

Научная статья

УДК 004.032.26:614.849; DOI: 10.61260/2218-13X-2023-4-185-198

МОДЕЛЬ ПРОГНОЗИРОВАНИЯ ЛЕСНЫХ ПОЖАРОВ НА ОСНОВЕ НЕЙРО-НЕЧЕТКОЙ СИСТЕМЫ ANFIS

✉ **Медведев Дмитрий Валерьевич.**

Санкт-Петербургский университет ГПС МЧС России, Санкт-Петербург, Россия

✉ meedvedevdv@mail.ru

Аннотация. Рассмотрены существующие инновационные подходы как отечественных, так и зарубежных ученых к интеллектуальному прогнозированию, а также управлению лесными пожарами. Представлена реализация применения нейро-нечеткой системы ANFIS для прогнозирования лесных пожаров с целью повышения надежности и достоверности получаемых прогнозных данных. Проведен анализ признакового пространства при рассмотрении лесных пожаров, представлена корреляционная матрица, характеризующая степень влияния признаков на прогнозируемые показатели. Построена структура нейро-сетевой модели с соответствующими лингвистическими переменными и функциями принадлежности. Представлены результаты обучения системы ANFIS на основе исторических данных на территории Ленинградской области за период с 2015 по 2023 г. Полученные результаты позволяют повысить эффективность оперативного прогнозирования динамики развития лесных пожаров, обосновывать принятие управленческих решений по их ликвидации.

Ключевые слова: лесные пожары, прогнозирование, ANFIS, нейро-нечеткая система, управление

Для цитирования: Медведев Д.В. Модель прогнозирования лесных пожаров на основе нейро-нечеткой системы ANFIS // Науч.-аналит. журн. «Вестник С.-Петерб. ун-та ГПС МЧС России». 2023. № 4. С. 185–198. DOI: 10.61260/2218-13X-2023-4-185-198.

Scientific article

IMPLEMENTATION OF THE ANFIS NEURO-FUZZY SYSTEM FOR FOREST FIRE MANAGEMENT

✉ **Medvedev Dmitry V.**

Saint-Petersburg university of State fire service of EMERCOM of Russia, Saint-Petersburg, Russia

✉ meedvedevdv@mail.ru

Abstract. The existing innovative approaches of both domestic and foreign scientists to intelligent forecasting, as well as forest fire management, are considered. The implementation of the application of the ANFIS neuro-fuzzy system for predicting forest fires in order to increase the reliability and reliability of the forecast data obtained is presented. The analysis of the feature space when considering forest fires is carried out, a correlation matrix is presented that characterizes the degree of influence of features on the predicted indicators. The structure of the neural network model with the corresponding linguistic variables and membership functions is constructed. The results of the ANFIS system training based on historical data in the Leningrad Region for the period from 2015 to 2023 are presented. The results obtained make it possible to increase the efficiency of operational forecasting of the dynamics of forest fires, to justify the adoption of management decisions on their elimination.

Keywords: forest fires, forecasting, ANFIS, neuro-fuzzy system, management

For citation: Medvedev D.V. Forest fire forecasting model based on the ANFIS neuro-fuzzy system // Scientific and analytical journal «Vestnik Saint-Petersburg university of State fire service of EMERCOM of Russia». 2023. № 4. P. 185–198. DOI: 10.61260/2218-13X-2023-4-185-198.

Введение

Природные пожары – явления, имеющие сложно прогнозируемую сущность, по причине влияния огромного количества разносторонних факторов. Лесные пожары могут сопровождаться значительными по масштабу последствиями, связанными с опасностью для жизни и здоровья населения, нарушением экологического состояния окружающей среды, социальным и материальным ущербом. Согласно информационно-аналитическому сборнику ФГБУ ВНИИПО МЧС России «Пожары и пожарная безопасность в 2022 г. Статистика пожаров и их последствий», число лесных пожаров на территории Российской Федерации за 2022 г. составило 12 528. На рис. 1 представлена протяженность границ с лесом на объектах защиты, граничащих с лесными участками в субъектах Российской Федерации. Большая часть Российской Федерации имеет объекты, для которых протяженность границ с лесом более 150 км, что может включать в себя потенциальную пожарную опасность для этих объектов.

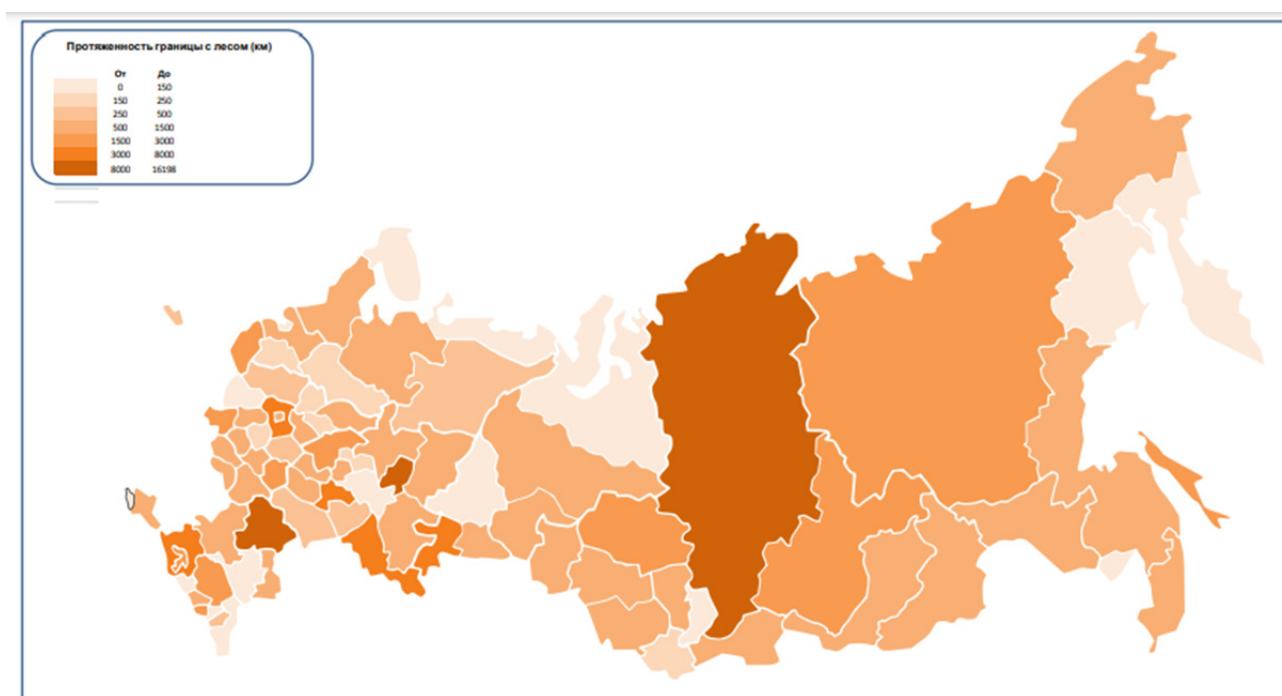


Рис. 1. Протяженность границ с лесом на объектах защиты, граничащих с лесными участками в субъектах Российской Федерации

На рис. 2 представлена динамика количества лесных пожаров на территории Российской Федерации за период с 2019 по 2022 г. Общая площадь, пройденная огнём за 2022 г., превысила 860 тыс. га, согласно данным Министерства природных ресурсов и экологии Российской Федерации.

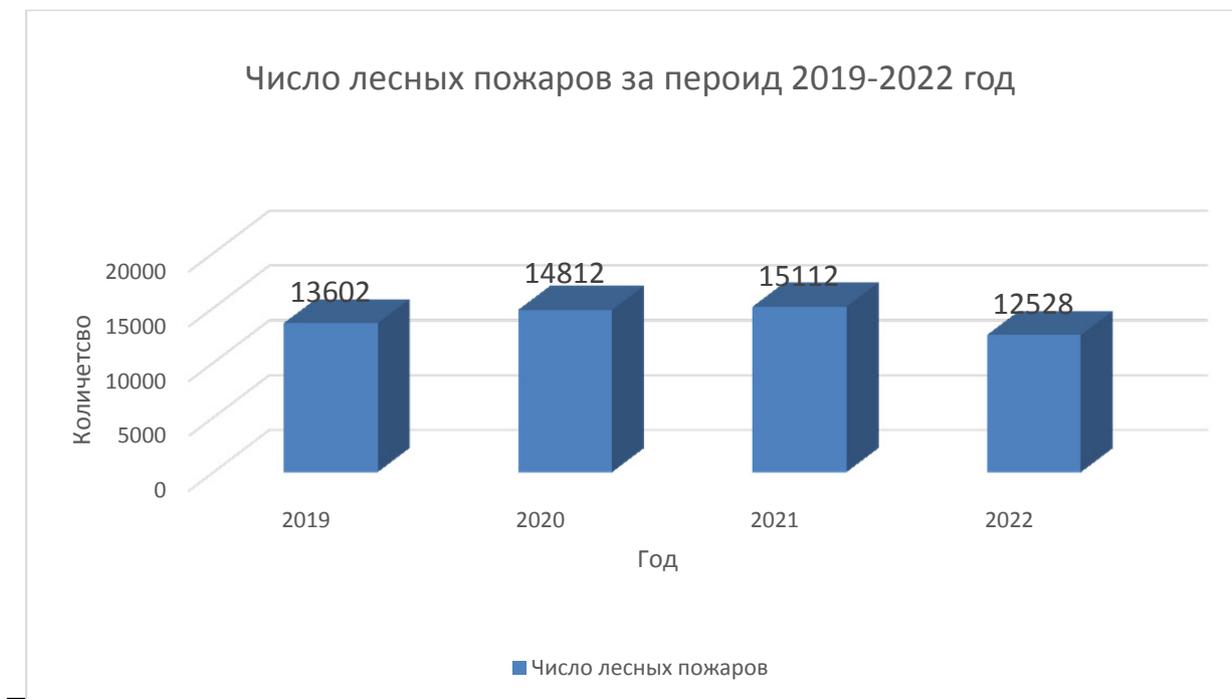


Рис. 2. Динамика лесных пожаров за период 2019–2022 г.

Исследования, связанные с прогнозированием и оценкой возникновения и развития природных пожаров, основываются на построении аналитических либо экспериментальных моделей, которые требуют высокого уровня детализации при описании модели. Данные модели имеют ряд ограничений, связанных с масштабируемостью, как временной, так и пространственной, предельной вычислительной способностью, гибкостью, универсальностью [1–3].

В связи с этим предлагается рассмотреть возможность применения адаптивной системы нейронечеткого вывода (ANFIS), которая показала хорошие результаты при решении задач прогнозирования в других областях исследования [4–6]. Использование нечеткой логики позволяет снизить степень неопределенности в исходных данных, а также восстановить причинно-следственные связи между переменными, что позволит упростить процесс интерпретации результатов применения нейронной сети.

Методы исследования

Основоположником теории нечетких множеств принято считать Лотфи Заде, который расширил классическую теорию множеств и предложил соответствующую нечеткую логику. Необходимость появления нечетких систем объяснялась развитием сложности исследуемых объектов. Возможность представлять человеческие знания в формализованном виде, выявление причинно-следственных связей обусловили активное развитие и применение данного подхода в различных областях исследований. Основным недостатком таких систем является зависимость от экспертной группы, которая привлекается при генерации правил вывода и функций принадлежности. Впоследствии этот недостаток было предложено преодолеть при помощи интеграции нейронных сетей в систему нечеткого вывода, в результате чего появилась возможность обучать такие системы без привлечения экспертов. Гибридное использование двух этих подходов позволило компенсировать основные недостатки каждого из подходов, чтобы получить удовлетворительную интерпретируемость и возможность обучать систему. Система ANFIS является примером нейро-нечеткого подхода, в котором параметры функции принадлежности подбираются алгоритмом обратного распространения ошибки, а вывод результатов при помощи нечеткой логики [7].

ANFIS – адаптивная сеть, в которой реализован нечеткий вывод типа Такаги-Сугено. Продукционные правила данного типа представлены в виде «если ... то ...». Модель Такаги-Сугено включает в себя лингвистические переменные (термы) и функциональную зависимость. В общем виде такую модель можно представить как:

$$R_i: \text{если } x_1 \text{ это } B_1 \text{ и } x_2 \text{ это } B_2 \text{ и } \dots \text{ и } x_i \text{ это } B_i, \text{ то } y = f(x_1, x_2, \dots, x_i),$$

где x_i является антецедентом, нечетким высказыванием; y – консеквентном четкой функцией.

Например, с помощью модели Такаги-Сугено можно аппроксимировать нелинейную функцию как кусочно-линейную.

На первом слое (рис. 3) осуществляется процесс фазификации входных переменных. Численные переменные переводятся в качественные путем сопоставления численного значения и значения функции принадлежности для соответствующих лингвистических переменных. Например, лингвистическая переменная «уровень пожарного риска» может содержать термы «Низкий», «Средний», «Высокий». Нейроны первого слоя активируются функцией принадлежности, которая вычисляет уровень соответствия входных данных и термов лингвистической переменной. Существует ряд апробированных функций принадлежности, используемых на практике, к таким относятся: треугольная, трапецевидная, Гауссова и др.

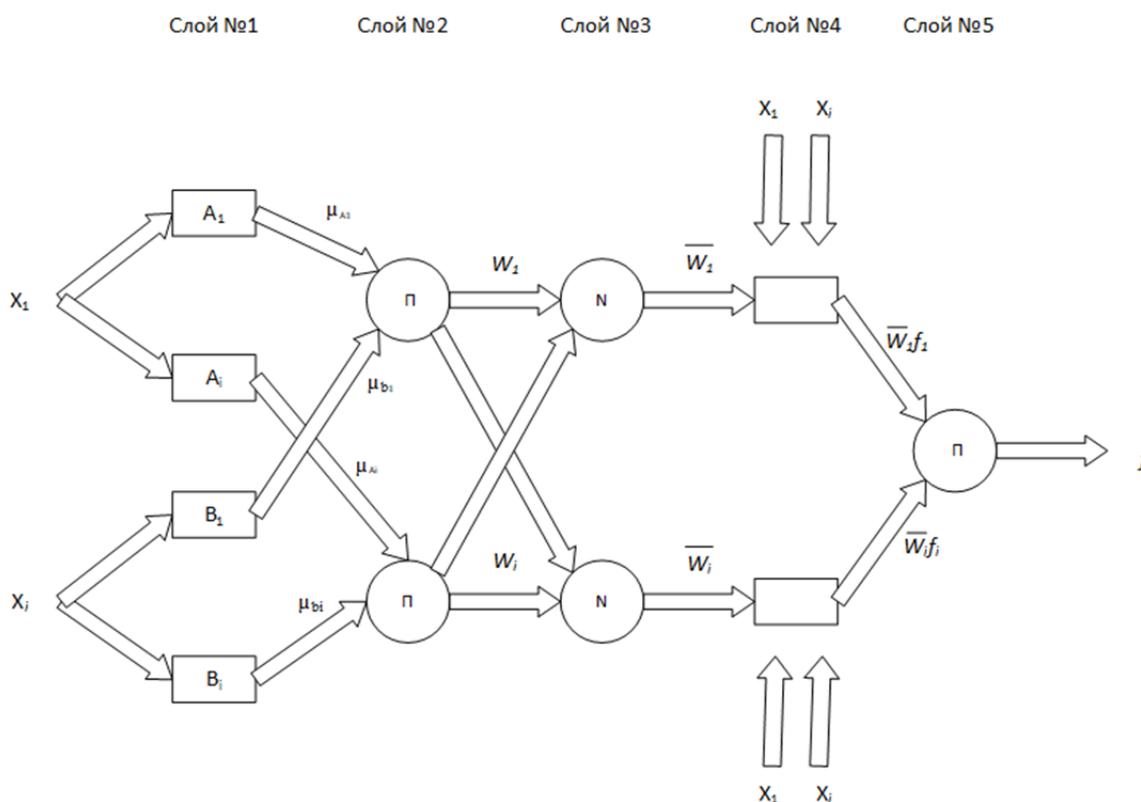


Рис. 3. Архитектура модели ANFIS

Треугольная функция принадлежности представляется в виде:

$$F(x) = \begin{cases} 1 - \frac{b-x}{b-a}, & a \leq x \leq b \\ 1 - \frac{x-b}{c-b}, & b \leq x \leq c \\ 0, & \text{для оставшихся значений } x \end{cases},$$

где a, b, c – переменные предпосылки.

Трапецевидная функция принадлежности представляется в виде:

$$F(x) = \begin{cases} 1 - \frac{b-x}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ 1 - \frac{x-c}{d-c}, & c \leq x \leq d \\ 0, & \text{для оставшихся значений } x \end{cases},$$

где a, b, c, d – переменные предпосылки.

Гауссова функция принадлежности в виде:

$$F(x) = e^{-\left(\frac{x-c}{\varphi}\right)^2},$$

где c – смещения пика от 0; φ – ширина.

Второй слой (рис. 3) представляет собой множество правил, количество нейронов соответствует количеству предикативных правил. Так как каждый нейрон представляет собой определенное правило системы, то он связан лишь с теми узлами, которые формирует посылку текущего правила. Выходом слоя является степень истинности правил, рассчитанная по алгоритму Ларсена (логические произведения), графическая интерпретация представлена на рис. 4.

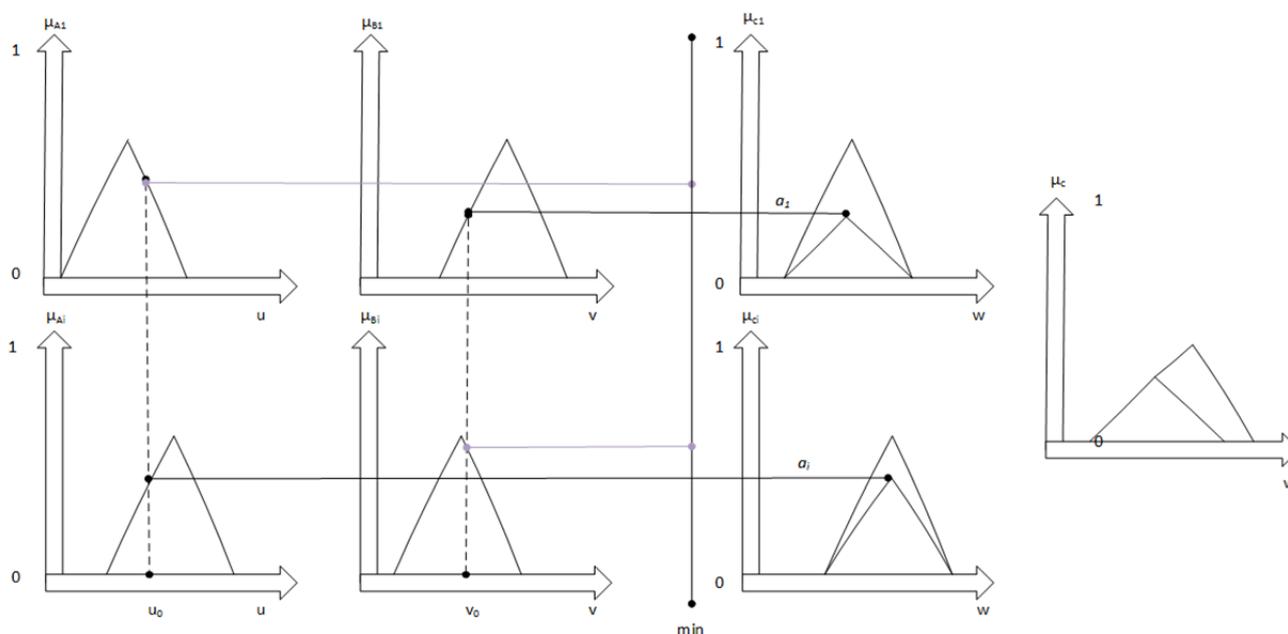


Рис. 4. Пример алгоритма Ларсена для двух входов и двух функций принадлежности

Третий слой (рис. 3) имеет такое же количество узлов, как и на втором слое, каждый нейрон представляет собой нормализованное значение степени истинности правила, в соответствии с формулой:

$$\bar{u}_i = \frac{u_i}{\sum_{j=1}^m u_j}.$$

Четвертый слой (рис. 3) состоит из того же количества нейронов, что и третий, каждый нейрон представляет степень влияния нечеткого правила на выходной слой сети. Дополнительными входными данными текущего слоя являются параметры следствий:

$$\bar{u}_i * y_i = \bar{u}_i * (c_{i1} * x_1 + c_{i2} * x_2 + \dots + c_{i0}).$$

Пятый слой состоит из одного нейрона, осуществляющего суммирование степеней влияния каждого из правил.

В процессе обучения сети подбираются оптимальные значения параметров следствий четвертого слоя методом наименьших квадратов (МНК). Используя метод обратного распространения ошибки, уточняются параметры предпосылок первого слоя. Процедура осуществляется итерационно до тех пор, пока ошибка по МНК превышает пороговое значения точности.

Параметры консеквентов по МНК итерационно можно найти по формуле:

$$S_{i+1} = S_i - \frac{S_i * a_{i+1} * a_{i+1}^T * S_i}{1 + a_{i+1}^T * S_i * a_{i+1}},$$

$$X_{i+1} = X_i + S_{i+1} * a_{i+1} * (b_{i+1}^T - a_{i+1}^T * X_i),$$

где $X_0=0$; $S_0=\gamma I$ (γ – большое число; I – единичная матрица); a_{i+1}^T – i строка матрицы A ; b_{i+1}^T – i элементы вектора B .

Корректировка параметров antecedентов осуществляется алгоритмом обратного распространения ошибок. Результат, выход сети, полученный при прямом проходе, вычитается из требуемого по каждому элементу обучающей выборки:

$$E = \sum_{p=1}^P E_p ;$$

$$E_p = (T_p - O_p^L)^2,$$

где P – размер обучающей выборки; T – действительный результат; O^L – выход последнего слоя нейронной сети.

Процесс обучения осуществляется методом градиентного спуска. Функция потерь отображает по каждому примеру текущую ошибку, а антиградиент показывает направление, в котором необходимо сместить параметры для уменьшения ошибки функции потерь. Градиент выходного слоя можно представить в виде:

$$\frac{\partial E_p}{\partial O_{i,p}^L} = -2 * (T_{i,p} - O_{i,p}^L),$$

где L – индекс крайнего слоя; i – номер текущего узла.

Градиент внутренних слоев высчитывается как линейная комбинация градиентов следующих слоев согласно формуле:

$$\frac{\partial E_p}{\partial O_{i,p}^k} = \sum_{m=1}^{k+1} \frac{\partial E_p}{\partial O_{m,p}^{k+1}} * \frac{\partial O_{m,p}^{k+1}}{\partial O_{i,p}^k},$$

где $1 \leq k \leq L-1$; K – количество узлов на k слое.

Результаты исследования

Для формирования перечня исходных признаков модели был проведен анализ существующих программных решений, позволяющих проводить компьютерное прогнозирование природных пожаров, а также научных исследований в данной области [8–12], результаты которого обобщены и представлены на табл. 1.

Таблица 1

Переменные, используемые в системах по прогнозированию лесных пожаров

Программное средство	Используемые переменные
BehavePlus [13]	температура относительная влажность воздуха скорость и направление ветра уклон местности влажность лесной подстилки лесные горючие материалы
FARSITE [14]	лесные горючие материалы сомкнутость полога леса высота над уровнем моря уклон местности ландшафтная экспозиция метеорологические условия (температура, относительная влажность скорость и направление ветра)
Wildland-urban interface Fire Dynamics Simulator-LS [15]	индикатриса нормальной скорости скорость ветра уклон местности направление нормали направление ветра или уклона

В работе [16] использовались переменные, представленные на рис. 5.

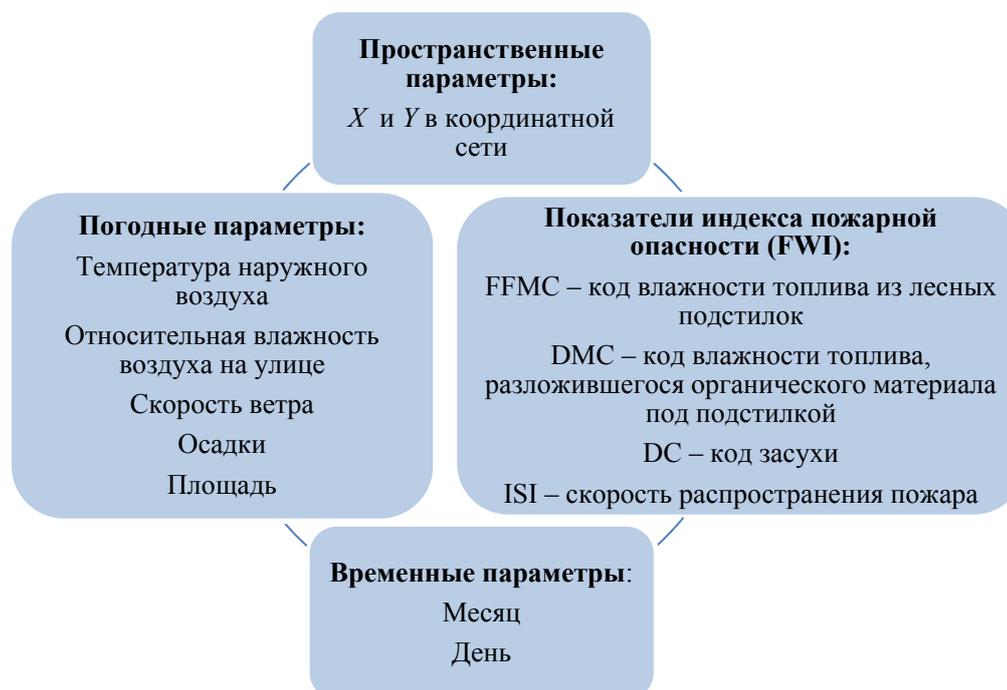


Рис. 5. Переменные, предложенные нечеткой модели прогнозирования лесных пожаров

Анализируя особенности географического, климатического, природного ландшафта, информацию о типах и запасах растительных горючих материалов, а также таксационного описания лесного фонда, предлагается использовать следующий набор переменных и их термов, представленных в табл. 2, источником данных для которых является информационная система дистанционного мониторинга Федерального агентства лесного хозяйства.

Таблица 2

**Лингвистические переменные и соответствующие им термы
для прогнозирования лесных пожаров**

Переменная	Множество термов
Температура в °С	{Высокая, Средняя, Низкая}
Точка росы	{Высокая, Средняя, Низкая}
Суточные осадки(мм)	{Высокая, Средняя, Низкая}
Площадь, пройденная огнем в субъекте Российской Федерации, (га)	{Высокая, Средняя, Низкая}
Площадь, пройденная огнем в субъекте Российской Федерации, покрытая лесом (га)	{Высокая, Средняя, Низкая}
Площадь при регистрации	{Высокая, Средняя, Низкая}
Расстояние до населенного пункта	{Далеко, Умеренно, Близко}
Продолжительность ликвидации	{Высокая, Средняя, Низкая}
Класс природной пожарной опасности (на основе влажности лесной подстилки)	{Очень высокий, Высокий, Средний, Слабый, Отсутствует}
Класс природной пожарной опасности (на основе влажности напочвенного покрова)	{Очень высокий, Высокий, Средний, Слабый, Отсутствует}

В качестве целевых переменных выступают значения:

- продолжительность ликвидации пожара;
- площадь, пройденная огнем, покрытая лесом (га).

По результатам формирования признакового пространства был проведен корреляционный анализ, представленный на рис. 6 на основе данных, взятых с сайта ИСДМ-Рослесхоз для территории Ленинградской обл. за период с 2015 по 2023 г. Корреляционная матрица позволяет сделать предположение о признаках, не оказывающих существенного влияния на целевые показатели.

Обучение нейро-нечеткой системы проводилось на накопленных исторических данных, объем которых составил 560 образцов за исследуемый период.

Обучение проводилось с использованием функции принадлежности Гаусса, с заданием среднего значения и среднеквадратичного отклонения, которые были получены по результатам статистического анализа исторических данных, представленных на рис. 7.

Каждый из признаков, представленных в табл. 2, был описан в виде термов, содержащих три функции принадлежности Гаусса.

Обучение производилось в течение девяти эпох на размеченном наборе данных, результаты которого представлены на рис. 8–10 для целевой переменной – продолжительность ликвидации.

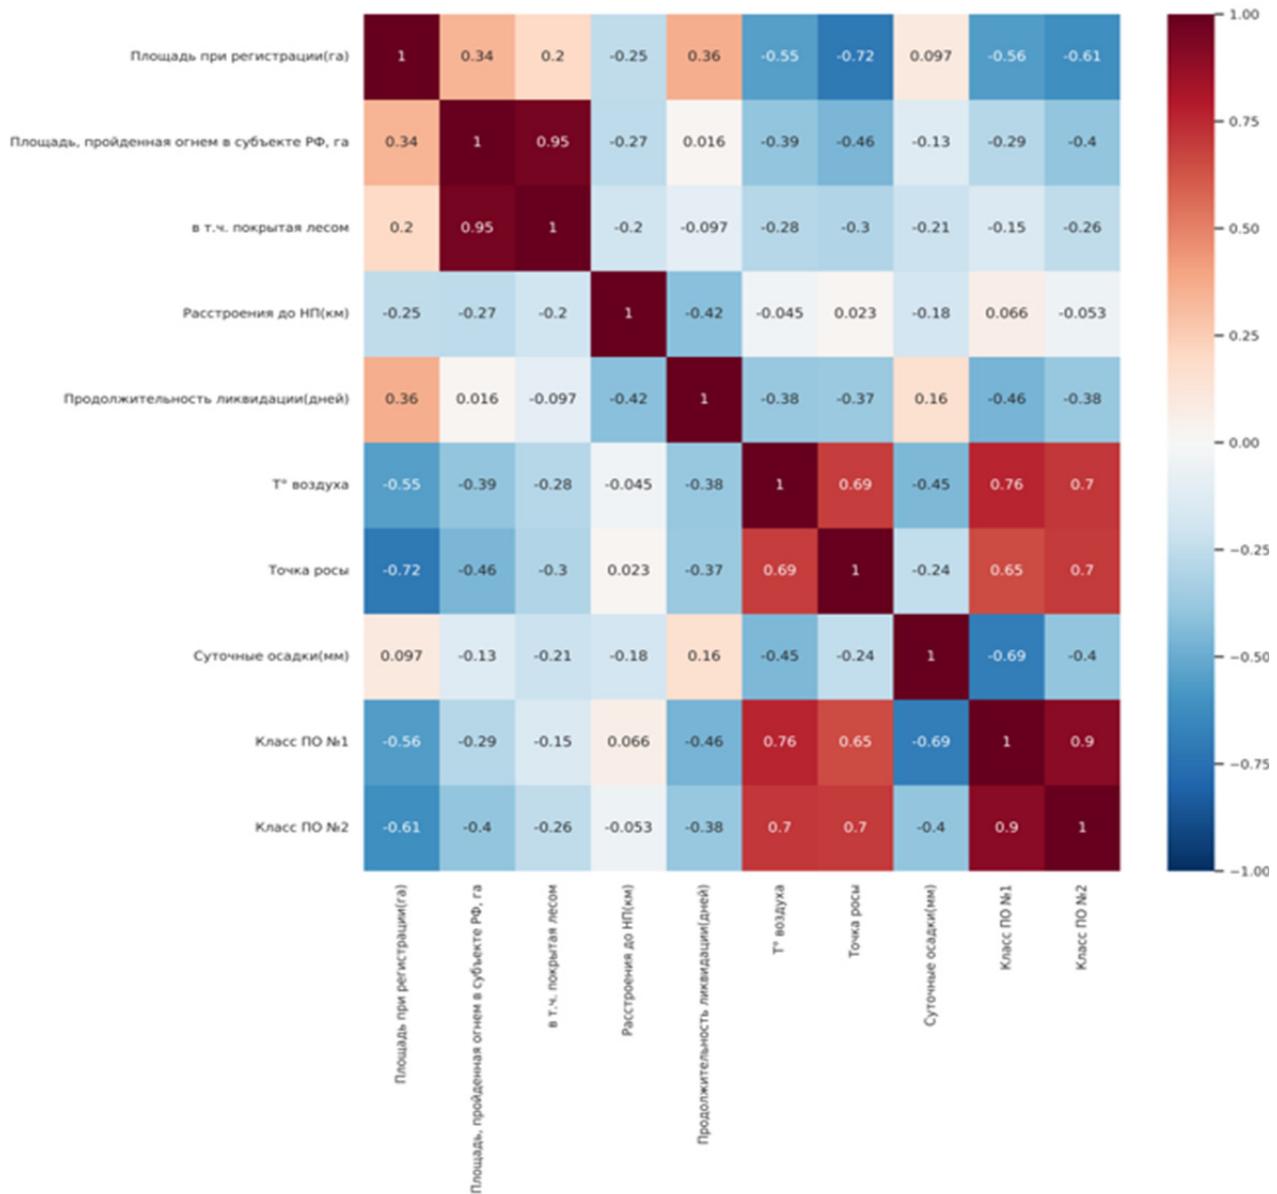


Рис. 6. Корреляционная матрица для признакового пространства

	Площадь при регистрации(га)	Площадь, пройденная огнем в субъекте РФ, га	в т.ч. покрытая лесом	Расстроения до НП(км)	Продолжительность ликвидации(дней)	Т° воздуха	Точка росы	Суточные осадки(мм)	Класс ПО №1	Класс ПО №2
count	376.000000	376.000000	376.000000	376.000000	376.000000	376.000000	376.000000	376.000000	376.000000	376.000000
mean	17.367021	39.135638	22.013298	3.950532	7.255319	18.726303	5.692021	0.499468	2.308511	3.000000
std	24.978463	96.611443	61.493868	2.032220	3.391554	13.301972	7.536145	1.442849	0.876680	1.161608
min	2.000000	0.000000	0.000000	0.300000	0.000000	-9.700000	-16.200000	0.000000	1.000000	1.000000
25%	3.000000	4.000000	3.000000	2.400000	5.000000	11.800000	0.000000	0.000000	2.000000	2.000000
50%	6.000000	10.000000	6.000000	3.800000	5.000000	20.150000	6.000000	0.000000	3.000000	3.000000
75%	25.000000	29.250000	16.000000	5.400000	10.000000	24.025000	11.425000	0.100000	3.000000	4.000000
max	169.000000	1206.000000	700.000000	10.000000	31.000000	227.000000	18.000000	9.000000	4.000000	5.000000

Рис. 7. Результаты статистического анализа исторических данных

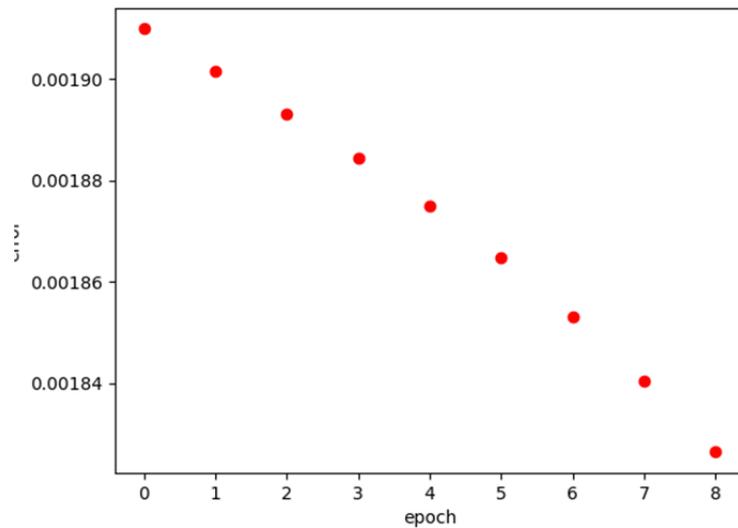


Рис. 8. График изменения ошибки с течением эпох

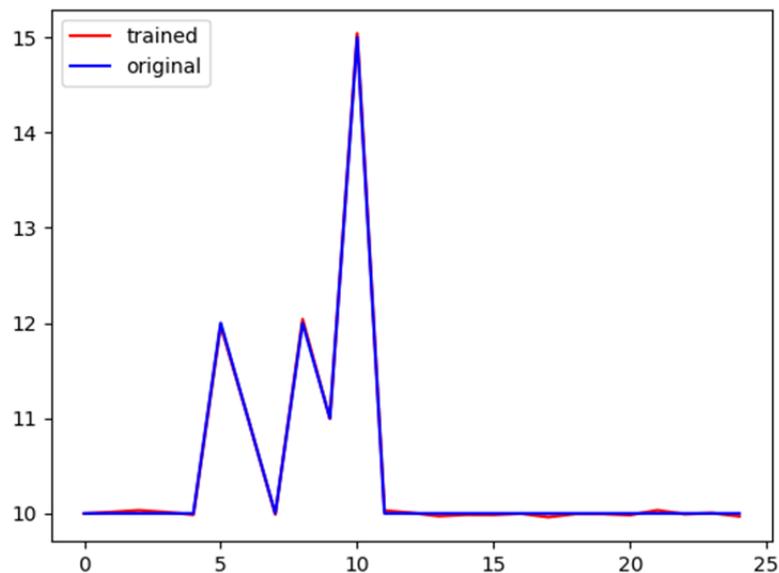


Рис. 9. График для сравнения исходных и обученных значений продолжительности ликвидации

```

current error: 0.001909866342010088
current error: 0.0019014319026158383
current error: 0.001892961108683084
current error: 0.0018844543934751978
current error: 0.0018750547581436803
current error: 0.0018646648232964874
current error: 0.0018531760806584283
current error: 0.0018404675729074122
current error: 0.0018264045498253849

```

Рис. 10. Изменение ошибки с течением эпохи

На рис. 11–13 представлены результаты обучения для целевой переменной – площадь, пройденная огнем, покрытая лесом (га).

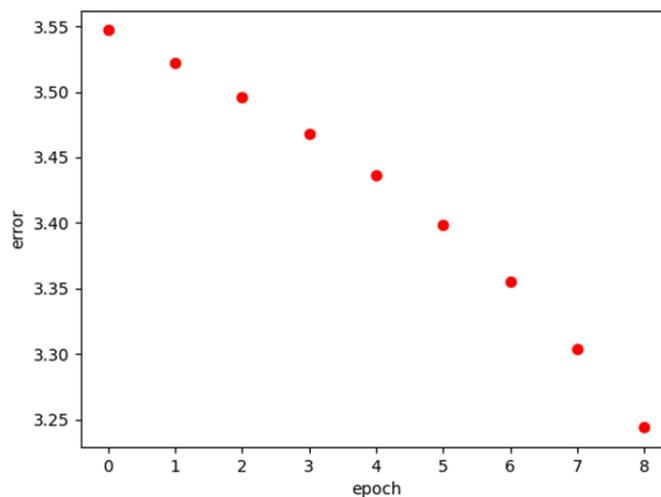


Рис. 11. График изменения ошибки с течением эпох

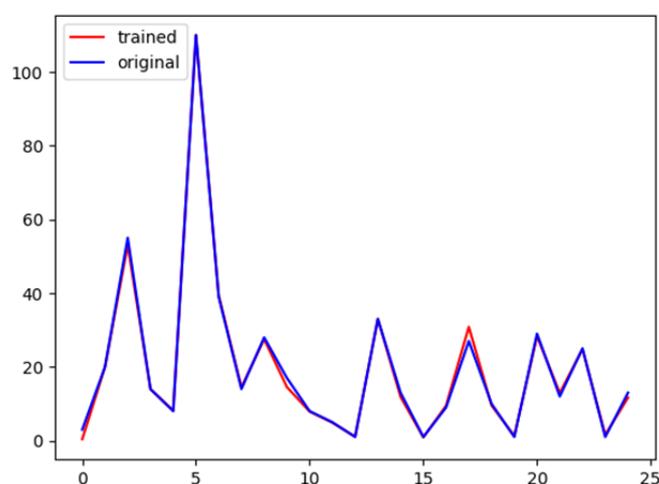


Рис. 12. График для сравнения исходных и обученных значений площади, пройденной огнем на территории Ленинградской области, покрытой лесом (га)

```

current error: 3.5470546798105245
current error: 3.5220769411462554
current error: 3.4957745218296497
current error: 3.468070022162417
current error: 3.43595438070978
current error: 3.3985790384381858
current error: 3.3549289068425967
current error: 3.3037989101897125
current error: 3.2437788528339957

```

Рис. 13. Изменение ошибки с течением эпохи

Представленные результаты обучения позволяют сделать вывод о высокой точности на обучающих данных, итоговые ошибки к концу девятой эпохи:

- продолжительность ликвидации – 0,0018;
- площади, пройденной огнем на территории Ленинградской обл., покрытой лесом (га) – 3,24.

Анализируя полученные результаты, можно сделать вывод о том, что при увеличении числа эпох ошибка при определении площади, пройденной огнем на территории

Ленинградской области, покрытой лесом (га), может быть уменьшена, однако для этого необходимо использовать более производительные ресурсы.

Полученные результаты могут быть использованы для прогнозирования выделенных целевых показателей с целью обоснования принятия соответствующих решений по привлекаемым силам и средствам, направленных на эффективное управление тушением и ликвидацией лесных пожаров на территории Ленинградской обл.

Заключение

Прогнозирование площади лесных пожаров является нетривиальной задачей, зависящей от множества факторов, не всегда имеющих четкую математическую формализацию, в связи с чем подход, основанный на нечеткой логике с возможностью обучения системы, является возможным инструментом решения данной проблемы.

Выполнив сбор исходных данных на территории Ленинградской обл. за период с 2015 по 2023 г. и определив систему нейро-нечеткого вывода, был проведен процесс обучения системы ANFIS. Реализованная система позволяет осуществлять прогнозирование продолжительности ликвидации лесного пожара, а также площади пожара.

В дальнейшем полученные результаты могут быть улучшены за счет применения большего числа исторических данных, увеличения числа значимых признаков, усовершенствования системы ANFIS.

Список источников

1. Берестенькова М.В. Интеллектуальная система прогнозирования лесных пожаров // Хвойные бореальной зоны. 2012. Т. 30. № 5-6. С. 64–67. EDN TTNHLP.
2. Колпаков В.Ф. Применение нечеткого моделирования для информационной поддержки принятия решений при ликвидации лесных пожаров // Пожаровзрывобезопасность. 2017. Т. 26. № 7. С. 65–73. DOI: 10.18322/PVB.2017.26.07.65-73. EDN ZIDWQZ.
3. Матвеев А.В., Богданова Е.М. Классификация методов прогнозирования чрезвычайных ситуаций // Национальная безопасность и стратегическое планирование. 2018. № 4 (24). С. 61–70. EDN YTPZYL.
4. Петрова И.Ю., Глебов А.А. Прогнозирование электропотребления с помощью нейро-нечеткой системы ANFIS // Наука и образование: научное издание МГТУ им. Н.Э. Баумана. 2006. № 7. С. 3. EDN HYSJDN.
5. Дуболазов В.А., Сомов А.Г. Прогнозирование и оценка экономических данных при помощи адаптивной системы нейро-нечеткого вывода ANFIS // Экономика и менеджмент систем управления. 2017. № 4-4 (26). С. 411–418. EDN ZXQAKF.
6. Оперативное прогнозирование теплового потока при пожаре в вертикальном стальном резервуаре с защитной стенкой с использованием ANFIS / Т.С. Станкевич [и др.] // Пожаровзрывобезопасность. 2020. Т. 29. № 5. С. 13–39. DOI: 10.22227/PVB.2020.29.05.13-39. EDN FFGNIX.
7. Бутырский Е.Ю., Матвеев А.В. Математическое моделирование систем и процессов. СПб.: Информ. изд. учеб.-науч. центр «Стратегия будущего», 2022. 733 с. DOI: 10.37468/book_011222. EDN CCRIRT.
8. Яковлев Д.В., Звягинцева А.В., Ус Н.А. Нейросетевое моделирование в прогнозировании возникновения лесных пожаров // Информация и безопасность. 2009. Т. 12. № 3. С. 397–404. EDN KWCIVB.
9. Ражников С.В. Информационно-аналитическая поддержка управления оповещением населения при ландшафтных (природных) пожарах // Сибирский пожарно-спасательный вестник. 2023. № 2 (29). С. 95–106.
10. Wildland Fire Burned Areas Prediction Using Long Short-Term Memory Neural Network with Attention Mechanism / Li Zhongzhi [et al.] // Fire technology. 2021. Vol. 57. P. 1–23. DOI: 10.1007/s10694-020-01028-3.

11. Forest Fire Prediction with Imbalanced Data Using a Deep Neural Network Method / C. Lai [et al.] // *Forests*. 2022. Vol. 13. № 7. P. 1129. DOI: 10.3390/f13071129.
12. Cortez P., Morais A. A Data Mining Approach to Predict Forest Fires Using Meteorological Data. In *New Trends in Artificial Intelligence // Proceedings of the 13th EPIA 2007 – Portuguese Conference on Artificial Intelligence*, Guimarães, Portugal, December 2007; Neves, J., Santos, M.F., Machado, J., Eds. P. 512–523.
13. Andrews Patricia L. Current status and future needs of the BehavePlus Fire Modeling System // *International Journal of Wildland Fire*. 2014. № 23. P. 21–33. DOI: 10.1071/WF12167.
14. Price S., Germino M.J. Modeling of fire spread in sagebrush steppe using FARSITE: an approach to improving input data and simulation accuracy // *Fire Ecology*. 2022. № 18. P. 18–23. DOI: 10.1186/s42408-022-00147-2.
15. Mahmoud H., Chulahwat A. Unraveling the Complexity of Wildland Urban Interface Fires // *Scientific Reports*. 2018. № 8. P. 9315. DOI: 10.1038/s41598-018-27215-5.
16. Nebot À., Mugica F. Forest Fire Forecasting Using Fuzzy Logic Models // *Forests*. 2021. № 12 (8). P. 1005. DOI: 10.3390/f12081005.

References

1. Beresten'kova M.V. Intellektual'naya sistema prognozirovaniya lesnyh pozharov // *Hvojnye boreal'noj zony*. 2012. T. 30. № 5-6. S. 64–67. EDN TTNHLP.
2. Kolpakov V.F. Primenenie nechetkogo modelirovaniya dlya informacionnoj podderzhki prinyatiya reshenij pri likvidacii lesnyh pozharov // *Pozharovzryvobezopasnost'*. 2017. T. 26. № 7. S. 65–73. DOI: 10.18322/PVB.2017.26.07.65-73. EDN ZIDWQZ.
3. Matveev A.V., Bogdanova E.M. Klassifikaciya metodov prognozirovaniya chrezvychajnyh situacij // *Nacional'naya bezopasnost' i strategicheskoe planirovanie*. 2018. № 4 (24). S. 61–70. EDN YTPZYL.
4. Petrova I.Yu., Glebov A.A. Prognozirovanie elektropotrebleniya s pomoshch'yu nejro-nechetkoj sistemy ANFIS // *Nauka i obrazovanie: nauchnoe izdanie MGTU im. N.E. Bauman*. 2006. № 7. S. 3. EDN HYSJDN.
5. Dubolazov V.A., Somov A.G. Prognozirovanie i ocenka ekonomicheskikh dannyh pri pomoshchi adaptivnoj sistemy nejro-nechetkogo vyvoda ANFIS // *Ekonomika i menedzhment sistem upravleniya*. 2017. № 4-4 (26). S. 411–418. EDN ZXQAKF.
6. Operativnoe prognozirovanie teplovogo potoka pri pozhare v vertikal'nom stal'nom rezervuare s zashchitnoj stenкой s ispol'zovaniem ANFIS / T.S. Stankevich [i dr.] // *Pozharovzryvobezopasnost'*. 2020. T. 29. № 5. S. 13–39. DOI: 10.22227/PVB.2020.29.05.13-39. EDN FFGNIX.
7. Butyrskij E.Yu., Matveev A.V. *Matematicheskoe modelirovanie sistem i processov*. SPb.: Inform. izd. ucheb.-nauch. centr «Strategiya budushchego», 2022. 733 s. DOI: 10.37468/book_011222. EDN CCRIRT.
8. Yakovlev D.V., Zvyaginceva A.V., Us N.A. Nejrosetevoe modelirovanie v prognozirovanii vozniknoveniya lesnyh pozharov // *Informaciya i bezopasnost'*. 2009. T. 12. № 3. S. 397–404. EDN KWCIVB.
9. Razhnikov S.V. Informacionno-analiticheskaya podderzhka upravleniya opoveshcheniem naseleniya pri landshaftnyh (prirodnyh) pozharah // *Sibirskij pozharno-spatatel'nyj vestnik*. 2023. № 2 (29). S. 95–106.
10. Wildland Fire Burned Areas Prediction Using Long Short-Term Memory Neural Network with Attention Mechanism / Li Zhongzhi [et al.] // *Fire technology*. 2021. Vol. 57. P. 1–23. DOI: 10.1007/s10694-020-01028-3.
11. Forest Fire Prediction with Imbalanced Data Using a Deep Neural Network Method / C. Lai [et al.] // *Forests*. 2022. Vol. 13. № 7. P. 1129. DOI: 10.3390/f13071129.
12. Cortez P., Morais A. A Data Mining Approach to Predict Forest Fires Using Meteorological Data. In *New Trends in Artificial Intelligence // Proceedings of the 13th EPIA 2007 – Portuguese*

Conference on Artificial Intelligence, Guimarães, Portugal, December 2007; Neves, J., Santos, M.F., Machado, J., Eds. P. 512–523.

13. Andrews Patricia L. Current status and future needs of the BehavePlus Fire Modeling System // International Journal of Wildland Fire. 2014. № 23. P. 21–33. DOI: 10.1071/WF12167.

14. Price S., Germino M.J. Modeling of fire spread in sagebrush steppe using FARSITE: an approach to improving input data and simulation accuracy // Fire Ecology. 2022. № 18. P. 18–23. DOI: 10.1186/s42408-022-00147-2.

15. Mahmoud H., Chulahwat A. Unraveling the Complexity of Wildland Urban Interface Fires // Scientific Reports. 2018. № 8. P. 9315. DOI:10.1038/s41598-018-27215-5.

16. Nebot À., Mugica F. Forest Fire Forecasting Using Fuzzy Logic Models // Forests. 2021. № 12 (8). P. 1005. DOI:10.3390/f12081005.

Информация о статье:

Статья поступила в редакцию: 27.10.2023; одобрена после рецензирования: 10.11.2023; принята к публикации: 25.12.2023

The information about article:

The article was submitted to the editorial office: 27.10.2023; approved after review: 10.11.2023; accepted for publication: 25.12.2023

Информация об авторах:

Медведев Дмитрий Валерьевич, адъюнкт Санкт-Петербургского университета ГПС МЧС России (196105, Санкт-Петербург, Московский пр., д. 149), e-mail: meedvedevdv@mail.ru, <https://orcid.org/0009-0002-9436-4376>, SPIN-код: 8464-6705

Information about the authors:

Medvedev Dmitry V., associate professor Saint-Petersburg university of State fire service of EMERCOM of Russia (196105, Saint-Petersburg, Moskovsky ave., 149), e-mail: meedvedevdv@mail.ru, <https://orcid.org/0009-0002-9436-4376>, SPIN: 8464-6705