for Data Science, 2023 – P. 5-9.
18. Gradyushko, A. A. Telegram Chatbot as a New Source of Information for Journalists / A. A. Gradyushko. – Text: direct // MEDIAEducation: Media 80 as a Total Daily Life : Materials of the V International Scientific Conference (November 24-25, 2020, Chelyabinsk). / edited by A. A. Morozova. – Chelyabinsk: Chelyabinsk State University Publishing House, 2020, pp. 305–309.
19. Frank A., Asuncion A. UCLMachineLearningRepository. University of California, School of Information and Computer Science. Irvine, 2010. [Electronic resource] Access mode: <http://arhive.ics.uci.edu/ml> (accessed: 17.07.2025).
20. A.V. Bakhtizin, V.V. Korablev, A.N. Morozov, Et al. Artificial Intelligence in the Oil and Gas Industry: Problems and Prospects // Oil and Gas Business. 2019. Vol. 17. No. 1. Pp. 5-11.
21. Abu-Abed F.N. «Building a Neural Network Classifier for Detecting Unusual Situations During Industrial Drilling of Oil Wells» TERRITORY OF OIL AND GAS // Drilling // Issue No. 6 // June 2012. – Moscow, 2012. – Pp. 16-19.
22. Kosinski M., Stillwell D., Graepel T. Private traits and attributes are predictable from digital records of human behavior // Proceedings of the National Academy of Sciences (PNAS). 2013. Vol. 110, N 15. P. 5802 5805.

Информация об авторах

А.М. Авдеенко – доктор физико-математических технических наук

А.П. Сатин – кандидат технических наук

Information about the author

A.M. Avdeenko – Doctor of Physico-Mathematical Technical Sciences

A.P. Satin – Candidate of Technical 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 редакцию 06.10.2025, одобрена после рецензирования 30.11.2025, принята к публикации 15.12.2025.

The article was submitted 06.10.2025, approved after reviewing 30.11.2025, accepted for publication 15.12.2025.