

ОПЕРАТИВНАЯ ОЦЕНКА ПАРАМЕТРОВ ПОЖАРА В ГОРНОЙ ВЫРАБОТКЕ УГОЛЬНОЙ ШАХТЫ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

И.О. Федоткин

Университет науки и технологий МИСИС, Москва, Россия, e-mail: fedotkin.iliya@gmail.com

Аннотация: Пожары относятся к числу наиболее распространенных аварий в угольных шахтах России, а принятие обоснованных решений при их развитии требует информации не только о факте возгорания, но и о положении очага, текущей интенсивности пожара и ожидаемом изменении опасных факторов пожара. В связи с этим проведено исследование возможности применения нейросетевой модели для совместной оценки расстояния до очага пожара, текущей мощности тепловыделения и краткосрочного прогноза температуры и концентрации оксида углерода (СО) в контрольных точках горной выработки. Входными данными нейросетевой модели являлись временные окна предшествующих значений температуры и концентрации СО в трех последовательно расположенных точках измерения, а также скорость вентиляционного потока. Горизонт прогноза значений температуры и концентрации СО составлял 60 с. На тестовой выборке средняя абсолютная ошибка составила 99,34 кВт для оценки мощности тепловыделения пожара, 4,11 м – для оценки расстояния до очага, 2,97 °С – для прогноза температуры и 12,85 ppm – для прогноза концентрации СО. Полученные результаты показывают, что в пределах принятого в данной работе диапазона сценариев нейросетевая модель с входными данными в виде временных окон значений температуры и концентрации СО может быть использована для совместной оценки параметров очага пожара и краткосрочного прогноза значений рассматриваемых опасных факторов пожара в контрольных точках горной выработки.

Ключевые слова: подземный пожар, угольная шахта, нейросетевая модель, искусственная нейронная сеть, мощность тепловыделения, расстояние до очага пожара, прогнозирование опасных факторов пожара, оксид углерода.

Для цитирования: Федоткин И. О. Оперативная оценка параметров пожара в горной выработке угольной шахты с использованием машинного обучения // Горный информационно-аналитический бюллетень. – 2026. – № 8. – С. 157–166. DOI: 10.25018/0236_1493_2026_8_0_157.

Rapid assessment of fire parameters in coal mines using machine learning

I.O. Fedotkin

University of Science and Technology MISIS, Moscow, Russia, e-mail: fedotkin.iliya@gmail.com

Abstract: Fires are among the most frequent accidents in coal mines in Russia. Valid reaction choice during a fire requires information not only about the fact itself, but also about the location of the seat of fire, its current intensity and anticipated change of the fire hazards. In this respect, this study explores applicability of neural network models for the joint assessment of

the distance to the seat of fire, current heat liberation intensity and short-term prediction of temperature and carbon oxide concentration at the check points in a roadway. The input data of a neural network model were the time windows of previous temperatures and CO concentrations at three tandem check points, and ventilation airflow velocities. The forecast horizon for the temperature and CO concentration was 60 s. In the test sampling, the absolute error was 99.34 kW for the heat liberation capacity, 4.11 m for the distance to the seat of fire, 2.97 °C for the predicted temperature and 12.85 ppm for the predicted CO concentration. The results show that within the assumed range of scenarios in this study, the neural network model with the input data in the form of the time windows of previous temperatures and CO concentrations is usable for the joint assessment of fire parameters and short-term prediction of the test fire hazards at the check points in coal mines.

Key words: underground fire, coal mine, neural network model, artificial neural network, heat liberation capacity, distance to seat of fire, prediction of fire hazards, carbon oxide.

For citation: Fedotkin I. O. Rapid assessment of fire parameters in coal mines using machine learning. *MIAB. Mining Inf. Anal. Bull.* 2026;(8):157-166. [In Russ]. DOI: 10.25018/0236_1493_2026_8_0_157.

Введение

Пожары являются одним из самых распространенных видов аварий в российских угольных шахтах и представляют большую опасность для жизни и здоровья горнорабочих, а также приводят к значительным экономическим потерям и экологическому ущербу [1–3]. Кроме того, пожары в угольных шахтах могут приводить к разрушительным взрывам газа и угольной пыли с катастрофическими последствиями [4–6].

Для принятия обоснованных решений во время аварии важно располагать не только сведениями о факте возникновения пожара, но и данными о месте расположения очага и текущем состоянии пожара. Одной из наиболее содержательных количественных характеристик пожара является мощность тепловыделения. Данный параметр характеризует интенсивность выделения тепловой энергии при горении и является одним из ключевых показателей, определяющих развитие опасной обстановки во времени [7, 8].

Наряду с оценкой местоположения очага и текущей мощности тепловыде-

ления важное значение имеет прогнозирование опасных факторов пожара в контрольных точках горной выработки. В рамках данного исследования в качестве прогнозируемых параметров выбраны температура газовой среды и концентрация оксида углерода, поскольку они являются одними из основных показателей теплового и токсического воздействия пожара, а также доступны для инструментального контроля в шахтных условиях. При пожарах в горных выработках повышение температуры связано не только с ухудшением условий пребывания людей и тепловым воздействием на оборудование, но также оно может способствовать формированию тепловой депрессии пожара и изменению условий проветривания аварийного участка [8, 9].

Оксид углерода образуется при неполном сгорании горючих материалов и является одним из наиболее опасных токсичных продуктов сгорания. В отличие от температуры, высокая концентрация СО может сохраняться и распространяться на значительные расстояния от очага, в том числе на участки, где не-

посредственное тепловое воздействие выражено слабее [10].

Для расчета опасных факторов пожара в подземных горных выработках применяются различные типы математических моделей. Наиболее детальное описание пространственно-временной структуры потока обеспечивают модели вычислительной гидрогазодинамики или CFD-модели (Computational Fluid Dynamics). Такие модели позволяют детально рассчитывать температурные поля, распространение продуктов сгорания, а также влияние вентиляции на развитие пожарной обстановки [10–12]. Вместе с тем их применение в оперативном режиме существенно ограничено высокой вычислительной стоимостью, продолжительным временем расчета и необходимостью заранее задавать геометрию, граничные условия и параметры очага.

Другой класс инструментов составляют одномерные сетевые модели вентиляции. Такие модели позволяют быстрее анализировать влияние пожара на вентиляционную сеть в масштабе всего объекта, однако для них характерно упрощенное представление о структуре потока, вследствие чего они не описывают в полной мере трехмерные эффекты, такие как неоднородность температуры и концентраций по сечению выработки, локальные зоны перемешивания и сложная пространственно-временная структура потока вблизи очага. Кроме того, указанные модели также требуют предварительного задания достаточно полного описания состояния объекта и аварийного сценария [10, 13]. Их оперативное применение при развивающемся пожаре осложняется неполнотой данных о текущей обстановке, в том числе неопределенностью фактического положения очага и интенсивности тепловыделения. Таким образом, актуальной задачей является исследование подходов к оперативной оценке параметров очага

пожара и краткосрочному прогнозированию температуры и концентрации СО в горных выработках. В настоящей работе рассматривается нейросетевая модель, принимающая в качестве входных данных временные окна значений температуры и концентрации СО в трех точках измерения. Модель предназначена для одновременной оценки состояния до очага, текущей мощности тепловыделения пожара и прогноза температуры и концентрации СО в точках измерения через 60 с.

Постановка задачи

Для моделирования различных сценариев пожара с целью создания обучающего набора данных был использован подход вычислительной динамики жидкости и газа на основе программного комплекса Fire Dynamics Simulator (FDS). В FDS реализуется трехмерное моделирование низкоскоростных течений на основе численного решения уравнений Навье–Стокса с использованием метода крупных вихрей [14]. FDS использовался в большом числе исследований, посвященных моделированию пожаров в тоннелях и протяженных подземных сооружениях, и является хорошим источником подробных физически согласованных данных в многопараметрических постановках [15–17].

Расчетная область представляла собой протяженную горную выработку прямоугольного сечения высотой 2,4 м, шириной 3,2 м и длиной 220 м с продольной вентиляцией. Источник пожара располагался по ходу вентиляционного потока на расстоянии 210 м от выходной границы и задавался как площадной очаг размером 2,4×2,4 м (площадью 5,76 м²), характеризующий обобщенный экзогенный пожар в горной выработке. В качестве горючей нагрузки использовались характеристики модельного топлива с теплотой сгорания 25 МДж/кг [18, 19].

Динамика роста тепловыделения на начальной стадии задавалась по квадратичному закону (t-squared fire) [20, 21]. Пространство сценариев для CFD-моделирования задавалось вариацией следующих параметров: пиковая мощность тепловыделения пожара, продольная скорость движения вентиляционного потока и время достижения пиковой мощности. Скорость движения вентиляционного потока изменялась в диапазоне от 1,0 до 5,0 м/с, пиковая мощность тепловыделения принимала значения от 1,0 до 5,0 МВт, а время ее достижения составляло 120, 180 или 240 с [21].

Для каждого сценария выполнялся отдельный CFD-расчет с уникальным идентификатором, по которому в дальнейшем проводилось разделение данных на обучающую и тестовую части. Таким образом, качество модели оценивалось на сценариях, не использовавшихся при обучении, что обеспечивало проверку способности искусственной нейронной сети формировать предсказания для новых сочетаний мощности тепловыделения пожара, скорости вентиляционного потока и времени развития пожара.

CFD-модель предусматривала запись значений температуры и концентрации оксида углерода (CO) в контрольных точках, находящихся у кровли выработки на высоте 2,2 м. Для обучения искусственной нейронной сети формировались конфигурации, состоящие из трех точек, обозначаемых как p_1 , p_2 , p_3 , и расположенных последовательно по направлению вентиляционного потока. Точки измерения располагались так, чтобы расстояние между соседними точками конфигурации составляло 20 м и при этом расстояние от очага до точки (ближней к очагу) находилось в диапазоне от 10 до 160 м, что обеспечивало рассмотрение различных положений измерительной конфигурации относительно источника пожара.

В каждой точке p_i , $i = 1, 2, 3$ в момент времени t регистрировались две величины: температура газовой среды $T_i(t)$, °С и концентрация оксида углерода $C_i(t)$. По этим данным для каждой точки измерения создавалось временное окно предшествующих значений измеряемой величины, поскольку такая форма входных данных позволяет учитывать не только текущие значения температуры и концентрации CO, но и характер их изменения во времени. В рассматриваемом случае для температуры и концентрации CO учитывалась история показаний за последние 30 с.

Дополнительно в качестве известного параметра режима проветривания во входной вектор признаков включалась продольная скорость вентиляционного потока V , м/с. Таким образом, общий входной вектор признаков нейросети имел следующий вид

$$\mathbf{x}(t) = [T_1(t), C_1(t), T_2(t), C_2(t), T_3(t), C_3(t), V]$$

где $T_i(t)$ и $C_i(t)$ обозначают временные окна значений температуры и концентрации CO в точке p_i .

Вектор целей искусственной нейронной сети включал 8 выходных переменных. Первая целевая переменная d , м, соответствовала расстоянию от очага пожара до ближайшей точки измерения. Вторая целевая переменная $Q(t)$, кВт, соответствовала текущему значению мощности тепловыделения пожара. Остальные 6 целевых переменных задавали значения температуры и концентрации CO в каждой из точек измерения через горизонт прогноза τ . Таким образом, целевой вектор имел вид

$$\mathbf{y}(t) = [d, Q(t), T_1(t + \tau), C_1(t + \tau), T_2(t + \tau), C_2(t + \tau), T_3(t + \tau), C_3(t + \tau)] \in \mathbb{R}^8.$$

После формирования обучающего набора данных выполнялось его разделение на обучающую и тестовую выборки в соотношении 80 на 20%. Разделение проводилось по уникальным идентификаторам CFD-сценариев CHID, в результате чего все временные отсчеты, относящиеся к одному CFD-расчету, попадали только в одну из выборок. Такой способ разбиения предотвращал утечку информации между выборками и обеспечивал оценку качества модели на сценариях, не использовавшихся при обучении.

Для решения задачи использовалась многослойная полносвязная искусственная нейронная сеть, реализующая отображение

$$\hat{\mathbf{y}}(t) = f_0(\mathbf{x}(t)),$$

где $\mathbf{x}(t)$ — входной вектор признаков; $\hat{\mathbf{y}}(t)$ — вектор предсказанных значений целевых переменных; θ — набор обучаемых параметров модели.

В скрытых слоях нейронной сети использовалась функция активации ReLU [22].

Перед обучением входные признаки и целевые переменные стандартизировались следующим образом: для каждой переменной z рассчитывалось среднее значение μ_z и стандартное отклонение s_z по обучающей выборке, далее выполнялось преобразование

$$z^* = \frac{z - \mu_z}{s_z},$$

где z — исходное значение соответствующей переменной; z^* — стандартизованное значение; μ_z и s_z — среднее значение и стандартное отклонение переменной z , рассчитанные по обучающей выборке.

Параметры, рассчитанные на обучающей выборке, использовались для преобразования тестовой выборки и для обратного преобразования целевых пе-

ременных к исходным физическим единицам. Такой порядок обработки данных исключает использование информации из тестовой выборки при подготовке данных для обучения [23].

При обучении нейронной сети минимизировалась среднеквадратичная ошибка между стандартизованными истинными значениями целевых переменных и соответствующими предсказаниями модели. Для пакета данных размера B функция потерь $\mathcal{L}(\theta)$ описывалась следующим выражением:

$$\mathcal{L}(\theta) = \frac{1}{Bm} \sum_{j=1}^B \sum_{k=1}^m (\hat{y}_{j,k}^* - y_{j,k}^*)^2,$$

где B — число примеров в пакете данных; m — количество целевых переменных; $y_{j,k}^*$ — стандартизованное истинное значение k -ой целевой переменной для j -го объекта; $\hat{y}_{j,k}^*$ — соответствующее предсказанное значение.

Минимизация функции потерь выполнялась с использованием адаптивного градиентного метода оптимизации семейства Adam. Нейросетевая модель была реализована на языке Python с использованием открытой библиотеки машинного обучения PyTorch.

Для оценки качества нейросетевой модели использовались метрики, рассчитываемые после обратного преобразования предсказанных значений к исходным физическим единицам. Для отдельной целевой переменной использовалась средняя абсолютная ошибка (MAE), выражаемая в единицах измерения целевой переменной и определяемая как

$$MAE = \frac{1}{N} \sum_{j=1}^N |y_j - \hat{y}_j|,$$

где y_j — истинное значение j -й целевой переменной; \hat{y}_j — предсказанное значение соответствующей переменной; N — число объектов тестовой выборки.

Для сопоставления ошибок величин, имеющих разные единицы измерения,

также использовалась нормированная средняя абсолютная ошибка, NMAE (%):

$$NMAE = \frac{MAE}{D_y} \cdot 100\%,$$

где D_y – нормирующее значение для соответствующей целевой величины.

Для расстояния до очага, текущей мощности тепловыделения, температуры и концентрации CO значение D_y определялось как диапазон истинных значений соответствующей целевой переменной на тестовой выборке. При расчете данной метрики для группы однотипных целевых переменных, например для трех прогнозируемых температур, данный диапазон определялся по объединенному массиву истинных значений соответствующей группы. Дополнительно для оценки верхней части распределения ошибок рассчитывались 90-й и 95-й процентиля абсолютной ошибки, далее обозначаемые как p_{90} и p_{95} . Данные показатели соответствуют значениям абсолютной ошибки $|y_j - \hat{y}_j|$, ниже которых находится соответственно 90 и 95% всех рассчитанных абсолютных ошибок для соответствующей группы целевых величин. Относительные значения p_{90} и p_{95} определялись делением соответствующих процентилей абсолютной ошибки на нормирующее значение D_y .

Результаты и обсуждение

Качество модели оценивалось на тестовой выборке отдельно для четырех групп целевых переменных: текущей мощности тепловыделения, расстояния до очага пожара, температуры и концентрации CO на горизонте прогнозирования 60 с.

Для температуры и концентрации CO показатели рассчитаны по объединенному массиву ошибок для трех точек измерения p_1, p_2, p_3 , что позволяет оценить среднюю точность прогноза опасных факторов пожара по всей рассматриваемой конфигурации точек.

Как видно из таблицы, средняя абсолютная ошибка оценки текущей мощности тепловыделения пожара составила 99,34 кВт, а нормализованная средняя абсолютная ошибка (NMAE) – 1,92%. При этом для 90% предсказаний модели абсолютная ошибка не превышала 228,29 кВт, а для 95% предсказаний – 347,90 кВт, что соответственно составляет 4,42 и 6,73% от нормирующего диапазона. Таким образом, модель способна восстанавливать текущую интенсивность пожара по косвенным признакам, содержащимся во временных окнах температуры и концентрации CO при заданной скорости вентиляционного потока.

Показатели точности нейросетевой модели на тестовой выборке

Accuracy metrics of the neural-network model on the test set

Группа целевых переменных	MAE – средняя абсолютная ошибка	NMAE – нормализованная средняя абсолютная ошибка, %	p_{90} / p_{95} – 90-й и 95-й процентиля абсолютной ошибки	Относительные значения p_{90} / p_{95} , % от диапазона
Текущая мощность тепловыделения пожара $\dot{Q}(t)$, кВт	99,34	1,92	228,29 / 347,90	4,42 / 6,73
Расстояние до очага d , м	4,11	2,74	6,98 / 16,68	4,65 / 11,12
Температура через 60 с в точках p_1-p_3 , $T(t+60)$, °C	2,97	0,83	7,52 / 11,59	2,10 / 3,23
Концентрация оксида углерода через 60 с в точках p_1-p_3 , $C(t+60)$, ppm	12,85	1,17	33,02 / 48,88	3,00 / 4,44

Аналогичный вывод можно сделать относительно способности нейросетевой модели к оценке расстояния до очага d . Средняя абсолютная ошибка для этой целевой переменной составила 4,11 м, что соответствует $NMAE = 2,74\%$, а 90-й и 95-й процентилю абсолютной ошибки составили соответственно 6,98 и 16,68 м, или 4,65 и 11,12% от нормирующего диапазона. С учетом протяженности рассматриваемой области и принятой измерительной конфигурации этот результат показывает, что в рамках данной постановки модель может использоваться для предварительного определения участка выработки, в котором расположен очаг пожара.

Наиболее высокая точность по нормированным показателям была получена при прогнозировании значений температуры и концентрации CO на 60 с вперед, то есть для параметров, непосредственно контролируемых в точках измерения. Средняя абсолютная ошибка прогноза температуры составила $2,97\text{ }^{\circ}C$ ($NMAE = 0,83\%$), а 95-й перцентиль абсолютной ошибки — $11,59\text{ }^{\circ}C$. Для концентрации CO соответствующие значения составили 12,85 ppm ($NMAE = 1,17\%$) и 48,88 ppm. Для всех рассмотренных групп целевых величин коэффициент детерминации составлял не менее 0,96. Это свидетельствует о высокой доле объясненной дисперсии и показывает, что нейросетевая модель не только обеспечивает приемлемые значения средних ошибок, но и воспроизводит основную вариацию целевых параметров на тестовой выборке.

Данный результат может быть объяснен общей постановкой задачи и использованием временного окна предшествующих значений температуры и концентрации CO . В отличие от подхода, основанного только на текущем срезе измерений, временное окно содержит информацию о предшествующей

динамике контролируемых параметров, в том числе о направлении изменения, скорости этого изменения, а также о форме сигнала, характерной для определенной стадии развития пожара при заданном режиме проветривания. Такая информация особенно важна для краткосрочного прогноза, поскольку она более полно отражает развитие процессов переноса тепла и продуктов горения вентиляционным потоком. В результате модель получает информацию, достаточную для аппроксимации зависимости между текущей динамикой показаний датчиков и их значениями на горизонте 60 с в пределах рассмотренной постановки.

Заключение

В работе рассмотрена нейросетевая модель для оперативной совместной оценки параметров очага пожара и краткосрочного прогнозирования опасных факторов пожара в протяженной горной выработке. В качестве входных данных использовались временные окна предшествующих значений температуры и концентрации CO в трех последовательно расположенных точках измерения, а также значение продольной скорости вентиляционного потока. Целевыми переменными являлись расстояние от очага до ближайшей точки измерения, текущая мощность тепловыделения пожара, а также значения температуры и концентрации CO в точках измерения на горизонте прогноза 60 с.

Полученные результаты показали, что в пределах рассмотренной постановки нейросетевая модель обеспечивает оценку текущей мощности тепловыделения пожара со средней абсолютной ошибкой 99,34 кВт и оценку расстояния до очага со средней абсолютной ошибкой 4,11 м. Для 95% предсказаний абсолютная ошибка не превышала 347,90 кВт для мощности тепловыделения и 16,68 м

для расстояния до очага. Эти значения показывают, что временные окна температуры и концентрации СО содержат информативные признаки, позволяющие косвенно оценивать рассматриваемые характеристики очага пожара.

Наиболее высокая точность по нормированным показателям была получена при прогнозировании температуры и концентрации СО на горизонте 60 с. Средняя абсолютная ошибка прогноза температуры составила 2,97 °С при NMAE = 0,83%, а средняя абсолютная ошибка прогноза концентрации СО – 12,85 ppm при NMAE = 1,17%. При этом 95-й процентиль абсолютной ошибки составил соответственно 11,59 °С и 48,88 ppm.

Таким образом, полученные результаты показывают, что нейросетевая модель может использоваться для совме-

стной оценки расстояния до очага, текущей мощности тепловыделения пожара и краткосрочного прогноза температуры и концентрации СО в контрольных точках горной выработки в рамках рассмотренного диапазона сценарных параметров.

С практической точки зрения совместная оценка расстояния до очага, текущей мощности тепловыделения и прогнозных значений температуры и концентрации СО позволяет перейти от регистрации отдельных признаков пожара к более полной и упреждающей оценке аварийной обстановки. Описанный подход может рассматриваться как основа для информационной поддержки решений при анализе развития аварии, оценке возможных вариантов вентиляционного режима, организации эвакуации и планировании действий горноспасательных подразделений.

СПИСОК ЛИТЕРАТУРЫ

1. *Liang Y., Yang Y., Guo S., Tian F., Wang S.* Combustion mechanism and control approaches of underground coal fires: a review // *International Journal of Coal Science & Technology*. 2023, vol. 10, article 24. DOI: 10.1007/s40789-023-00581-w.

2. *Баловцев С. В., Скопинцева О. В., Куликова Е. Ю.* Анализ аварийности и тенденции развития аэрологической безопасности угольных шахт // *Горный информационно-аналитический бюллетень*. – 2024. – № 12. – С. 135–149. DOI: 10.25018/0236_1493_2024_12_0_135.

3. *Архипов И. А., Филин А. Э.* Анализ состояния аварийности на угольных предприятиях России // *Горный информационно-аналитический бюллетень*. – 2019. – № 1. – С. 208–215. DOI: 10.25018/0236-1493-2019-01-0-208-215.

4. *Niu Y., Si R., Li Z., Wang L., Huang Z., Jia Q.* Experimental study on gas and coal dust explosive overpressure and flame dynamic characteristics in an engineering-level test roadway // *Frontiers in Earth Science*. 2023, vol. 11, article 1330932. DOI: 10.3389/feart.2023.1330932.

5. *Скопинцева О. В., Баловцев С. В., Рыбичев А. А.* Исследование взрывопожароопасности угольной пыли пластов средней стадии метаморфизма // *Горный информационно-аналитический бюллетень*. – 2026. – № 5. – С. 80–94. DOI: 10.25018/0236_1493_2026_5_0_80.


6. *Жихарев С. Я., Родионов В. А., Пихконен Л. В.* Исследование технологических свойств и показателей взрывопожароопасности каменноугольной пыли инновационными методами // *Горный журнал*. – 2018. – № 6. – С. 45–49. DOI: 10.17580/gzh.2018.06.09.

7. *Babrauskas V., Peacock R. D.* Heat release rate: The single most important variable in fire hazard // *Fire Safety Journal*. 1992, vol. 18, no. 3, pp. 255–272. DOI: 10.1016/0379-7112(92)90019-9.

8. *Salami O. B., Kumar A. R., Aamir I., Pushparaj R. I., Xu G.* Enhancing fire safety in underground mines: Experimental and large eddy simulation of temperature attenuation, gas evolution, and bifurcation influence for improved emergency response // *Process Safety and Environmental Protection*. 2024, vol. 183, pp. 260–273. DOI: 10.1016/j.psep.2023.12.056.

9. *Zhang M., Li Z.* Experiments on a mine system subjected to ascensional airflow fire and countermeasures for mine fire control // *Fire*. 2024, vol. 7, no. 7, article 223. DOI: 10.3390/fire7070223.

10. *Yuan L., Zhou L., Smith A. C.* Modeling carbon monoxide spread in underground mine fires // *Applied Thermal Engineering*. 2016, vol. 100, pp. 1319–1326. DOI: 10.1016/j.applthermaleng.2016.03.007.

11. Li B., Li Y., Sun Y., Zhang W., Li J., Zhang Z., Cui Y., Dong J., Liu H. Study on the influence of forced ventilation on the maximum fire temperature in roadway heading // *Scientific Reports*. 2025, vol. 15, article 9830. DOI: 10.1038/s41598-025-94169-w.
12. Копылов Н. П., Федоткин Д. В., Карпов А. В., Сушкина Е. Ю. Моделирование тушения пожаров нефтепродуктов в резервуарах с применением водопенных огнетушащих веществ // *Безопасность труда в промышленности*. – 2020. – № 8. – С. 14–22. DOI: 10.24000/0409-2961-2020-8-14-22.
13. Nematollahi Sarvestani A., Oreste P., Gennaro S. Fire scenarios inside a room-and-pillar underground quarry using numerical modeling to define emergency plans // *Applied Sciences*. 2023, vol. 13, no. 7, article 4607. DOI: 10.3390/app13074607.
14. Weisenpacher P., Glasa J., Valasek L. Investigation of various fire dynamics simulator approaches to modelling airflow in road tunnel induced by longitudinal ventilation // *Fire*. 2025, vol. 8, no. 2, article 74. DOI: 10.3390/fire8020074.
15. Fernández-Alaiz F., Castañón A.M., Gómez-Fernández F., Bascompta M. Mine fire behavior under different ventilation conditions: Real-scale tests and CFD modeling // *Applied Sciences*. 2020, vol. 10, no. 10, article 3380. DOI: 10.3390/app10103380.
16. Haghighat A., Luxbacher K. Tenability analysis for improvement of firefighters' performance in a methane fire event at a coal mine working face // *Journal of Fire Sciences*. 2018, vol. 36, no. 3, pp. 256–274. DOI: 10.1177/0734904118767066.
17. Ang C. D., Rein G., Peiró J., Harrison R. Simulating longitudinal ventilation flows in long tunnels: Comparison of full CFD and multi-scale modelling approaches in FDS6 // *Tunnelling and Underground Space Technology*. 2016, vol. 52, pp. 119–126. DOI: 10.1016/j.tust.2015.11.003.
18. Yuan L., Mainiero R. J., Rowland J. H., Thomas R. A., Smith A. C. Numerical and experimental study on flame spread over conveyor belts in a large-scale tunnel // *Journal of Loss Prevention in the Process Industries*. 2014, vol. 30, pp. 55–62. DOI: 10.1016/j.jlp.2014.05.001.
19. Tan P., Zhang C., Xia J., Fang Q.-Y., Chen G. Estimation of higher heating value of coal based on proximate analysis using support vector regression // *Fuel Processing Technology*. 2015, vol. 138, pp. 298–304. DOI: 10.1016/j.fuproc.2015.06.013.
20. Mowrer F. W., Williamson R. B. Methods to characterize heat release rate data // *Fire Safety Journal*. 1990, vol. 16, no. 5, pp. 367–387. DOI: 10.1016/0379-7112(90)90009-4.
21. Ingason H. Design fire curves for tunnels // *Fire Safety Journal*. 2009, vol. 44, no. 2, pp. 259–265. DOI: 10.1016/j.firesaf.2008.06.009.
22. Dubey S. R., Singh S. K., Chaudhuri B. B. Activation functions in deep learning: A comprehensive survey and benchmark // *Neurocomputing*. 2022, vol. 503, pp. 92–108. DOI: 10.1016/j.neucom.2022.06.111.
23. Kapoor S., Narayanan A. Leakage and the reproducibility crisis in machine-learning-based science // *Patterns*. 2023, vol. 4, no. 9, article 100804. DOI: 10.1016/j.patter.2023.100804. 

REFERENCES

1. Liang Y., Yang Y., Guo S., Tian F., Wang S. Combustion mechanism and control approaches of underground coal fires: a review. *International Journal of Coal Science & Technology*. 2023, vol. 10, article 24. DOI: 10.1007/s40789-023-00581-w.
2. Balovtsev S. V., Skopintseva O. V., Kulikova E. Yu. Analysis of accidents and development trends in aerological safety of coal mines. *MIAB. Mining Inf. Anal. Bull.* 2024, no. 12, pp. 135–149. [In Russ]. DOI: 10.25018/0236_1493_2024_12_0_135.
3. Arhipov I. A., Filin A. E. Accident rate analysis in coal mines in Russia. *MIAB. Mining Inf. Anal. Bull.* 2019, no. 1, pp. 208–215. [In Russ]. DOI: 10.25018/0236-1493-2019-01-0-208-215.
4. Niu Y., Si R., Li Z., Wang L., Huang Z., Jia Q. Experimental study on gas and coal dust explosive overpressure and flame dynamic characteristics in an engineering-level test roadway. *Frontiers in Earth Science*. 2023, vol. 11, article 1330932. DOI: 10.3389/feart.2023.1330932.
5. Skopintseva O. V., Balovtsev S. V., Rybichev A. A. Investigation of the explosion and fire hazard of coal dust in formations of the middle stage of metamorphism. *MIAB. Mining Inf. Anal. Bull.* 2026, no. 5, pp. 80–94. [In Russ]. [In Russ]. DOI: 10.25018/0236_1493_2026_5_0_80.
6. Zhikharev S. Ya., Rodionov V. A., Pikhkonen L. V. Innovative methods for investigating technological properties and explosion/fire risk data of coal dust. *Gornyi Zhurnal*. 2018, no. 6, pp. 45–49. [In Russ]. DOI: 10.17580/gzh.2018.06.09.

7. Babrauskas V., Peacock R. D. Heat release rate: The single most important variable in fire hazard. *Fire Safety Journal*. 1992, vol. 18, no. 3, pp. 255 – 272. DOI: 10.1016/0379-7112(92)90019-9.
8. Salami O. B., Kumar A. R., Aamir I., Pushparaj R. I., Xu G. Enhancing fire safety in underground mines: Experimental and large eddy simulation of temperature attenuation, gas evolution, and bifurcation influence for improved emergency response. *Process Safety and Environmental Protection*. 2024, vol. 183, pp. 260 – 273. DOI: 10.1016/j.psep.2023.12.056.
9. Zhang M., Li Z. Experiments on a mine system subjected to ascensional airflow fire and countermeasures for mine fire control. *Fire*. 2024, vol. 7, no. 7, article 223. DOI: 10.3390/fire7070223.
10. Yuan L., Zhou L., Smith A. C. Modeling carbon monoxide spread in underground mine fires. *Applied Thermal Engineering*. 2016, vol. 100, pp. 1319 – 1326. DOI: 10.1016/j.applthermaleng.2016.03.007.
11. Li B., Li Y., Sun Y., Zhang W., Li J., Zhang Z., Cui Y., Dong J., Liu H. Study on the influence of forced ventilation on the maximum fire temperature in roadway heading. *Scientific Reports*. 2025, vol. 15, article 9830. DOI: 10.1038/s41598-025-94169-w.
12. Kopylov N. P., Fedotkin D. V., Karpov A. V., Sushkina E. Yu. Modeling of extinguishing of oil product fires in the tanks using water-based extinguishing agents. *Occupational Safety in Industry*. 2020, no. 8, pp. 14 – 22. [In Russ]. DOI: 10.24000/0409-2961-2020-8-14-22.
13. Nematollahi Sarvestani A., Oreste P., Gennaro S. Fire scenarios inside a room-and-pillar underground quarry using numerical modeling to define emergency plans. *Applied Sciences*. 2023, vol. 13, no. 7, article 4607. DOI: 10.3390/app13074607.
14. Weisenpacher P., Glasa J., Valasek L. Investigation of various fire dynamics simulator approaches to modelling airflow in road tunnel induced by longitudinal ventilation. *Fire*. 2025, vol. 8, no. 2, article 74. DOI: 10.3390/fire8020074.
15. Fernández-Alaiz F., Castañón A.M., Gómez-Fernández F., Bascompta M. Mine fire behavior under different ventilation conditions: Real-scale tests and CFD modeling. *Applied Sciences*. 2020, vol. 10, no. 10, article 3380. DOI: 10.3390/app10103380.
16. Haghightat A., Luxbacher K. Tenability analysis for improvement of firefighters' performance in a methane fire event at a coal mine working face. *Journal of Fire Sciences*. 2018, vol. 36, no. 3, pp. 256 – 274. DOI: 10.1177/0734904118767066.
17. Ang C. D., Rein G., Peiró J., Harrison R. Simulating longitudinal ventilation flows in long tunnels: Comparison of full CFD and multi-scale modelling approaches in FDS6. *Tunnelling and Underground Space Technology*. 2016, vol. 52, pp. 119 – 126. DOI: 10.1016/j.tust.2015.11.003.
18. Yuan L., Mainiero R. J., Rowland J. H., Thomas R. A., Smith A. C. Numerical and experimental study on flame spread over conveyor belts in a large-scale tunnel. *Journal of Loss Prevention in the Process Industries*. 2014, vol. 30, pp. 55 – 62. DOI: 10.1016/j.jlp.2014.05.001.
19. Tan P., Zhang C., Xia J., Fang Q.-Y., Chen G. Estimation of higher heating value of coal based on proximate analysis using support vector regression. *Fuel Processing Technology*. 2015, vol. 138, pp. 298 – 304. DOI: 10.1016/j.fuproc.2015.06.013.
20. Mowrer F. W., Williamson R. B. Methods to characterize heat release rate data. *Fire Safety Journal*. 1990, vol. 16, no. 5, pp. 367 – 387. DOI: 10.1016/0379-7112(90)90009-4.
21. Ingason H. Design fire curves for tunnels. *Fire Safety Journal*. 2009, vol. 44, no. 2, pp. 259 – 265. DOI: 10.1016/j.firesaf.2008.06.009.
22. Dubey S. R., Singh S. K., Chaudhuri B. B. Activation functions in deep learning: A comprehensive survey and benchmark. *Neurocomputing*. 2022, vol. 503, pp. 92 – 108. DOI: 10.1016/j.neucom.2022.06.111.
23. Kapoor S., Narayanan A. Leakage and the reproducibility crisis in machine-learning-based science. *Patterns*. 2023, vol. 4, no. 9, article 100804. DOI: 10.1016/j.patter.2023.100804.

ИНФОРМАЦИЯ ОБ АВТОРЕ

Федоткин Илья Олегович – аспирант, Университет науки и технологий МИСИС, e-mail: fedotkin.iliya@gmail.com, ORCID ID: 0009-0004-2399-480X.

INFORMATION ABOUT THE AUTHOR

I.O. Fedotkin, Graduate Student, University of Science and Technology MISIS, 119049, Moscow, Russia, e-mail: fedotkin.iliya@gmail.com, ORCID ID: 0009-0004-2399-480X.

Получена редакцией 14.04.2026; получена после рецензии 16.05.2026; принята к печати 10.07.2026.
Received by the editors 14.04.2026; received after the review 16.05.2026; accepted for printing 10.07.2026.