

Научная статья

УДК 351.78; DOI: 10.61260/1998-8990-2025-1-102-117

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ОБОСНОВАНИЯ ОБЪЕМОВ ИНЖЕНЕРНО-ТЕХНИЧЕСКИХ МЕРОПРИЯТИЙ ДЛЯ МИНИМИЗАЦИИ УЩЕРБА ОТ ПРИРОДНЫХ ЧРЕЗВЫЧАЙНЫХ СИТУАЦИЙ С УЧЕТОМ АНТРОПОГЕННЫХ ФАКТОРОВ

Рыбаков Анатолий Валерьевич.

Академия гражданской защиты МЧС России, Москва, Россия.

✉ **Постернак Евгений Валерьевич.**

Российский государственный социальный университет, Москва, Россия

✉ **kripsy93@yandex.ru**

Аннотация. Рассмотрены вопросы повышения точности прогнозирования ущерба от природных чрезвычайных ситуаций с учетом антропогенных факторов. Показано, что игнорирование данных факторов приводит к недостоверным оценкам ущерба и неэффективному планированию защитных мероприятий. Предложен подход, основанный на интеграции метеорологических и антропогенных показателей в единую модель с использованием нейронной сети. Модель позволяет одновременно прогнозировать ущерб и обосновывать объемы инженерно-технических мероприятий, что способствует более рациональному распределению ресурсов и снижению совокупных потерь от чрезвычайных ситуаций.

Ключевые слова: прогнозирование ущерба, чрезвычайные ситуации, антропогенные факторы, инженерно-технические мероприятия, нейронная сеть, оптимизация ресурсов, метеорологические данные

Для цитирования: Рыбаков А.В., Постернак Е.В. Математическая модель обоснования объемов инженерно-технических мероприятий для минимизации ущерба от природных чрезвычайных ситуаций с учетом антропогенных факторов // Проблемы управления рисками в техносфере. 2025. № 1 (73). С. 102–117. DOI: 10.61260/1998-8990-2025-1-102-117.

Scientific article

MATHEMATICAL MODEL FOR JUSTIFYING THE VOLUMES OF ENGINEERING AND TECHNICAL MEASURES TO MINIMIZE DAMAGE FROM NATURAL EMERGENCIES CONSIDERING ANTHROPOGENIC FACTORS

Rybakov Anatoly V.

Academy of civil protection of EMERCOM of Russia, Moscow, Russia.

✉ **Posternak Evgeniy V.**

Russian state social university, Moscow, Russia

✉ **kripsy93@yandex.ru**

Abstract. The article addresses the issue of improving the accuracy of damage forecasting from natural emergencies while taking anthropogenic factors into account. It is demonstrated that ignoring these factors leads to unreliable damage assessments and inefficient planning of protective measures. An approach is proposed that integrates meteorological and anthropogenic indicators into a unified model using a neural network. The model enables simultaneous damage forecasting and justification of the volumes of engineering and technical measures, contributing to a more rational allocation of resources and a reduction in overall losses from emergencies.

Keywords: damage forecasting, emergencies, anthropogenic factors, engineering and technical measures, neural network, resource optimization, meteorological data

For citation: Rybakov A.V., Posternak E.V. Mathematical model for justifying the volumes of engineering and technical measures to minimize damage from natural emergencies considering anthropogenic factors // Problemy upravleniya riskami v tekhnosfere = Problems of risk management in the technosphere. 2025. № 1 (73). P. 102–117. DOI: 10.61260/1998-8990-2025-1-102-117.

Введение

В последние десятилетия наблюдается рост частоты и интенсивности природных чрезвычайных ситуаций (ЧС), приводящих к значительным человеческим жертвам и экономическим потерям [1, 2]. Актуальность исследований, направленных на прогнозирование ущерба от ЧС и разработку эффективных стратегий управления рисками, обусловлена необходимостью повышения устойчивости территорий и рационального распределения ресурсов.

Традиционные подходы к оценке ущерба от ЧС в основном опираются на метеорологические показатели и статистические методы. Однако такие методы зачастую не учитывают дополнительные факторы, влияющие на последствия катастроф, что может приводить к значительным отклонениям прогнозов от реальных значений. Одним из ключевых ограничений существующих моделей является недостаточное внимание к антропогенным характеристикам территории, таким как плотность населения, социально-демографическая структура, тип застройки и экономическая стоимость инфраструктуры [3]. Вследствие этого имеющиеся прогнозные модели не позволяют в полной мере учитывать комплексные риски, связанные с воздействием ЧС на населенные пункты и их инфраструктуру.

Кроме того, большинство существующих исследований ориентированы исключительно на прогнозирование ущерба, но не затрагивают задачу обоснования оптимальных объемов инженерно-технических мероприятий (ИТМ), необходимых для минимизации совокупного ущерба, включающего как прямой ущерб от ЧС, так и затраты на реализацию ИТМ [4]. Проблема оптимального распределения ресурсов требует разработки методов, способных не только прогнозировать ущерб, но и предлагать экономически обоснованные стратегии реагирования. Однако стандартные методы оптимизации, применяемые в данной области, часто опираются на перебор возможных решений, что делает их вычислительно неэффективными при увеличении размерности задачи [5].

В последние годы широкое распространение получили методы машинного обучения, в частности нейронные сети, которые позволяют моделировать сложные нелинейные зависимости между параметрами ЧС и их последствиями [6–8]. Однако вопрос интеграции прогнозирования ущерба и оптимизации ИТМ остается открытым. Развитие моделей, способных одновременно предсказывать ущерб и определять оптимальные меры снижения его последствий, является важной задачей для повышения эффективности управления рисками.

Таким образом, цель настоящего исследования заключается в разработке интегрированной модели прогнозирования ущерба от ЧС с учетом метеорологических и антропогенных факторов, а также в обосновании оптимальных объемов ИТМ для снижения совокупного ущерба. В предложенной постановке задача сводится к минимизации ущерба с учетом затрат на ИТМ.

Для достижения этой цели в работе выполняются:

- сбор и анализ данных, включая метеорологические и антропогенные показатели;
- математическая постановка задачи прогнозирования ущерба и оптимизации ИТМ;
- описание архитектуры и метода обучения модели машинного обучения;
- демонстрация примера входных данных и результатов работы алгоритма.

В статье описываются методы преобразования и нормализации данных, обеспечивающие интеграцию разнородной информации о метеорологических условиях, антропогенных показателях и последствиях ЧС. Также представлена структура функции потерь, включающая регуляризационные члены, предотвращающие чрезмерный рост объемов ИТМ, и архитектура нейронной сети, используемой для прогнозирования ущерба и оптимизации ресурсов.

Сбор и исследование данных

В рамках исследования была выполнена интеграция данных о ЧС, погодных условиях и антропогенных факторах из разных источников [9]. Основу для статистики по ЧС составили:

- данные МЧС России (данные по ЧС с указанием сил, средств, ущерба, метеорологические данные за периоды) [10];
- социально-экономические данные с ресурсов Статистической базы данных Европейской экономической комиссии ООН [11];
- данные по ЧС с ресурса Центра исследований эпидемиологии катастроф [12]. База данных EM-DAT поддерживается Центром исследований эпидемиологии катастроф, входящим в состав Лувенского университета.

Данные по ЧС за период с 1990 по 2024 г. представлены в табл. 1. Была сформирована таблица по ЧС с колонками:

- уникальный идентификатор, включающий год, порядковый номер, код государства для каждого события катастрофы;
- код Международной организации по стандартизации (ISO), обозначающий страну;
- интенсивность ЧС;
- количество погибших (погибшие и пропавшие без вести);
- количество раненых (число людей с физическими увечьями, травмами или заболеваниями, которым требуется немедленная медицинская помощь в связи со стихийным бедствием);
- количество пострадавших (число людей, которым требуется немедленная помощь в связи со стихийным бедствием);
- количество людей, потерявших жилье (число людей, которым требуется убежище из-за того, что их дома были разрушены или серьезно повреждены во время стихийного бедствия);
- общий ущерб (тыс. долл. США) с поправкой на инфляцию с использованием индекса потребительских цен;
- дата ЧС.

Таблица 1

Статистика показателей ЧС

Код события	Буквенный код государства	Сила ЧС (км/ч)	Погибло (чел.)	Ранено (чел.)	Пострадало (чел.)	Потеряли жилье (чел.)	Ущерб (тыс. дол.)	Дата ЧС
1999-0392-CHN	CHN	144	30	500	115 000	7 500	441 939	09.10.1999
1999-0401-IND	IND	200	84	1 000	500 000	700 000	859 732	18.10.1999
2002-0700-USA	USA	200	36	115	3 600	351	1 185 775	05.11.2002
2003-0290-PHL	PHL	140	13	3	46 472	80 655	4 066	15.06.2003
2004-0004-NIU	NIU	300	1	2	200	500	64 527	06.01.2004
2004-0103-MDG	MDG	300	363	879	773 000	214 260	403 294	07.03.2004
2004-0412-CHN	CHN	165	188	4 000	8 590 000	468 000	3 532 851	06.08.2004

Табл. 2 содержит выборку данных с антропогенными показателями с 1990 по 2022 г. В сформированной таблице содержатся колонки:

- год;
- целочисленный код ISO;

- плотность населения;
- численность населения;
- численность детского населения;
- численность пожилого населения;
- процент безработного населения.

Таблица 2

Статистика по антропогенным показателям

Год	Код государства	Плотность (чел. на км ²)	Численность	Дети	Пожилые	Безработные (процент населения)
1990	40	92	7 729 236	1 347 038	1 154 887	3,2
1991	40	92	7 733 751	1 346 858	1 156 699	3,2
1992	40	92	7 733 751	1 346 858	1 156 699	3,2
1993	40	92	7 733 751	1 346 858	1 156 699	3,2
1994	40	92	7 733 751	1 346 858	1 156 699	3,2
1995	40	96	8 046 535	1 411 647	1 218 343	4,2
1996	40	96	8 046 897	1 410 862	1 218 788	4,2

На основе данных от МЧС России были взяты сведения по силам и средствам, которые были привлечены для устранения ЧС, и данные по антропогенным показателям. Объединение происходило на основе года возникновения и географического положения ЧС. Сформирована табл. 3 для анализа корреляции между силами, средствами в рамках устранения ЧС и антропогенными показателями с колонками:

- количество привлеченных сил (люди);
- количество привлеченных средств (техника);
- численность населения;
- численность детского населения;
- численность пожилого населения;
- численность социально незащищенных слоев населения;
- численность людей с ограниченными возможностями.

Таблица 3

Статистика ЧС по силам, средствам, антропогенным показателям

Силы	Средства	Численность	Дети	Пожилые	Безработные	Инвалиды
90	50	92	4 708 150	3 288 625	3 145 112	1 311 057
58	10	92	4 708 150	3 288 625	3 145 112	1 311 057
48	6	92	4 316 859	3 240 911	3 146 287	1 296 159

В табл. 4 представлен фрагмент данных о метеорологических показателях в г. Норильске, полученных на основе информации МЧС России. Таблица включает основные параметры:

- время измерения;
- дата измерения;
- направление ветра (градусы);
- средняя скорость ветра (м/с);
- порывы ветра (м/с);
- видимость (км);
- явления (текст);
- температура воздуха (градус Цельсия);
- температура точки росы (градус Цельсия);

- относительная влажность воздуха (%);
- эффективная температура (градус Цельсия);
- эффективная температура на солнце (градус Цельсия);
- атмосферное давление – приведенное к уровню моря атмосферное давление (гПа);
- атмосферное давление – измеренное на уровне метеостанции атмосферное давление (гПа);
- минимальная температура – минимум температуры воздуха на высоте 2 м над землей (градус Цельсия);
- максимальная температура – максимум температуры воздуха на высоте 2 м над землей (градус Цельсия);
- количество выпавших осадков за период времени (мм);
- количество выпавших осадков за 24 ч (мм);
- высота снежного покрова (см).

Таблица 4

Метеорологические данные

Часы	Дата	Направление ветра	Средняя скорость ветра, м/с	Порывы ветра, м/с	Видимость, км	Явления	Температура воздуха, °С	Температура точки росы, °С	Относительная влажность воздуха, %
0:00:00	01.01.2011	90	8	12	10	позёмок {метель}	-22,9	-26,9	70
3:00:00	01.01.2011	90	6	12	20	позёмок {метель}	-22,4	-25,6	75
9:00:00	01.01.2011	90	8	14	20	позёмок {метель}	-23,7	-27	74
12:00:00	01.01.2011	90	7	12	20	позёмок {метель}	-24,4	-27,6	75
15:00:00	01.01.2011	90	6	–	20	позёмок {метель}	-24,1	-28,1	69
18:00:00	01.01.2011	90	6	–	20	позёмок {метель}	-23,5	-27,5	70
21:00:00	01.01.2011	90	6	–	0,2	позёмок {метель}	-22,5	-26,5	70
0:00:00	02.01.2011	90	5	–	20	{метель}	-23,5	-27,5	70
3:00:00	02.01.2011	90	8	12	20	позёмок {метель}	-21,9	-26,8	64
6:00:00	02.01.2011	90	8	12	50	позёмок {метель}	-22,5	-27,3	65
12:00:00	02.01.2011	90	7	12	20	позёмок {метель}	-22	-26,9	64

Далее была проведена предобработка данных для анализа корреляции между показателями ЧС: ущерб, привлеченные силы, средства и антропогенные показатели. Над данными были совершены следующие операции:

- удаление (или заполнение) пропущенных значений. Некоторые записи содержали пропущенные ячейки по ущербу, населению или другим признакам. Были удалены события с критически неполной информацией либо выполнено восстановление значений там, где это возможно;

- проверка корректности и типов данных. Все числовые показатели (ущерб, численность) приведены к float- или integer-типам;

– объединение данных. Каждая запись о ЧС сопоставлялась с соответствующими антропогенными показателями по ключам «код» и «год», чтобы совместить в единой выборке сведения о событии, ущербе, числе погибших/пострадавших и демографической обстановке.

В результате получен консолидированный набор данных для последующего анализа. Для оценки связей между показателями был построен ряд тепловых карт на рис. 1, демонстрирующих коэффициенты корреляции Пирсона между переменными [13].

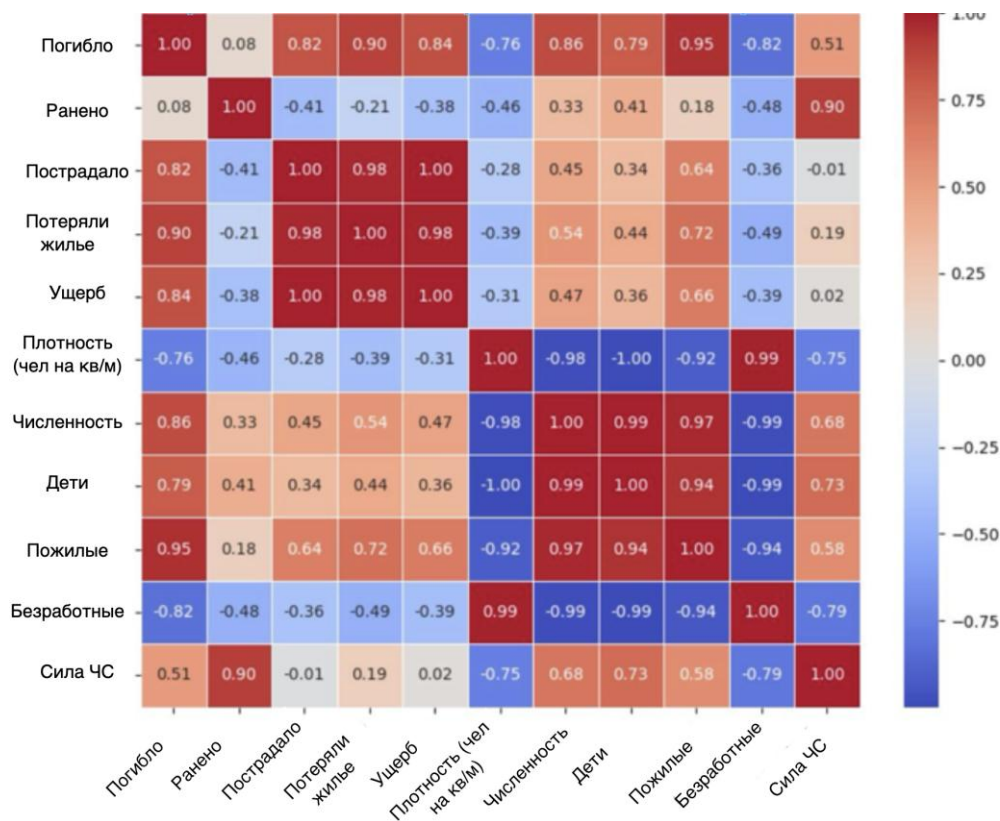


Рис. 1. Тепловая карта корреляции по антропогенным показателям

На тепловой карте можно заметить следующие факты:

– плотность населения имеет отрицательную корреляцию с числом погибших (-0,76) и раненых (-0,46). Это свидетельствует о том, что в регионах с более высокой плотностью населения человеческие потери могут быть ниже. Возможно, это связано с развитой инфраструктурой и лучшим доступом к спасательным ресурсам;

– плотность населения слабо коррелирует с ущербом (0,31), это указывает на то, что материальные потери меньше в густонаселенных регионах;

– численность населения сильно коррелирует с числом погибших (0,86), раненых (0,33), ущербом (0,47). Это подтверждает, что в регионах с большей численностью населения последствия ЧС сильнее выражены;

– доля детей сильно коррелирует с числом погибших (0,79), что указывает на повышенную уязвимость детей в ЧС или на недостаточную защиту. Слабая, но положительная корреляция с ущербом (0,36) подтверждает, что в регионах с большим числом детей последствия ЧС могут быть серьезнее;

– показатель численности пожилого населения сильно коррелирует с числом погибших (0,95) и ущербом (0,66). Это указывает на высокую уязвимость пожилых людей из-за их физического состояния и меньшей мобильности. Численность пожилого населения сильно коррелирует с числом людей, которые потеряли жилье в результате ЧС (0,72).

Выявленные зависимости подтверждают, что для повышения точности прогнозов ущерба и эффективности инженерно-технических мероприятий необходимо учитывать демографические и социально-экономические характеристики территории.

Подобный анализ помогает:

- интерпретировать, какие признаки могут оказывать существенное влияние на ущерб;
- выявить мультиколлинеарность, когда два или более фактора избыточно дублируют друг друга (например, численность населения и дети тесно связаны);
- обосновать выбор ключевых признаков для последующего моделирования. Если некоторые показатели слабо или отрицательно коррелируют с последствиями ЧС, их можно либо исключить, либо рассматривать совместно с другими признаками.

Следующая тепловая карта на рис. 2 демонстрирует корреляцию между антропогенными показателями и привлекаемыми силами, средствами в рамках устранения ЧС.

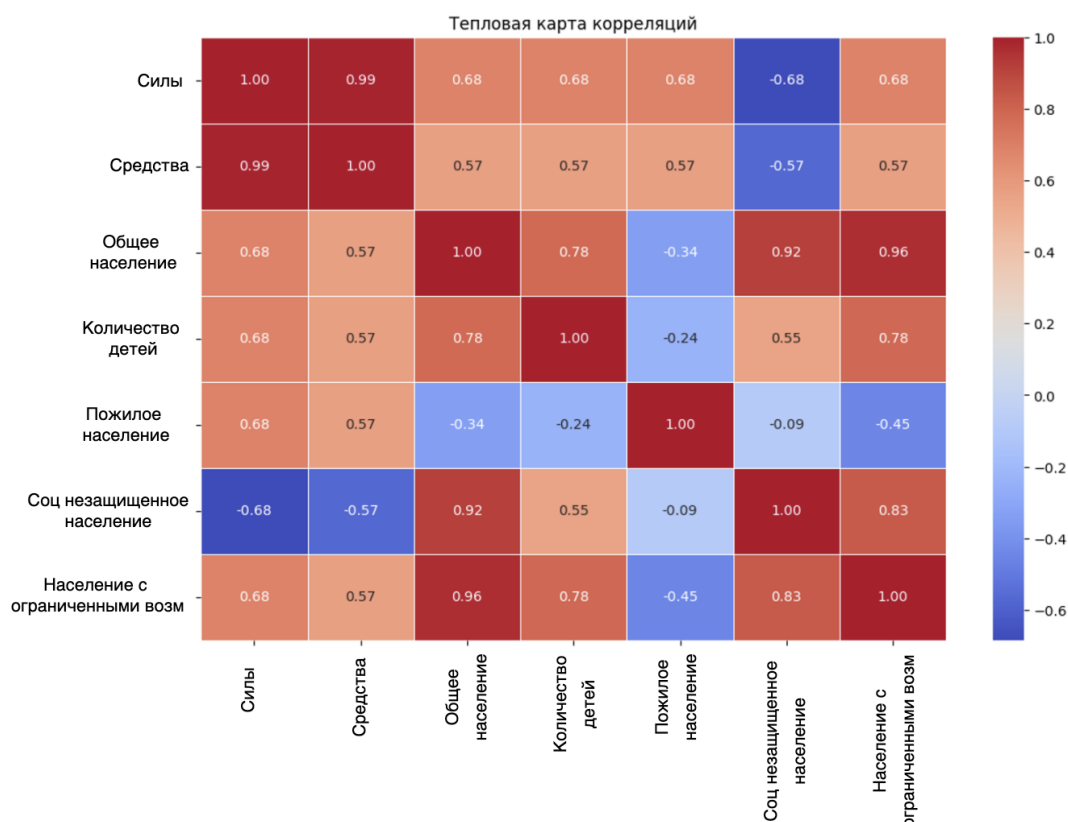


Рис. 2. Тепловая карта корреляции сил, средств и антропогенных показателей

На тепловой карте можно заметить, что:

- присутствует сильная корреляция (0,68) между антропогенными показателями (общее население, количество детей и другие) и привлекаемыми силами. Это указывает на необходимость учета структуры населения при планировании ресурсов для ликвидации ЧС;
- корреляция между антропогенными показателями и привлекаемыми средствами немного слабее (0,57), но остается высокой, что подтверждает взаимосвязь между характеристиками населения и используемыми средствами.

Имеющиеся данные не покрывают весь спектр необходимых параметров (например, точную информацию об объемах и стоимости ИТМ), однако уже демонстрируют наличие значимых связей между ущербом, силами, средствами и демографическими, социально-экономическими факторами. Эти результаты подтверждают целесообразность включения антропогенных переменных при построении модели прогнозирования ущерба и выработке оптимального объема ИТМ.

Постановка математической задачи

Определим целевую функцию и сформулируем задачу оптимизации. Пусть $Z_{predicted}(M, A, t, R)$ – прогнозируемый ущерб, зависящий от метеорологических факторов M , антропогенных факторов A , а также от выбранных объемов ИТМ R в момент времени t . Если $C(R)$ обозначает стоимость реализации объема ИТМ, тогда совокупный ущерб можно представить в виде формулы:

$$Z_{total}(M, A, t, R) = Z_{predicted}(M, A, t, R) + C(R, t), \quad (1)$$

где $Z_{predicted}(M, A, t, R)$ – прогнозируемый в момент времени t ущерб от ЧС, зависящий от метеорологических факторов M , антропогенных факторов A , а также от выбранных объемов ИТМ R ; $C(R, t)$ – функция стоимости реализации ИТМ в момент времени t .

Задача оптимизации формулируется как:

$$Z_{total}(M, A, t, R) \rightarrow \min_R \text{ при } R_i \geq 0, \forall i,$$

то есть необходимо подобрать такие объемы ИТМ, которые минимизируют суммарный ущерб в заданный момент времени t .

Данная задача требует одновременного решения двух взаимосвязанных подзадач: прогнозирование ущерба, оптимизация объемов ИТМ.

Для прогнозирования ущерба $Z_{predicted}(M, A, t, R)$ при заданных условиях M, A, t и управляемой переменной R целесообразно использовать алгоритм машинного обучения, обученный на исторических данных, например, нейронную сеть. Нейронная сеть, получая на вход набор признаков, отражающих метеорологические факторы M , антропогенные факторы A и временной аспект t , может аппроксимировать функцию $Z_{predicted}$, тем самым предоставляя оценку ожидаемого ущерба для данных условий и заданного объема ИТМ R .

Однако полный перебор возможных вариантов объемов ИТМ R с целью минимизации $Z_{total}(M, A, t, R)$ может быть чрезвычайно ресурсоемким [14]. Если для каждого из n ИТМ стоит бинарный выбор – применять или не применять его, то сложность данной задачи сводится к $O(2^n)$. Однако в реальности объемы каждого мероприятия из набора ИТМ могут принимать не просто два, а множество значений, или даже являться непрерывными переменными. Это означает, что сложность перебора потенциальных конфигураций возрастает.

Если рассматривается n потенциальных мероприятий, каждое из которых может быть реализовано в различных дискретных уровнях k , то поиск оптимального объема ИТМ $R_{optimal}$ сводится к перебору k^n числа конфигураций. Для непрерывных параметров задача усложняется. Такой перебор быстро становится вычислительно неэффективным.

Для решения этой проблемы используются оптимизационные методы, интегрированные в процесс обучения алгоритма машинного обучения [15]. Подход заключается в следующем:

– совместное обучение прогнозированию ущерба и определению оптимальных объемов ИТМ. Нейронная сеть расширяется так, чтобы на ее выходе, помимо прогноза ущерба, формировался вектор оптимальных объемов мероприятий $R_{optimal}$. В этом случае процесс оптимизации происходит не путем внешнего перебора, а через настройку параметров сети в процессе обучения, направленном на минимизацию целевой функции Z_{total} ;

– регуляризация членов в функции обучения. Чтобы избежать чрезмерного роста объемов ИТМ, в функцию потерь включаются регуляризационные члены (штрафы за большие объемы каждого из мероприятий) [16]. Это позволяет контролировать поведение сети без привлечения дополнительных внешних эвристических алгоритмов.

Архитектура предлагаемого алгоритма машинного обучения

В данной работе используется обучение с учителем. На этапе подготовки обучающей выборки были размечены исторические данные, в которых зафиксированы фактические значения ущерба Z_{actual} и фактические объемы ИТМ R_{actual} , а также условия, сопровождавшие каждую ЧС (метеорологические факторы M , антропогенные факторы A , временные характеристики t и т. д.).

Учитывая большую размерность и нелинейность исходных данных, была выбрана глубокая нейронная сеть. Многослойная архитектура дает возможность последовательно извлекать более сложные паттерны на каждом уровне, что улучшает качество прогнозов по сравнению с традиционными или неглубокими моделями. Для борьбы с переобучением используются современные методы регуляризации, что обеспечивает устойчивые результаты даже при большом числе скрытых слоев.

В предлагаемом решении используется многослойная однонаправленная нейронная сеть, состоящая из P скрытых слоев. Каждый скрытый слой представляет собой полносвязный Dense слой с функцией активации ReLU, что позволяет эффективно моделировать нелинейные зависимости. На данный момент прототип нейронной модели содержит четыре скрытых слоя, но более детальная конфигурация (число нейронов в каждом слое и параметры регуляризации) может изменяться для оптимизации точности и скорости обучения в зависимости от качества обучающей выборки, поэтому на архитектуре указано P скрытых слоев.

В рамках предлагаемой архитектуры нейросети используется алгоритм обратного распространения ошибки, поскольку он является стандартным и наиболее распространенным методом оптимизации параметров многослойных нейронных сетей. Он позволяет эффективно вычислять градиент функции потерь по отношению к каждому параметру сети, независимо от глубины. Благодаря этому, сеть может обучаться с учетом всех нелинейных преобразований, содержащихся в скрытых слоях, а современные варианты градиентных методов (например ADAM) обеспечивают быструю и устойчивую сходимость. Альтернативные методы оказались менее эффективны в данном случае.

Для решения поставленной задачи определим состав входных и выходных данных. Входные данные представлены на рис. 3.

Техническое поле	Метеорологические показатели	Антропогенные показатели	Экономические показатели	Данные по ЧС (обучение)
идентификатор точки измерений (141312)	время измерения (18:00)	численность населения (8391642)	средняя стоимость применения сил (1300)	интенсивность ЧС (144)
	дата измерения (1998-04-03)	плотность населения (105)	средняя стоимость средств (2100)	количество погибших (30)
	направление ветра (90)	численность детского населения (1229270)		количество раненых (22)
	средняя скорость ветра (6)	численность пожилого населения (1486978)		количество пострадавших (121)
	порывы ветра (12.1)	численность социально незащищенных слоев населения (327274)		количество людей, потерявших жилье (1422)
	...	численность людей с ограниченными возможностями (360001)		общий ущерб (859732)
	высота снежного покрова (24.0)			силы (22)
				средства (17)
				стоимость применения средств (11313)
				стоимость применения сил (8000)

Рис. 3. Пример входных необработанных данных для работы с моделью

Данные по ЧС указываются лишь в процессе обучения модели. Перед подачей входных данных в модель машинного обучения необходимо выполнить их предобработку и нормализацию, что обусловлено необходимостью устранения влияния масштабных различий между параметрами и улучшения стабильности численных вычислений в процессе обучения.

Предобработка включает удаление пропущенных значений, проверку типов данных, устранение выбросов и трансформацию категориальных признаков в числовую форму с использованием методов, таких как one-hot encoding или label encoding.

Для нормализации данных применяются различные алгоритмы, включая стандартное масштабирование, которое приводит данные к нулевому среднему и единичному стандартному отклонению, и минимаксное масштабирование, позволяющее привести значения в диапазон от 0 до 1.

Эти методы обеспечивают равномерный вклад различных признаков в процесс обучения модели. Кроме того, для повышения устойчивости алгоритма к шуму может быть выполнена регуляризация, включающая отбор ключевых признаков на основе их статистической значимости. Применение таких методов позволяет эффективно подготовить данные, улучшить качество прогнозов и обеспечить стабильность работы модели машинного обучения.

В рамках решения задачи прогнозирования ущерба и определения оптимального объема ИТМ получаем набор данных, который представлен на рис. 4.

Данные по ЧС	
интенсивность ЧС (144)	
количество погибших (0)	
количество раненых (0)	
* количество пострадавших (2) *	
количество людей, потерявших жилье (4)	
общий ущерб (32132)	
силы (122)	
средства (23)	
стоимость применения средств (700)	
стоимость применения сил (1300)	

Рис. 4. Пример выходных данных с показателями ЧС, включая силы и средства

На рис. 5 приводится описание архитектуры нейронной сети и ее схематичное представление на период обучения. Нейронная сеть состоит из нескольких функциональных блоков:

- блок получения входных данных. Получаемые данные этим блоком преобразуются в определенную структуру;
- блок нормализации и векторизации. Обработанные входные данные нормализуются и преобразуются в вектор;
- блоки скрытых слоев. Скрытые слои осуществляют нелинейные преобразования, извлекая признаки и формируя комплексные зависимости;
- блоки выходных слоев. Выходные слои разделены на две ветви: одна для прогноза ущерба $Z_{predicted}$, другая – для оптимальных объемов ИТМ $R_{optimal}$;

– блок обучения, учитывающий ошибку прогноза ущерба и регуляризационные члены для R . Модель обучается методом обратного распространения ошибки. Данный блок участвует лишь в процессе обучения модели.

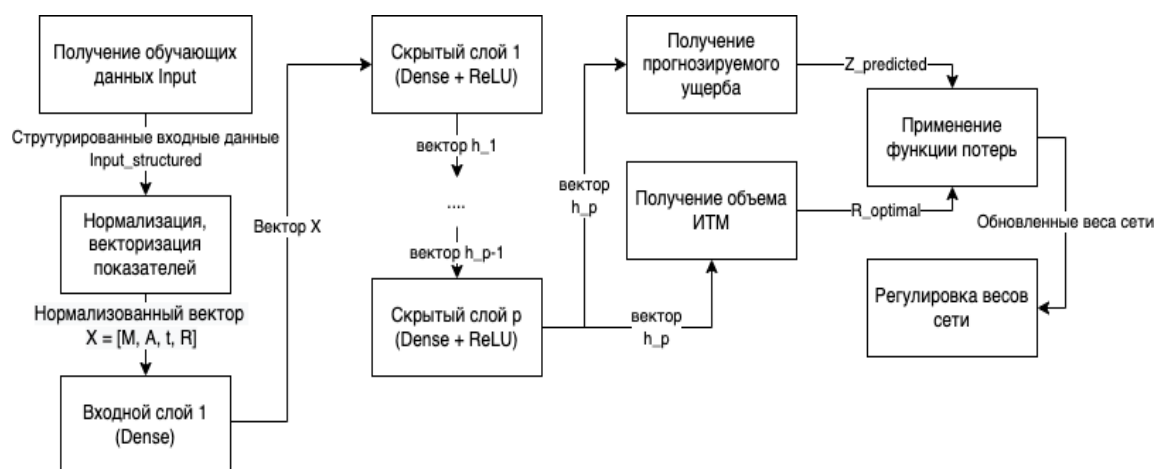


Рис. 5. Архитектура нейронной сети в процессе обучения

В рамках прогнозирования архитектура нейронной сети представлена на рис. 6. В данном процессе появляется блок визуализации прогнозируемого ущерба и оптимального объема ИТМ. Этот блок является результатом работы нейронной сети при прогнозировании.

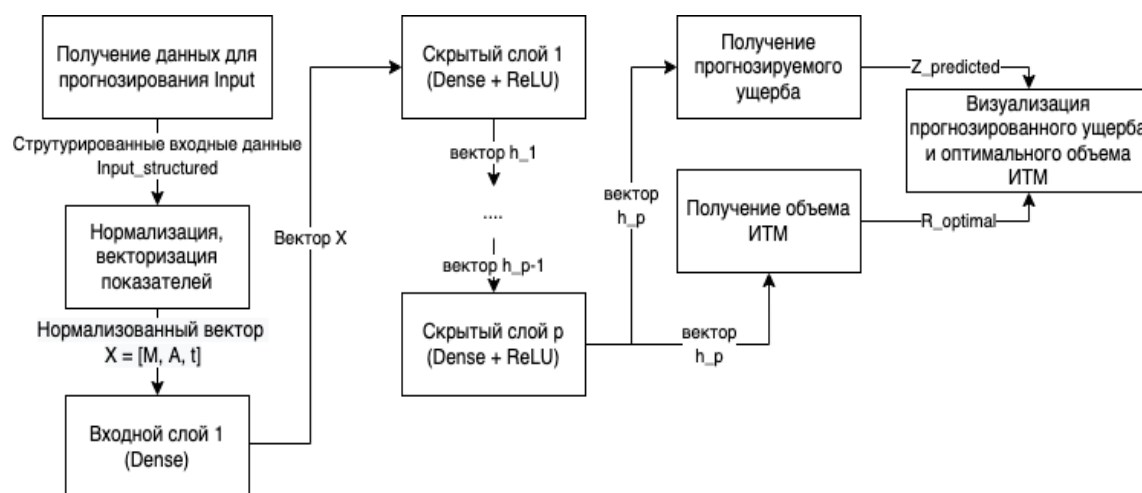


Рис. 6. Архитектура нейронной сети в процессе прогнозирования

Стоит отметить следующее:

- Dense – это тип слоя в нейронной сети, в котором каждый нейрон данного слоя соединен со всеми нейронами предыдущего слоя. В таком слое вычисляется линейная комбинация входных данных с параметрами (весами и смещениями);
- ReLU (Rectified Linear Unit) – это функция активации, используемая после Dense-слоя;
- в архитектуре нейронной сети имеется P скрытых слоев.

Как указывалось в формуле (1), совокупный ущерб $Z_{total}(M, A, t, R)$ складывается из прогнозируемого ущерба $Z_{predicted}(M, A, t, R)$ и стоимости реализации ИТМ $C(R, t)$. При этом в предлагаемой архитектуре нейросеть имеет два главных выхода:

- $Z_{predicted}$ – оценка ожидаемого ущерба при данных условиях M, A и наборе объемов ИТМ R в момент времени t ;

– R – объем ИТМ, который используется для снижения ущерба.

В рамках решения данной задачи считается, что в исторических данных уже зафиксированы оптимальные (или близкие к оптимальным) объемы ИТМ и соответствующий ущерб. Таким образом, обучение сети сводится к тому, чтобы:

– приблизить прогноз $Z_{predicted}$ к фактическому ущербу Z_{actual} ;

– научиться воссоздавать оптимальные объемы ИТМ, чтобы итоговые затраты $C(R, t)$ не были чрезмерными.

Для этого в процессе обучения используется функция вычисления потерь в блоке «Применение функции потерь» нейронной сети, которая представлена формулой (2):

$$L(Z_{predicted}, Z_{actual}, R, t) = \alpha * (Z_{predicted} - Z_{actual}) + \beta * C(R, t) + \lambda * \sum_i R_i^2, \quad (2)$$

где t – время; α – коэффициент, влияющий на точность прогнозов (определяет, насколько важна точность прогноза ущерба по сравнению с другими частями функции потерь); $Z_{predicted}$ – предсказанное значение ущерба; Z_{actual} – фактическое значение ущерба; β – коэффициент, отражающий значимость стоимости ИТМ (поощряет модель не только снижать прогнозируемый ущерб, но и делать это экономически оправдано); $C(R, t)$ – функция стоимости реализованных ИТМ, зависящая от объема R в момент времени t ; λ – регуляризационный член, контролирует абсолютную величину объемов ИТМ (если модель попытается уменьшить ущерб, резко увеличивая объемы ИТМ, она столкнется с увеличением этого штрафа); $\sum_i R_i^2$ – суммы квадратов объемов ИТМ.

Поскольку $C(R, t)$ определяется, в том числе, из исторических данных по затратам на объемы ИТМ, модель при обучении будет «учиться» находить такие R , которые одновременно минимизируют суммарный ущерб и не приводят к неограниченным расходам.

В практическом плане процедура обучения выглядит так:

– получение обучающего примера – берутся исторические записи, где известны M, A, t , фактический ущерб Z_{actual} и фактический объем ИТМ R_{actual} ;

– прогон через сеть: на вход подаются M, A, t . Сеть генерирует прогноз $Z_{predicted}$ и рекомендуемые $R_{optimal}$;

– вычисление $C(R, t)$ – исходя из $R_{optimal}$, определяется стоимость $C(R, t)$ по имеющимся историческим данным о затратах;

– вычисление ошибки – учитывается точность ущерба $\alpha * (Z_{predicted} - Z_{actual})$, штраф за высокую стоимость $\beta * C(R, t)$ и регуляризационное слагаемое $\lambda * \sum_i R_i^2$;

– обратное распространение ошибки – по методу градиентного спуска ADAM вычисляются $\frac{dL}{dw}$ для всех обучаемых параметров сети (включая те, что формируют R), и сеть обновляет веса, стремясь минимизировать L .

Так как в исторических данных R_{actual} принято за «оптимальное» (или близкое к оптимальному) решение, сеть при обучении фактически стремится воспроизводить эти «оптимальные» стратегии применения ИТМ. В итоге, когда на вход подаются новые M, A, t , сеть способна одновременно:

– предсказывать ущерб $Z_{predicted}$;

– выдавать набор R , минимизирующий Z_{total} , принимая во внимание стоимость $C(R, t)$.

Такой совместный подход избавляет от необходимости полного перебора вариантов ИТМ и дает «оптимальные» по данным модели решения напрямую на выходе нейросети.

Заключение

В данной работе была представлена математическая постановка задачи прогнозирования ущерба от природных ЧС с учетом метеорологических и антропогенных факторов, а также задача оптимизации объемов ИТМ. В ходе исследования проведен анализ доступных данных по ЧС, выполнена их очистка и предобработка, построены корреляционные зависимости между ущербом, силами и средствами, привлеченными для ликвидации последствий, и социально-экономическими характеристиками территории.

Анализ данных подтвердил наличие значимых связей между метеорологическими параметрами, демографической структурой населения и последствиями ЧС, что обосновывает необходимость их комплексного учета при прогнозировании ущерба.

Для решения поставленной задачи предложена архитектура алгоритма машинного обучения, использующего нейронную сеть, способную не только прогнозировать ущерб от ЧС, но и одновременно подбирать оптимальные объемы ИТМ для минимизации совокупного ущерба (суммы ущерба от ЧС и затрат на ИТМ). Введена целевая функция, включающая регуляризационные члены, позволяющие избежать чрезмерного роста затрат на мероприятия. Обоснована необходимость интеграции оптимизационного подхода в процесс обучения модели.

Разработанная модель позволит повысить точность прогнозирования ущерба, учесть демографические и социально-экономические особенности территорий и предложить оптимальные меры реагирования на ЧС. В дальнейшем исследовании планируется расширение набора данных, сбор детализированной информации, а также тестирование, формирование рекомендаций для работы с моделью.

Список источников

1. Управление рисками экстремальных явлений и бедствий для продвижения адаптации к изменению климата (Межправительственная группа экспертов по изменению климата (МГЭИК)) // Специальный доклад МГЭИК по управлению рисками экстремальных явлений и бедствий для продвижения адаптации к изменению климата. 2012. 594 с. URL: https://www.ipcc.ch/site/assets/uploads/2018/03/IPCC_SREX_RU_web-1.pdf (дата обращения: 11.02.2025).
2. Evaluation of ensemble streamflow predictions in Europe / L. Alfieri [et al.] // *Journal of Hydrology*. 2014. Vol. 517. P. 913–922. DOI: 10.1016/j.jhydrol.2014.06.035.
3. Pappenberger F., Thielen J., Del Medico M. The impact of weather forecast improvements on large scale hydrology: analyzing a decade of forecasts of the European Flood Alert System // *Hydrological Processes*. 2011. Vol. 25. № 7. P. 1091–1113. DOI: 10.1002/hyp.7772.
4. Framing vulnerability, risk and societal responses: the MOVE framework / J. Birkmann [et al.] // *Natural Hazards*. 2013. Vol. 67. № 2. P. 193–211. DOI: 10.1007/s11069-013-0558-5.
5. Anaya-Arenas A.M., Renaud J., Ruiz A. Relief distribution networks: a systematic review // *Annals of Operations Research*. 2014. Vol. 223. № 1. P. 53–79. DOI: 10.1007/s10479-014-1581-y.
6. Rawls C.G., Turnquist M.A. Pre-positioning of emergency supplies for disaster response // *Transportation Research Part B: Methodological*. 2010. Vol. 44. № 4. P. 521–534. DOI: 10.1016/j.trb.2009.08.003.
7. Leveraging machine learning algorithms for improved disaster prediction and management / A. Linardos [et al.] // *Frontiers in Environmental Science*. 2023. Vol. 11. Article 1194918. DOI: 10.3389/fenvs.2023.1194918.
8. Lu L., Guo W. Automatic Quantification of Settlement Damage using Deep Learning of Satellite Images // *arXiv preprint arXiv: 2010.05512*. 2020. URL: <https://arxiv.org/abs/2010.05512> (дата обращения: 28.01.2025).

9. Рыбаков А.В., Постернак Е.В. Актуальность проблемы повышения качества прогнозирования чрезвычайных ситуаций природного характера // Моделирование технически сложных процессов и систем: сб. трудов XXXIII Междунар. науч.-практ. конф. Химки, 2023. С. 40–44.

10. МЧС России. URL: <https://mchs.gov.ru/deyatelnost/itogi-deyatelnosti-mchs-rossii> (дата обращения: 28.01.2025).

11. Европейская экономическая комиссия ООН. Статистическая база данных ЕЭК ООН. URL: <https://w3.unece.org/PXWeb/ru/> (дата обращения: 28.01.2025).

12. Центр исследований эпидемиологии катастроф. Международная база данных о чрезвычайных ситуациях EM-DAT. URL: <https://www.emdat.be/> (дата обращения: 28.01.2025).

13. Новоселов И.Э., Смирнов А.А., Жидков И.С. Изучение влияния параметров перовскитных солнечных батарей на их эффективность при помощи машинного обучения // Международный научно-исследовательский журнал. 2024. № S5 (143). URL: <https://research-journal.org/archive/5-143-2024-may/10.60797/IRJ.2024.143.121> (дата обращения: 28.01.2025). DOI: 10.60797/IRJ.2024.143.121.

14. Расина И.В. Дискретно-непрерывные модели и оптимизация управляемых процессов // Программные системы: теория и приложения. 2011. № 5. URL: <https://cyberleninka.ru/article/n/diskretno-neprieryvnye-modeli-i-optimizatsiya-upravlyaemyh-protssessov> (дата обращения: 28.01.2025).

15. Агарков Ю.Ю. Методы машинного обучения для оптимизации проектирования нейроморфных систем // Инновации и инвестиции. 2023. № 6. URL: <https://cyberleninka.ru/article/n/metody-mashinnogo-obucheniya-dlya-optimizatsii-proektirovaniya-neyromorfnyh-sistem> (дата обращения: 28.01.2025).

16. Торкунова Ю.В., Милованов Д.В. Оптимизация нейронных сетей: методы и их сравнение на примере интеллектуального анализа текста // ИАС. 2023. № 4. URL: <https://cyberleninka.ru/article/n/optimizatsiya-neyronnyh-setey-metody-i-ih-sravnienie-na-primere-intellektualnogo-analiza-teksta> (дата обращения: 28.01.2025).

References

1. Upravlenie riskami ekstremal'nyh yavlenij i bedstvij dlya prodvizheniya adaptacii k izmeneniyu klimata (Mezhpravitel'stvennaya gruppa ekspertov po izmeneniyu klimata (MGEIK) // Special'nyj doklad MGEIK po upravleniyu riskami ekstremal'nyh yavlenij i bedstvij dlya prodvizheniya adaptacii k izmeneniyu klimata. 2012. 594 s. URL: https://www.ipcc.ch/site/assets/uploads/2018/03/IPCC_SREX_RU_web-1.pdf (data obrashcheniya: 11.02.2025).

2. Evaluation of ensemble streamflow predictions in Europe / L. Alfieri [et al.] // Journal of Hydrology. 2014. Vol. 517. P. 913–922. DOI: 10.1016/j.jhydrol.2014.06.035.

3. Pappenberger F., Thielen J., Del Medico M. The impact of weather forecast improvements on large scale hydrology: analyzing a decade of forecasts of the European Flood Alert System // Hydrological Processes. 2011. Vol. 25. № 7. P. 1091–1113. DOI: 10.1002/hyp.7772.

4. Framing vulnerability, risk and societal responses: the MOVE framework / J. Birkmann [et al.] // Natural Hazards. 2013. Vol. 67. № 2. P. 193–211. DOI: 10.1007/s11069-013-0558-5.

5. Anaya-Arenas A.M., Renaud J., Ruiz A. Relief distribution networks: a systematic review // Annals of Operations Research. 2014. Vol. 223. № 1. P. 53–79. DOI: 10.1007/s10479-014-1581-y.

6. Rawls C.G., Turnquist M.A. Pre-positioning of emergency supplies for disaster response // Transportation Research Part B: Methodological. 2010. Vol. 44. № 4. P. 521–534. DOI: 10.1016/j.trb.2009.08.003.

7. Leveraging machine learning algorithms for improved disaster prediction and management / A. Linardos [et al.] // *Frontiers in Environmental Science*. 2023. Vol. 11. Article 1194918. DOI: 10.3389/fenvs.2023.1194918.

8. Lu L., Guo W. Automatic Quantification of Settlement Damage using Deep Learning of Satellite Images // *arXiv preprint arXiv:2010.05512*. 2020. URL: <https://arxiv.org/abs/2010.05512> (data obrashcheniya: 28.01.2025).

9. Rybakov A.V., Posternak E.V. Aktual'nost' problemy povysheniya kachestva prognozirovaniya chrezvychajnyh situacij prirodnogo haraktera // *Modelirovanie tekhnicheskii slozhnyh processov i sistem: sb. trudov HXXIII Mezhdunar. nauch.-prakt. konf. Himki, 2023*. S. 40–44.

10. MCHS Rossii. URL: <https://mchs.gov.ru/deyatelnost/itogi-deyatelnosti-mchs-rossii> (data obrashcheniya: 28.01.2025).

11. Evropejskaya ekonomicheskaya komissiya OON. Statisticheskaya baza dannyh EEK OON. URL: <https://w3.unece.org/PXWeb/ru/> (data obrashcheniya: 28.01.2025).

12. Centr issledovaniy epidemiologii katastrof. Mezhdunarodnaya baza dannyh o chrezvychajnyh situacijah EM-DAT. URL: <https://www.emdat.be/> (data obrashcheniya: 28.01.2025).

13. Novoselov I.E., Smirnov A.A., Zhidkov I.S. Izuchenie vliyaniya parametrov perovskitnyh solnechnykh batarej na ih effektivnost' pri pomoshchi mashinnogo obucheniya // *Mezhdunarodnyj nauchno-issledovatel'skij zhurnal*. 2024. № S5 (143). URL: <https://research-journal.org/archive/5-143-2024-may/10.60797/IRJ.2024.143.121> (data obrashcheniya: 28.01.2025). DOI: 10.60797/IRJ.2024.143.121.

14. Rasina I.V. Diskretno-neprieryvnye modeli i optimizatsiya upravlyaemyh processov // *Programmnye sistemy: teoriya i prilozheniya*. 2011. № 5. URL: <https://cyberleninka.ru/article/n/diskretno-neprieryvnye-modeli-i-optimizatsiya-upravlyaemyh-protsessov> (data obrashcheniya: 28.01.2025).

15. Agarkov Yu.Yu. Metody mashinnogo obucheniya dlya optimizatsii proektirovaniya nejromorfnyh sistem // *Innovatsii i investitsii*. 2023. № 6. URL: <https://cyberleninka.ru/article/n/metody-mashinnogo-obucheniya-dlya-optimizatsii-proektirovaniya-nejromorfnyh-sistem> (data obrashcheniya: 28.01.2025).

16. Torkunova Yu.V., Milovanov D.V. Optimizatsiya nejronnyh setej: metody i ih sravnenie na primere intellektual'nogo analiza teksta // *IJAS*. 2023. № 4. URL: <https://cyberleninka.ru/article/n/optimizatsiya-nejronnyh-setey-metody-i-ih-sravnenie-na-primere-intellektualnogo-analiza-teksta> (data obrashcheniya: 28.01.2025).

Информация о статье:

Статья поступила в редакцию: 12.02.2025; одобрена после рецензирования: 24.02.2025;
принята к публикации: 05.03.2025

The information about article:

The article was submitted to the editorial office: 12.02.2025; approved after review: 24.02.2025;
accepted for publication: 05.03.2025

Информация об авторах

Рыбаков Анатолий Валерьевич, профессор кафедры высшей математики Академии гражданской защиты МЧС России (141435, Московская обл., г. Химки, мкр. Новогорск, ул. Соколовская, стр. 1А), доктор технических наук, профессор, e-mail: a.rybakov@agz.50.mchs.gov.ru, <https://orcid.org/000-0002-4037-1231>, SPIN-код: 8654-3788

Постернак Евгений Валерьевич, аспирант факультета экологии и природоохранной деятельности Российского государственного социального университета (129226, Москва, ул. Вильгельма Пика, д. 4, стр. 1), e-mail: kripsy93@yandex.ru, <https://orcid.org/0009-0003-9732-4449>

Information about the authors:

Rybakov Anatoly V., professor of the department of higher mathematics at the academy of civil protection of EMERCOM of Russia (141435, Moscow region, Khimki, md. Novogorsk, Sokolovskaya str., 1A), doctor of technical sciences, professor, e-mail: a.rybakov@agz.50.mchs.gov.ru, <https://orcid.org/000-0002-4037-1231>, SPIN: 8654-3788

Posternak Evgeny V., postgraduate student at the faculty of ecology and environmental protection of the Russian state social university (129226, Moscow, Wilhelma Peak str., 4, building 1), e-mail: kripsy93@yandex.ru, <https://orcid.org/0009-0003-9732-4449>