

Система мониторинга и прогнозирования пожароопасных состояний мест размещения и накопления твердых коммунальных отходов при их захоронении и транспортировке

Людмила Анатольевна Королева^{1,2}✉, Андрей Геннадьевич Хайдаров³

¹ Санкт-Петербургский университет Государственной противопожарной службы Министерства Российской Федерации по делам гражданской обороны, чрезвычайным ситуациям и ликвидации последствий стихийных бедствий имени Героя Российской Федерации генерала армии Е.Н. Зиничева, г. Санкт-Петербург, Россия

² Институт проблем транспорта им. Н.С. Соломенко Российской академии наук, г. Санкт-Петербург, Россия

³ ООО «Аналитические системы», г. Санкт-Петербург, Россия

АННОТАЦИЯ

Введение. Пожары на объектах размещения и накопления твердых коммунальных отходов (ТКО) при их захоронении и транспортировке возникают с достаточной регулярностью. В настоящее время они практически не прогнозируются. Их обнаружение в большинстве случаев происходит, когда горение распространилось на значительные площади.

Цель и задачи. Разработка системы мониторинга и прогнозирования состояния мест размещения и накопления ТКО, позволяющей обнаруживать очаги горения, прогнозировать динамику изменения ключевых параметров и давать оценку пожарной опасности рассматриваемых объектов.

Материалы и методы. Проведен сравнительный анализ систем мониторинга мест размещения и накопления ТКО. Доказано, что наиболее перспективными для предупреждения возникновения пожароопасных ситуаций на рассматриваемых объектах являются методы прогнозирования с помощью искусственных нейронных сетей и машинного обучения. Определены этапы рабочего процесса при реализации технологии машинного обучения.

Результаты. Разработана система показателей для оценки пожароопасных состояний мест размещения и накопления отходов. Создана модель, позволяющая на основе полученных с датчиков данных прогнозировать динамику изменения ключевых параметров и давать оценку пожарной опасности мест размещения и накопления отходов с учетом выбранного горизонта планирования. Определены требования к модели, выполняемые задачи, проведены сбор и очистка данных, маркировка, конструирование признаков. Проведено обучение модели и ее оценка. Обоснован метод обнаружения аномалий на основе обучения без учителя.

Разработана модель, позволяющая на основе полученных с датчиков данных обнаруживать очаги горения, в том числе скрытые, с указанием их местоположения и границ. Представлены характеристики основных сценариев, определяющих структуру и использование сервиса «Умный полигон». Разработана его архитектура. Обоснованы преимущества использования. Проведено тестирование разработанных моделей.

Выводы. Применение сервиса «Умный полигон» позволит визуализировать информацию о состоянии мест захоронения отходов и результатах прогнозирования; сформировать отчет по полигону за выбранный период; осуществлять своевременное оповещение и передачу необходимой информации о возможности или возникновении горения; выбирать наилучшие решения, направленные на минимизацию пожарного риска и проводить контроль их эффективности.

Результаты проведенного исследования войдут в качестве модуля в состав комплексной платформы для риск-ориентированного прогнозирования, снижения экологической и пожарной опасности мест размещения и накопления ТКО.

Ключевые слова: полигон; свалка; горение; машинное обучение; модель; искусственная нейронная сеть; сервис «Умный полигон»; платформа

Для цитирования: Королева Л.А., Хайдаров А.Г. Система мониторинга и прогнозирования пожароопасных состояний мест размещения и накопления твердых коммунальных отходов при их захоронении и транспортировке // Пожаровзрывобезопасность/Fire and Explosion Safety. 2024. Т. 33. № 4. С. 52–68. DOI: 10.22227/0869-7493.2024.33.04.52-68

✉ Королева Людмила Анатольевна, e-mail: lyudamil@mail.ru

System of monitoring and predicting of fire hazardous conditions of municipal solid waste disposal and accumulation sites during their disposal and transportation

Lyudmila A. Koroleva^{1,2}✉, Andrey G. Khaydarov³

¹ Saint-Petersburg University of State Fire Service of the Ministry of the Russian Federation for Civil Defense, Emergencies and Elimination on Consequences of Natural Disasters named after Hero of the Russian Federation, Army General E.N. Zinichev, Saint Petersburg, Russian Federation

² Solomenko Institute of Transport Problems of the Russian Academy of Sciences, Saint Petersburg, Russian Federation

³ Limited Liability Company "Analytical systems", Saint Petersburg, Russian Federation

ABSTRACT

Introduction. Fires at disposal and accumulation sites of municipal solid waste (MSW) during their disposal and transportation occur with sufficient regularity. At present, they are practically not predicted. Their detection in many cases occurs when the burning has spread over significant areas.

Aims and objectives. The aim of the work is to develop a system of monitoring and forecasting of conditions of places of disposal and accumulation of MSW that enables to detect burning areas, to forecast the dynamics of changes in key parameters and to assess fire danger of the objects in question.

Materials and methods. A comparative analysis of monitoring systems for places of disposal and accumulation of MSW was made. It is proved that forecasting methods based on artificial neural networks and machine learning are the most promising for preventing fire-hazardous situations at the examined objects. The stages of the working process in the implementation of machine learning technology are defined.

Results. A system of indicators for assessing the fire hazardous conditions of waste disposal and accumulation sites is developed. A model allowing to forecast the dynamics of change of key parameters and to give an assessment of fire hazard of waste disposal and accumulation sites taking into account the chosen planning horizon on the basis of the data received from sensors is created. The requirements for the model, the tasks to be performed were determined, data gathering and cleaning, labelling, design of attributes were performed. The model was trained and evaluated. A method of anomaly detection based on teacherless learning was justified.

A model was developed that allows detecting combustion spots, including hidden ones, with indication of their location and boundaries, based on the data received from sensors. Characteristics of the main scenarios determining the structure and use of the Smart Site service are presented. Its architecture is described. Benefits of its usage are proved. The developed models are tested.

Conclusion. The application of the "Smart Polygon" service will enable visualization of information about the state of waste disposal sites and forecasting results; generate a report for the polygon for a selected period; provide timely notification and transfer necessary information about the possibility or occurrence of fires; select the best solutions aimed at minimizing fire risk and monitor their effectiveness.

The results of the study will be included as a module in an integrated platform for risk-oriented forecasting, reduction of environmental and fire hazard of disposal sites and accumulation of solid waste.

Keywords: polygon; combustion; machine learning; model; artificial neural network; "Smart Polygon" service; platform

For citation: Koroleva L.A., Khaydarov A.G. System of monitoring and predicting of fire hazardous conditions of municipal solid waste disposal and accumulation sites during their disposal and transportation. *Pozharovzryvobezopasnost/Fire and Explosion Safety*. 2024; 33(4):52-68. DOI: 10.22227/0869-7493.2024.33.04.52-68 (rus).

✉ Lyudmila Anatolyevna Koroleva, e-mail: lyudamil@mail.ru

Введение

Обращение с твердыми коммунальными отходами (ТКО) является глобальной проблемой, не решенной в Российской Федерации (РФ) и большинстве стран мирового сообщества [1–3]. Проводимая в нашей стране реформа в сфере обращения с отходами «не принесла ожидаемых результатов», ситуация с полигонами «близка к критической», около 90 % мусора вывозится на захоронение, полигоны в крупных городах переполнены, растет количество и размеры несанкционированных свалок [4]. Огромное количество ТКО нуждаются в транспортировке, утилизации и захоронении.

Полигоны и свалки ТКО, площадки накопления мусора при транспортировке большегрузным транспортом (далее — места размещения и накопления отходов) относятся к объектам повышенной пожарной опасности. По официальной статистике [5], пожары на рассматриваемых объектах составляют около 14 % от общего количества пожаров, происходящих в РФ. На их локализацию и ликвидацию привлекается значительное количество сил и средств, тушение может осуществляться в течение длительного времени (дни, недели, месяцы). Пожары в местах накопления и размещения ТКО приводят к значительным негативным последствиям для окружающей среды и здоровья

населения, сопровождаются большим материальным ущербом.

Обнаружение подземных тлеющих пожаров в большинстве случаев происходит, когда реакция горения уже началась и пожар распространился на значительные площади. На сегодняшний день пожары в местах накопления и размещения ТКО практически не прогнозируются.

В настоящее время активно изучаются вопросы, связанные с возможностью идентифицировать горение по изменению, например, температуры, концентраций кислорода, угарного и углекислого газов, метана^{1, 2} [6–10]. Следует, однако, принять во внимание, что происходящие в местах размещения и накопления отходов физико-химические и биологические процессы не могут учитываться отдельно друг от друга. Например, только по изменению концентрации углекислого газа не представляется возможным сделать заключение о возникновении подземного пожара. Создание эффективной системы мониторинга и прогнозирования должно базироваться на системном подходе, в рамках которого «взаимозависимые события», происходящие на полигоне, «должны рассматриваться одновременно» [11].

Актуальным является развитие технологий мониторинга и прогнозирования состояния мест размещения и накопления отходов, применение которых позволит предотвращать пожары, обеспечивать возможность их тушения на ранней стадии.

Цель работы заключается в разработке системы мониторинга и прогнозирования состояния мест размещения и накопления ТКО, позволяющей обнаруживать очаги горения, прогнозировать динамику изменения ключевых параметров и давать оценку пожарной опасности рассматриваемых объектов.

Для достижения поставленной цели в работе решены следующие **задачи**:

- проведен сравнительный анализ систем мониторинга мест размещения и накопления ТКО;
- обоснована система показателей для оценки их пожароопасных состояний;
- разработана модель, позволяющая прогнозировать динамику изменения ключевых параметров и давать оценку пожарной опасности мест размещения и захоронения отходов с учетом выбранного горизонта планирования;
- разработана модель, позволяющая обнаруживать очаги горения, в том числе скрытые, с указанием их местоположения и границ;

¹ *Copping S., Quinn C., Gregory R.* Review and Investigation of deep-seated fires within landfill sites. Environment Agency, 2007. URL: www.environment-agency.gov.uk (дата обращения: 08.09.23).

² *Mogbel S.* Characterizing Spontaneous Fires In Landfills. Ph.D. Thesis. USA : University of Central Florida, Orlando, 2009. URL: <https://stars.library.ucf.edu/etd/3855/> (дата обращения: 20.08.2022).

- проведено тестирование разработанных моделей и определены перспективы их использования.

Материалы и методы

Проведенный сравнительный анализ систем мониторинга мест размещения и накопления ТКО обусловил выбор методов и моделей. Были рассмотрены реализованные решения, среди которых: система автоматического контроля загазованности полигона ТКО (Инновационная промышленная группа компаний «СервисСофт», Российская Федерация (РФ)); система непрерывного мониторинга выбросов полигонов Landfill Continuous Emissions Monitoring System (компания Los Gatos Research, США); интеллектуальная тепловизионная камера Wastack (Канада); система диспетчерского управления и сбора данных Supervisory Control And Data Acquisition (SCADA) для системы откачки фильтра полигона (Systems Group Technologies, США); система удаленного мониторинга и управления SCS RMC (SCS Remote Monitoring and Control at Landfills, США); беспилотная авиационная система (БАС) для обнаружения и количественной оценки наземных утечек метана (SnifferDron, Sniffer Robotics, США); система видеомониторинга объектов VIDEOMATIC (группа компаний «Индустрия света», РФ).

Среди находящихся в стадии разработки наиболее перспективными, по нашей оценке, являются: комплексная система мониторинга состояния полигонов отходов для минимизации экологических рисков [12]; система оценки выбросов метана со свалки с использованием беспилотных авиационных систем и полупроводниковых датчиков [13].

Общими недостатками рассмотренных систем являются отсутствие функций прогнозирования возникновения, развития пожара в местах размещения и накопления отходов и поддержки принятия решений, направленных на предотвращение и тушение пожаров. Возможность подключения к системе группы полигонов в большинстве случаев не предусмотрена. Отсутствует функция визуализации полученной информации.

Проведенная оценка применимости различных методов [14], позволяющих реализовать системный подход и совместно учитывать температуру, свойства ТКО и происходящие в теле полигона процессы для прогнозирования пожароопасных ситуаций в местах размещения и накопления ТКО, позволила обосновать следующие выводы:

- методы, использующие линейные модели, не отличаются точностью, не позволяют исследовать всю совокупность происходящих процессов, что существенно ограничивает их применение для оценки процессов самовозгорания в местах размещения и накопления ТКО;



Рис. 1. Этапы рабочего процесса машинного обучения [16]

Fig. 1. Stages of the machine learning workflow [16]

Таблица 1. Система показателей для оценки пожароопасных состояний мест размещения и накопления отходов
Table 1. Indicator system for assessing fire hazardous states of waste disposal and accumulation sites

Зона Zone	Температура, °C Temperature, °C		[CH ₄]/ [CO ₂]	[CO], Ppmv	[O ₂], % об. [O ₂], % vol.	[N ₂], % об. [N ₂], % vol.	Примечание Note
	В устье скважины At the wellhead	В теле полигона In the body of the landfill					
Аэробное разложение Aerobic decomposition	< 80	≤ 90	–	–	> 2	78	Является исходным для мест накопления отходов It is the starting point for places of accumulation of waste
Анаэробное разложение Anaerobic decomposition	< 65	≤ 80	≥ 1	< 20	< 1,5	< 5	Нормальная эксплуатация полигона Normal operation of the polygon
Газовый фронт Gas front	40–55	50–70	1,0–0,8	0–400	> 1	5–15	Область повышенной температуры может длительное время быть неподвижной. Изменения происходят при проникновении воздуха либо наличия другого триггера The area of increased temperature can be stationary for an extended period. Changes occur upon the penetration of air or the presence of another trigger
Температурный фронт Temperature front	50–55	65–75	0,8–0,6	400–800	> 1	5–15	Повышению температуры предшествует уменьшение соотношения [CH ₄]/[CO ₂] до 0,3 An increase in temperature is preceded by a reduction in the [CH ₄]/[CO ₂] ratio to 0.3
	55–65	70–85	0,6–0,1	800–1200	> 1		
	65–90	80–110	< 0,1	1200–1500	> 1		
Фронт тления Smoldering front	> 65	> 80	< 0,2	≥ 1500	0,7–3,3	> 15	Измерение подповерхностных температур затруднено Measurement of subsurface temperatures is difficult
Зона пиролиза Pyrolysis zone	≥ 170	≥ 190	< 0,1	≥ 1000	0,7–11,0	–	Возможно протекание эндотермических процессов Endothermic processes may occur
Зона горения Combustion zone	≥ 170	≥ 190; рост во времени ≥ 190; growth over time	< 0,1	≥ 1000	0,7–11,0	> 15	Величина скорости изменения температуры определяет различия между горением и пиролизом The rate of temperature change determines the differences between combustion and pyrolysis

- метод конечных элементов имеет ряд существенных ограничений: влияние выбора сетки конечных элементов на результаты расчета температурных полей и сложность оценки точности результатов. Метод не позволяет учитывать уникальность объектов;
- наиболее перспективными являются методы прогнозирования с помощью искусственных нейронных сетей и машинного обучения, что подтверждается рядом отечественных и зарубежных исследований [12, 15].

Так, в работе [15] представлена модель искусственной нейронной сети для моделирования и прогнозирования температур поверхности свалки, основанная на использовании спутниковых снимков. Эффективность ее применения подтверждается достаточно высокими коэффициентами корреляции, полученными в процессе валидации искусственной нейронной сети. Однако такие модели для мониторинга и прогнозирования подземных пожаров как в РФ, так и за рубежом отсутствуют.

Представленный сравнительный анализ подтверждает необходимость создания систем мониторинга и прогнозирования мест размещения и накопления отходов. Перспективным направлением является применение методов искусственного интеллекта с использованием облачных технологий.

Для выполнения задачи предсказания ключевых параметров была разработана платформа, этапы рабочего процесса которой представлены на рис. 1.

В основе системы лежит итеративный процесс с обратными связями, которые предполагают экспериментирование с различными подходами в рамках ключевых этапов. На основе результатов экспериментов применения различных техник обеспечивается инкрементальное улучшение показателей модели.

На основании литературных данных [6–10, 17–23], была обоснована система показателей, оценка которых позволяет определять возможность возникновения и развития горения (табл. 1). В работе [14] представлены их референтные значения, поддающиеся измерению и контролю.

Рассматриваемые показатели были учтены в разрабатываемых моделях.

Результаты и их обсуждение

1. Разработка модели, позволяющей на основе полученных с датчиков данных прогнозировать динамику изменения ключевых параметров и давать оценку пожарной опасности мест размещения и накопления отходов с учетом выбранного горизонта планирования

Постановка задачи. Необходимо на основе характеризующих процесс биодеградаций отходов

данных, полученных с установленных на полигоне датчиков, предсказать ключевые параметры для заданного временного горизонта. Задача разрабатываемой модели заключается в предсказании температуры и массовых долей газов (табл. 2).

В качестве входных признаков модели действуют значения рассмотренных параметров за предшествующий временной период заданной длительности и координаты X и Y , определяющие положение точки полигона относительно шахты и дна полигона соответственно. Используемая модель полигона представлена на рис. 2.

Для оценки качества модели применены средняя абсолютная ошибка (англ. Mean Absolute Error, далее MAE):

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n},$$

и средняя квадратичная ошибка (англ. Mean Squared Error, далее MSE):

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n},$$

где y_i — это истинное (измеренное) значение параметра образца i ;

\hat{y}_i — оценочное значение параметра на основе модели;

n — количество образцов в выборке.

Таблица 2. Параметры процесса
Table 2. Process Parameters

Обозначение Designation	Наименование Name	Единица измерения Unit of Measurement
Q_10	Объемный расход жидкости Liquid Flow Rate	м ³ /с m ³ /s
Q_g0	Объемный расход газа Gas Flow Rate	м ³ /с m ³ /s
T	Температура Temperature	°C
w_CH ₄	Массовая доля метана Methane Mass Fraction	Безразмерный Dimensionless
w_CO ₂	Массовая доля углекислого газа Carbon Dioxide Mass Fraction	Безразмерный Dimensionless
w_N ₂	Массовая доля азота Nitrogen Mass Fraction	Безразмерный Dimensionless
w_O ₂	Массовая доля кислорода Oxygen MaFraction	Безразмерный Dimensionless

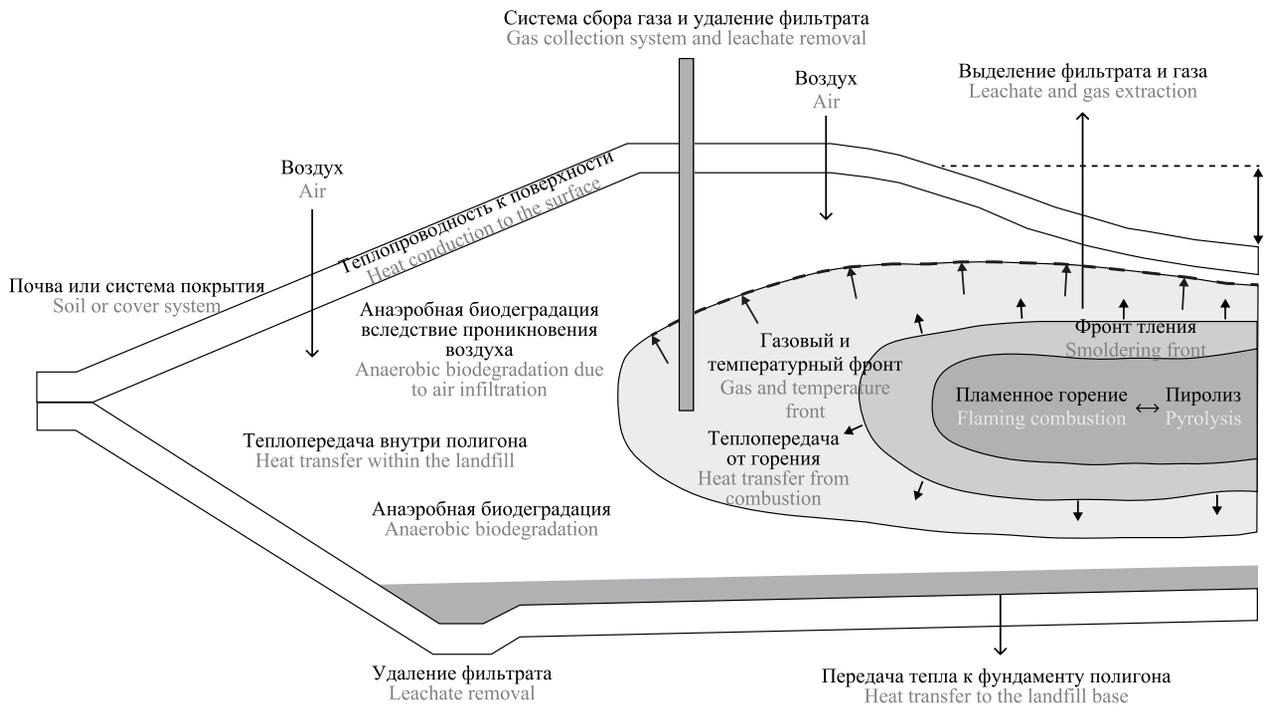


Рис. 2. Схематическое изображение геометрической модели полигона, используемой для генерации данных [24]
Fig. 2. Schematic representation of the geometric polygon model used for data generation [24]

Сбор данных. В связи с отсутствием реальных данных использовали синтетические данные, сгенерированные с помощью симуляции полигона на основе метода конечных элементов, что позволило получить параметры процесса, разрешенные в пространстве и времени. При этом для каждой уникальной комбинации расходов жидкости и газа была выполнена отдельная симуляция длительностью 1300 часов с шагом в 10 часов.

Параметры полигона были сэмплированы во времени с шагом в 10 часов и в пространстве полигона с шагом 1 м для каждой из координат, что позволило получить 900 временных рядов протяженностью 131 точек каждый. Полученные данные экспортированы из среды для симуляции Comsol в нейтральный формат csv и в дальнейшем импортированы в Python в форме Pandas Dataframe.

Для определения регрессоров построена корреляционная матрица (рис. 3), анализ которой показал, что все параметры процесса оказывают ненулевое влияние на температуру и массовые доли газов.

Определено, что объемный расход жидкости оказывает значимое влияние только на температуру. Если положение точки измерения относительно горизонтального расстояния до шахты оказывает существенное влияние на температуру и массовые доли, то вертикальная координата слабо коррелирует с изучаемыми параметрами. Также можно отметить, что массовые доли являются сильно зависимыми величинами. Такое поведение можно объяснить исполь-

зуемой в симуляции кинетической моделью. Данная информация может быть применена для дальнейшего упрощения модели.

Использованный сценарий для генерирования синтетических данных позволяет получить только данные, описывающие идеальное поведение системы с учетом всех упрощений используемой модели. Тем не менее данный подход обеспечивает генерацию практически неограниченного контингента данных, в том числе данных для редких сценариев.

На реальном полигоне может быть установлено несколько датчиков для измерения одного параметра, например температуры. При этом измерение других

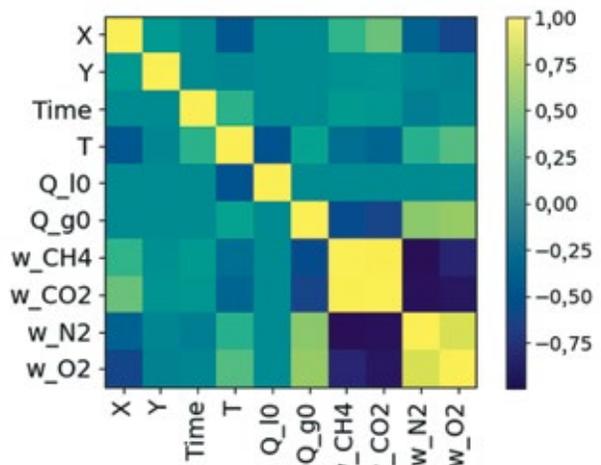


Рис. 3. Корреляционная матрица
Fig. 3. Correlation matrix

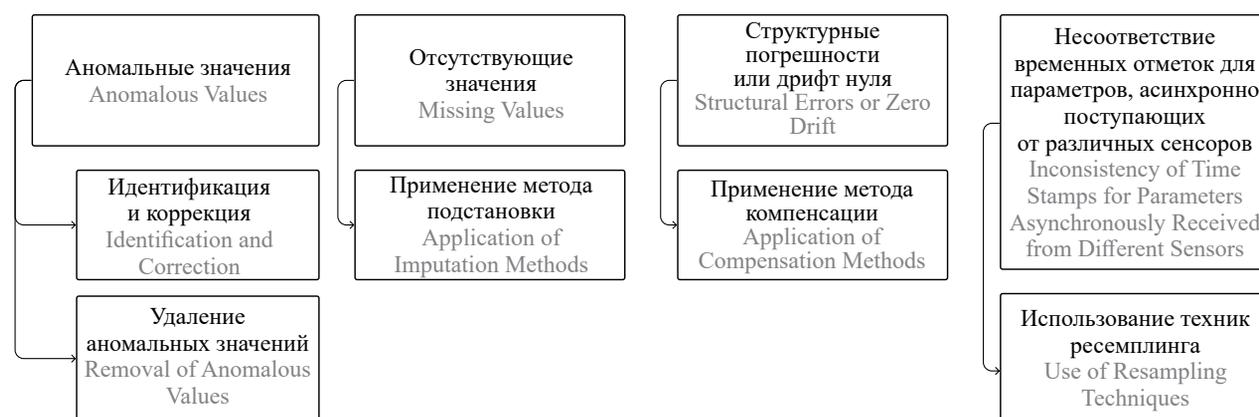


Рис. 4. Меры по устранению ошибок

Fig. 4. Error correction measures

параметров, таких как концентрации, может производиться в других точках полигона. В этом случае может быть построена многомерная интерполяционная модель (например, бикубическая) для получения отсутствующих значений в интересующих точках полигона.

Очистка данных. В связи с тем, что данные являются синтетическим, то необходимость в исправлении дефектов отпадает. Тем не менее при поступлении реальных данных с датчиков, установленных в местах размещения и накопления отходов, необходимо принять меры по устранению ошибок (рис. 4).

Маркировка данных. В случае с синтетическими данными целевые значения получены напрямую из симуляции и не требуют дальнейшей подготовки. При работе с реальными данными с полигонов потребуются работа с газоанализаторами. При этом из-за сильной корреляции между массовыми долями компонентов газа можно будет рассмотреть возможность использования софт сенсоров для оценки массовых долей одного, двух или трех газов в зависимости от концентрации остальных. Таким образом можно снизить требования к системе за счет снижения стоимости оборудования.

Конструирование признаков. В качестве входа в модель ожидаются временные ряды всех ключевых параметров, а также отдельных значений координат и расходов жидкости и газа. На выходе ожидаются предсказанные временные ряды для ключевых параметров. На основе требований к модели из общей выборки сформированы отдельные образцы данных размерностью n на 9, где n указывает на длину временного ряда, используемого для предсказаний, а 9 — это общее количество исходных признаков. Для упрощения формирования датасета координаты в каждом образце дублируются для каждой из точки во времени. Объемные расходы жидкости и газа принимаются как значения, которые могут быть изменены. Для каждого исходного образца формируется также вектор целевых значений размерностью m на 5, где m — это горизонт

предсказаний, а 5 указывает на количество признаков для предсказания. Формирование вектора исходных и выходных данных осуществляется методом скользящего, что позволяет гарантировать их соответствие. За счет минимального единичного смещения генерируется максимально возможное количество образцов для обучения модели. Ко всем признакам применена минимакс нормализация для равномерного их масштабирования.

Обучение модели. В связи с тем, что реальные данные с полигонов ожидаются со значительно более сложными зависимостями, чем в синтетических данных, в качестве типа модели выбраны полносвязные нейронные сети прямого распространения, что обусловлено универсальностью и гибкостью модели. В качестве исходных данных могут подаваться как временные ряды [25] (хотя и в качестве отдельных значений), так и глобальные параметры. Это могут быть, например, геометрические параметры полигона или его характеристики, которые оказывают влияние на динамику процесса. В качестве архитектуры испробованы архитектуры от одного до семи слоев с шагом в 2. Каждый промежуточный слой содержит от 4 до 32 нейронов с промежуточными значениями равными степенями двойки. В дальнейшем архитектура модели может быть расширена за счет добавления дополнительных слоев, а модель может быть дообучена или переобучена посредством методов transfer learning. При этом требуемое количество данных для переобучения модели для работы на другом полигон значительно ниже, чем если обучать модель с нуля.

В качестве решателя взят Adam, целевая функция MSE, размер batch составляет 512 образцов. Обучение производится до 1000 эпох или при отсутствии улучшений значений MSE на тестовой выборке в течение 20 эпох, что наступит раньше. Коэффициент обучения постоянный и равен $1e^{-4}$.

Для определения оптимальных значений гиперпараметров проведено полнофакторное исследо-

Таблица 3. Гиперпараметры и их значения
Table 3. Hyperparameters and their values

Гиперпараметр Hyperparameter	Значения Values
Скорость обучения Learning Rate	$1e^{-4}$
Количество скрытых слоев Number of Hidden Layers	1, 3, 5, 7
Количество нейронов на скрытый слой Number of Neurons per Hidden Layer	4, 8, 16, 32
Длина исходных образцов Length of Input Samples	10, 20, 30, 40
Горизонт предсказаний Prediction Horiz	5, 10, 20, 40

вание зависимости ключевых метрик от значений гиперпараметров (табл. 3).

Переобучение моделей было минимизировано за счет использования метода *early stopping*. Анализ кривых обучения показал, что все эксперименты имеют признаки конвергенции к решению.

Оценка модели. Для оценки модели создана тестовая выборка. Для этого из датасета случайно выбраны 33 % образцов, которые также исключены из обучающей выборки. Для оценки модели использованы метрики MAE и MSE, рассчитанные на тестовой выборке. Результаты показали:

- низкая разность между значениями целевой функции на обучающих и тестовых выборках для всех моделей указывает на отсутствие переобучения;
- длительность временного ряда на входе модели оказывает в целом положительное влияние на качество предсказаний. Тем не менее модели

с длительностью входных временных рядов в 10 точек также входят в десятку лучших моделей;

- увеличение количества скрытых слоев не оказывает положительного влияния. Модели с одним скрытым слоем показывают лучшие результаты;
- с другой стороны, большее количество нейронов на слой приводит к более высокой точности предсказаний;
- все модели представляют хорошие результаты при горизонте предсказаний как 5, так и 10 шагов вперед. При горизонте предсказаний 20 и более точность падает.

Для оценки наличия систематических ошибок распределение остаточных невязок представлено в виде гистограмм (рис. 5). Остаточные невязки лежат в интервале от среднего значения для температуры и около для доли метана.

Также отобразим предсказание для образца с минимальным и максимальным значениями MSE для всех параметров (рис. 6).

В ходе детального анализа модели можно заметить колебания значений, однако их диапазон очень мал.

Приведенная выше модель предсказывает значения ключевых параметров мест размещения и накопления отходов.

Задачу обнаружения и локализации очагов горения с использованием методов машинного обучения можно рассмотреть как задачу обнаружения аномалий (*anomaly detection*) и использовать метод для обнаружения аномалий на основе обучения без учителя [26].

В ходе текущего этапа проекта был опробован инструмент для визуализации аномалий *ruplot*. Для этого были сгенерированы синтетические данные со

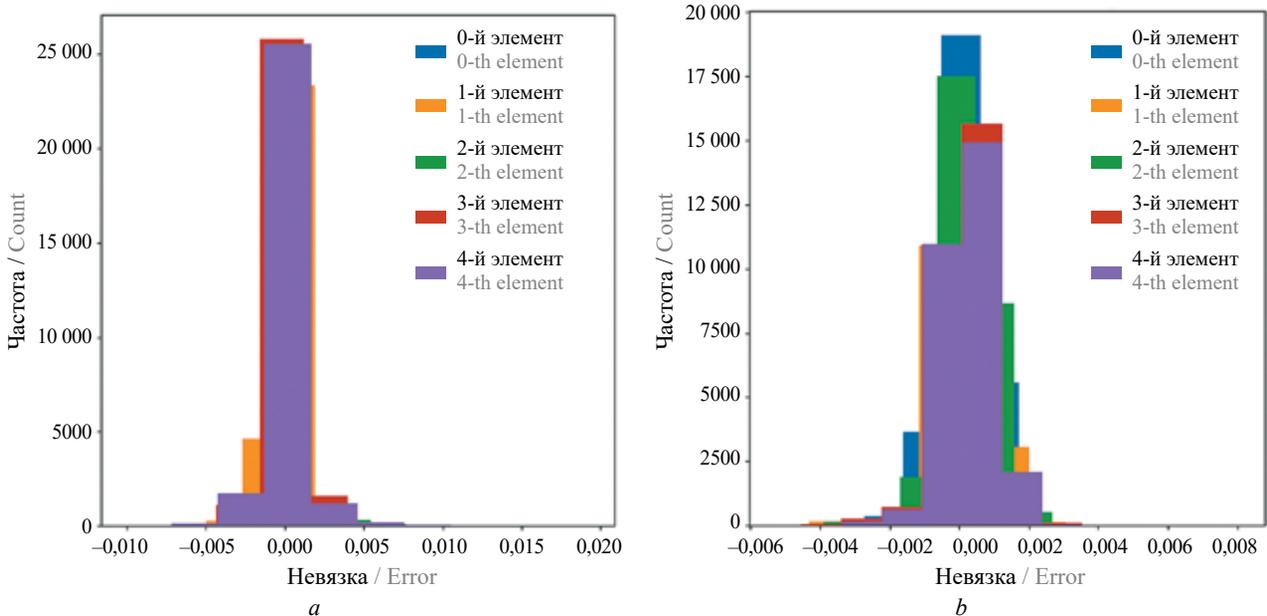


Рис. 5. Распределение остаточных невязок для доли метана (a) и температуры (b)
Fig. 5. Distribution of residual deviations for methane proportion (a) and temperature (b)

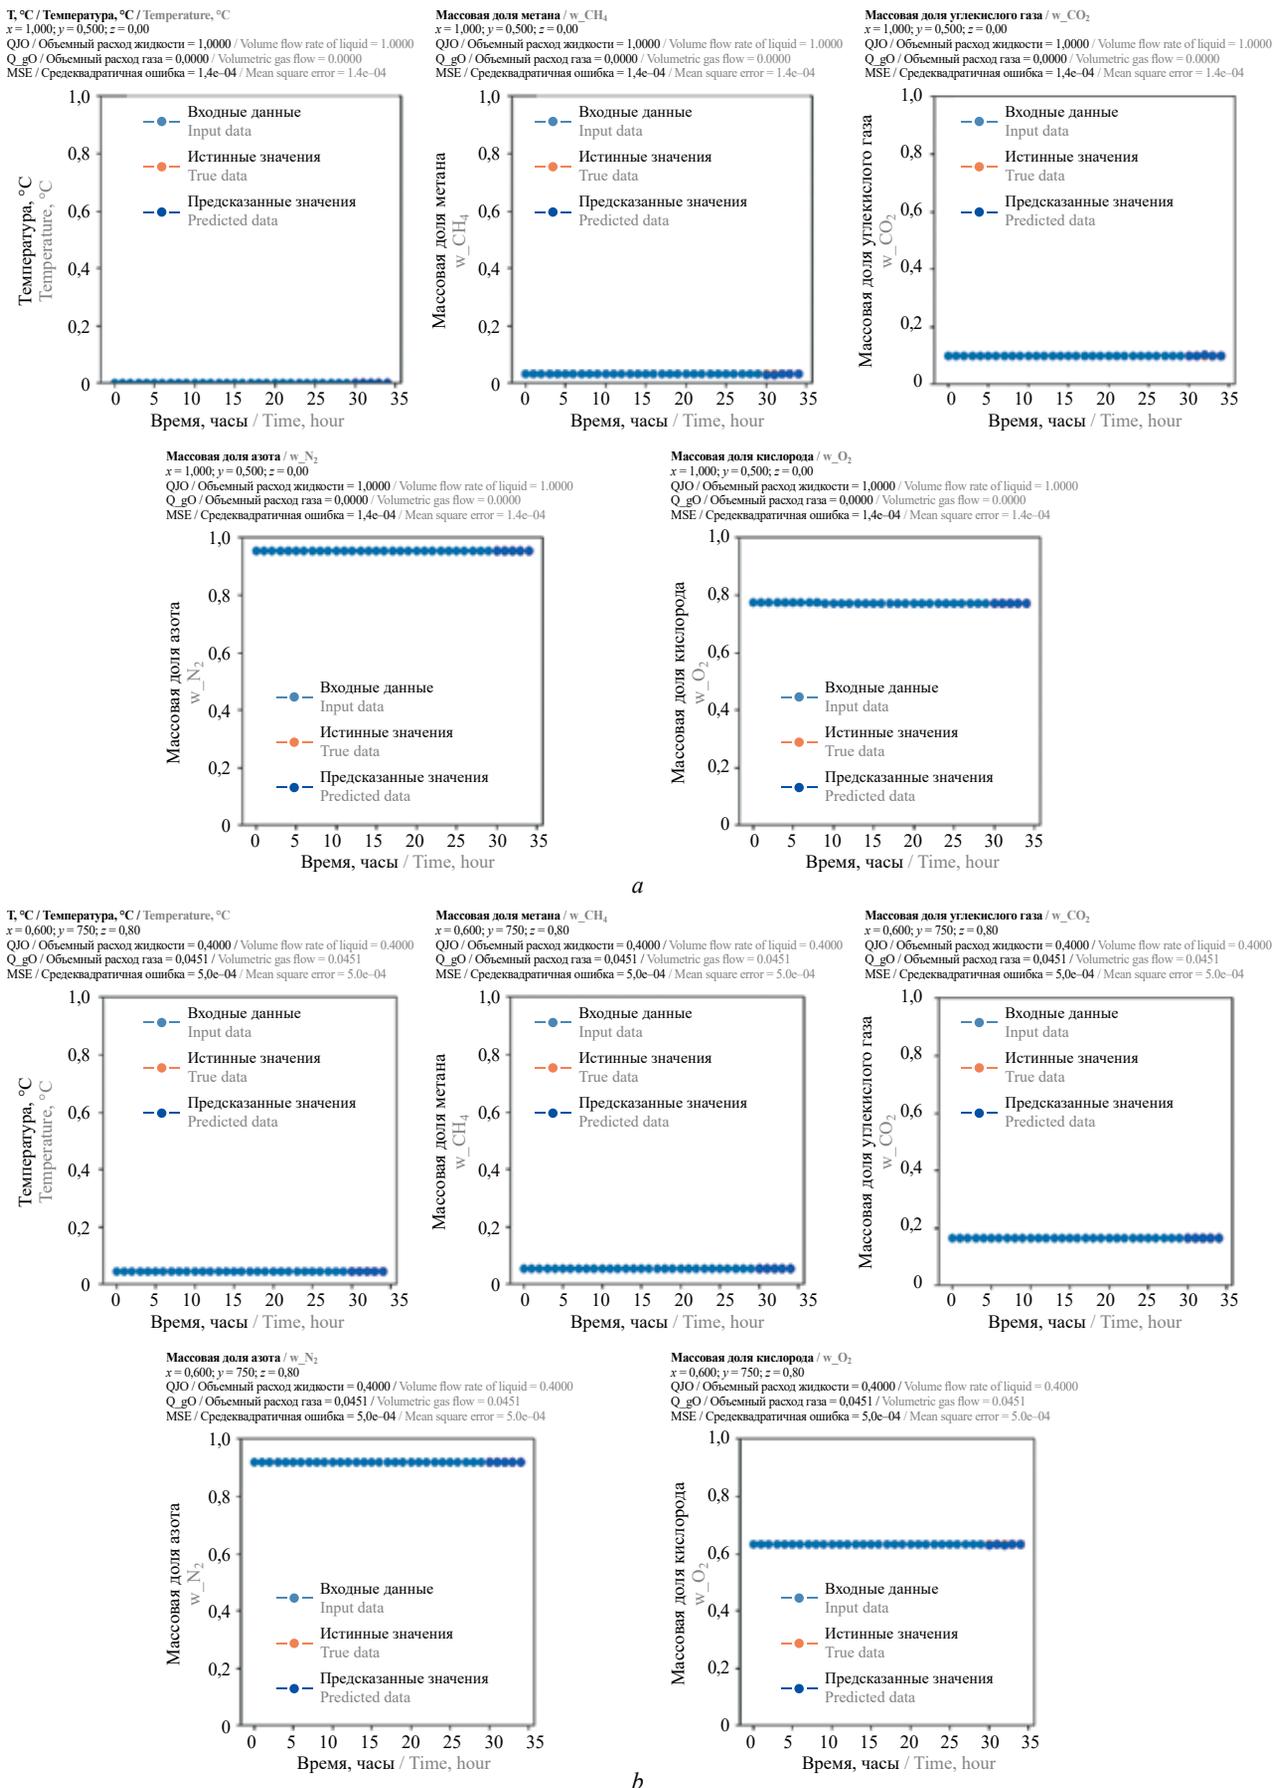


Рис. 6. Выбранные тестовые ряды с минимальным (а) и максимальным (б) значениями метрики MSE
 Fig. 6. Selected test series with minimum (a) and maximum (b) MSE metric values

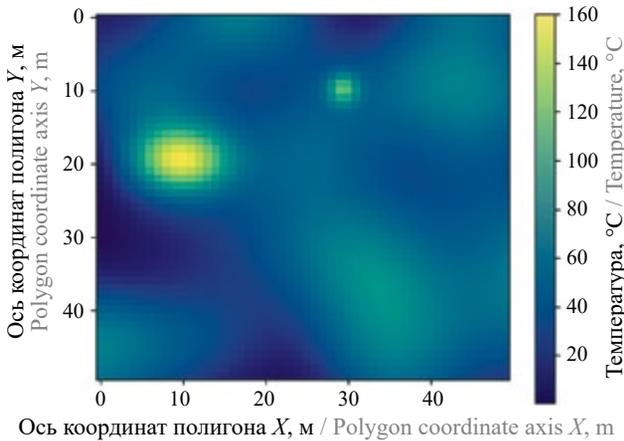


Рис. 7. Пример интерполированных данных
Fig. 7. Example of interpolated data

случайной простановкой аномалий. На рис. 7 представлено одно сечение трехмерного поля температур.

Данные считываются из базы данных и пропускаются через детектор аномалий. Детектор указывает на позицию аномалий. Результаты работы прототипа приведены на рис. 8. Визуализация представляет собой трехмерное поле температур полигона. Оранжево-желтые области обозначают регионы с аномально высокой температурой, которые локализируются детектором аномалий. Координаты аномалий отображаются в виде точек в визуализации, а также в виде таблицы под графиком.

Интеграция визуализаций, созданных с помощью инструмента ruyplot, осуществляется с помощью open-source инструмента dash. Dash создает flask webserver, который содержит созданную визуализацию и может быть встроен в веб-приложение или веб-страницу в качестве iframe.

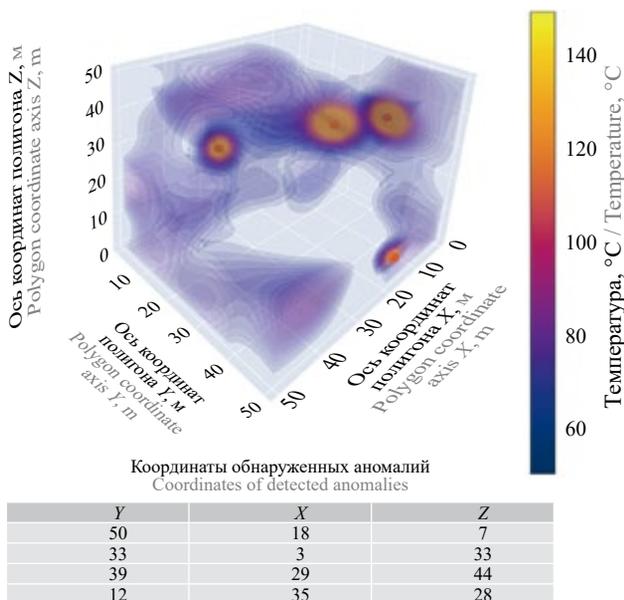


Рис. 8. Результат работы прототипа по обнаружению аномалий
Fig. 8. The result of the prototype's anomaly detection performance

2. Создание модели, позволяющей на основе полученных с датчиков данных обнаруживать очаги горения, в том числе скрытые, с указанием их местоположения и границ

Сценарии использования и архитектурное решение. Использование сервиса «Умный полигон» предусматривает три основных сценария использования, которые определяют архитектуру сервиса.

В рамках первого сценария происходит только сбор данных с датчиков, установленных в местах размещения и накопления ТКО. Датчики влажности и температуры, газоанализаторы снабжены нативным функционалом для записи данных в буфер и их периодической отправки в централизованную базу данных, развернутую в облаке. Рассматриваемое решение обеспечивает отказоустойчивость и децентрализацию всей системы. Например, в случае возникновения ошибки при сборе или передаче данных с одного датчика остальные продолжают работать без перебоев.

Реализация второго сценария заключается в предоставлении клиенту API сервиса для выполнения предсказаний по ключевым параметрам и оценке класса пожарной опасности мест размещения и накопления ТКО. Доступ API осуществляется посредством GET запросов, при которых клиент отправляет последние значения со своих датчиков. В качестве ответа формируются предсказания от сервиса. В теле запроса помимо данных клиент также указывает дополнительные параметры, такие как API ключ для идентификации клиента и идентификатор модели. Использование последнего позволяет не только обеспечивать версионирование моделей для клиентов, но и доступ к моделям, которые были обучены специально для выбранного полигона. Предоставление API на основе распространенного RestAPI интерфейса позволяет интегрировать сервис с клиентскими приложениями вне зависимости от системы и языка программирования.

Третий сценарий использования сервиса позволяет еще значительно сделать сервис более доступным для пользователей. При этом предоставляется веб-приложение для визуализации исторических данных, данных реального времени (периодическое обновление данных из базы данных для необработанных данных), а также предсказанных ключевых параметров и оценки класса пожарной опасности. Это позволяет клиенту получить доступ к основному функционалу сервиса прямо «из коробки».

Техническая сторона сервиса реализована на облачной бессерверной архитектуре, использование которой позволяет повысить отказоустойчивость, обеспечить высокий уровень масштабирования и удобство для пользователей, так как API и веб-приложение доступны напрямую через сеть интер-

нет. Для сбора необработанных данных используется нереляционная база данных для временных рядов InfluxDB, которая обеспечивает высокую плотность запросов по загрузке данных. Загрузка данных может осуществляться за счет RestAPI, а выгрузка данных для обучения моделей — за счет нативной интеграции в Python. Деплоймент сервера InfluxDB выполняется через docker контейнер с файловым хранилищем для данных, вынесенным через volume в хранилище объектов s3.

Работа RestAPI обеспечивается за счет сервиса API Gateway совместно с Cloud Functions, которые при получении API запросов выполняют их обработку.

Веб-приложение для визуализации данных использует сервис Data Lens, который берет данные напрямую из InfluxDB для выбранного полигона, а также периодически отправляет запросы API для получения предсказаний и оценок пожарной опасности в режиме псевдореального времени.

Обработка данных и обучение моделей происходит в офлайн режиме. Для этого ML аналитик делает запрос к базе данных с необработанными данными и, используя конвенциональные библиотеки Python, экспериментирует с обучением и оптимизацией моделей. Запущенный через docker mlflow, с вынесенным хранилищем данных в хранилище s3, осуществляет сохранение параметров и метрик моделей, а также артефактов, включая обученные модели. Это позволяет сравнивать модели между собой. После экспериментирования выбирается самый удачный кандидат и через уникальный идентификатор в mlflow модель интегрируется с обработчиком запросов. При этом новая модель становится доступна клиентам сервиса.

Архитектура сервиса схематично представлена на рис. 9.

Использование сервиса «Умный полигон» позволяет визуализировать информацию о состоянии мест размещения и накопления отходов и результатах прогнозирования; сформировать отчет по полигону за выбранный период; осуществлять своевременное оповещение и передачу необходимой информации о возможности или возникновении горения; выбирать наилучшие решения, направленные на минимизацию пожарного риска, и проводить контроль их эффективности.

3. Проведение тестирования разработанных моделей

Точность наилучших моделей лежит в диапазоне между 0,03 и 0,06 % относительной погрешности. Незначительное различие значений train_loss и test_loss для обученных моделей указывает на минимальное переобучение.

В ходе тестирования было установлено, что значения, возвращаемые через разработанные компо-

ненты с RestAPI интерфейсом, соответствуют как результатам, полученным при прямом использовании модели, так и тестовым значениям в пределах допустимой погрешности. Полученные результаты подтверждают работоспособность компонента. Средняя продолжительность обработки одного запроса, включая первоначальное форматирование данных в формате JSON, составляет около 5 миллисекунд при запуске на локальной системе.

В местах депонирования отходов возникает значительное количество пожаров, которые трудно поддаются тушению и практически не прогнозируются. Представленная работа является продолжением исследований [1, 6–9, 11, 12, 14, 17], направлена на создание прогнозных моделей и повышение точности предсказания возникновения пожароопасных ситуаций в местах накопления и размещения отходов. Проведенный анализ существующих систем видеомониторинга, компьютерного зрения, датчиков, применяемых в местах накопления и размещения ТКО, показал, что удовлетворительного решения вопросов, связанных с прогнозированием и предупреждением пожаров на таких объектах, пока не найдено.

Полученные результаты хорошо согласуются с выводами S. Samain [10], S. Moqbel [9] о необходимости разработки системы показателей, определяющих пожарную опасность мест накопления и размещения отходов. Наиболее значимыми показателями являются температура, концентрации газов в устье скважины, расходы газа и жидкости. Выбор метода прогнозирования подтвержден результатами, полученными H.A. Qdaisa, N. Shatnaw [15], обосновывающими перспективность использования искусственных нейронных сетей и машинного обучения.

В связи с отсутствием реальных данных с полигонов применяли синтетические данные, сгенерированные с помощью симуляции полигона на основе метода конечных элементов, подробно описанного D. Hanson, N. Yeşiller и др. [8].

Преодоление проблем, относящихся к практической реализации результатов исследований непосредственно в местах размещения и накопления отходов и не решенных в работах S. Copping et al. [7], D. Hanson et al. [8], S. Samain [10], A. Titov et al. [12], A. Musilli [18], G.S. Manjunath et al. [20], R. Mohsen [22], авторы связывают с обеспечением возможности не только обнаруживать очаги горения, определять их местоположение и границы, но и прогнозировать пожароопасные ситуации, что позволит принимать заблаговременные меры, направленные на снижение пожарного риска.

Результаты проведенного исследования войдут в качестве первого модуля «Мониторинг и прогнозирование пожароопасных состояний мест размещения и накопления ТКО» в состав комплексной

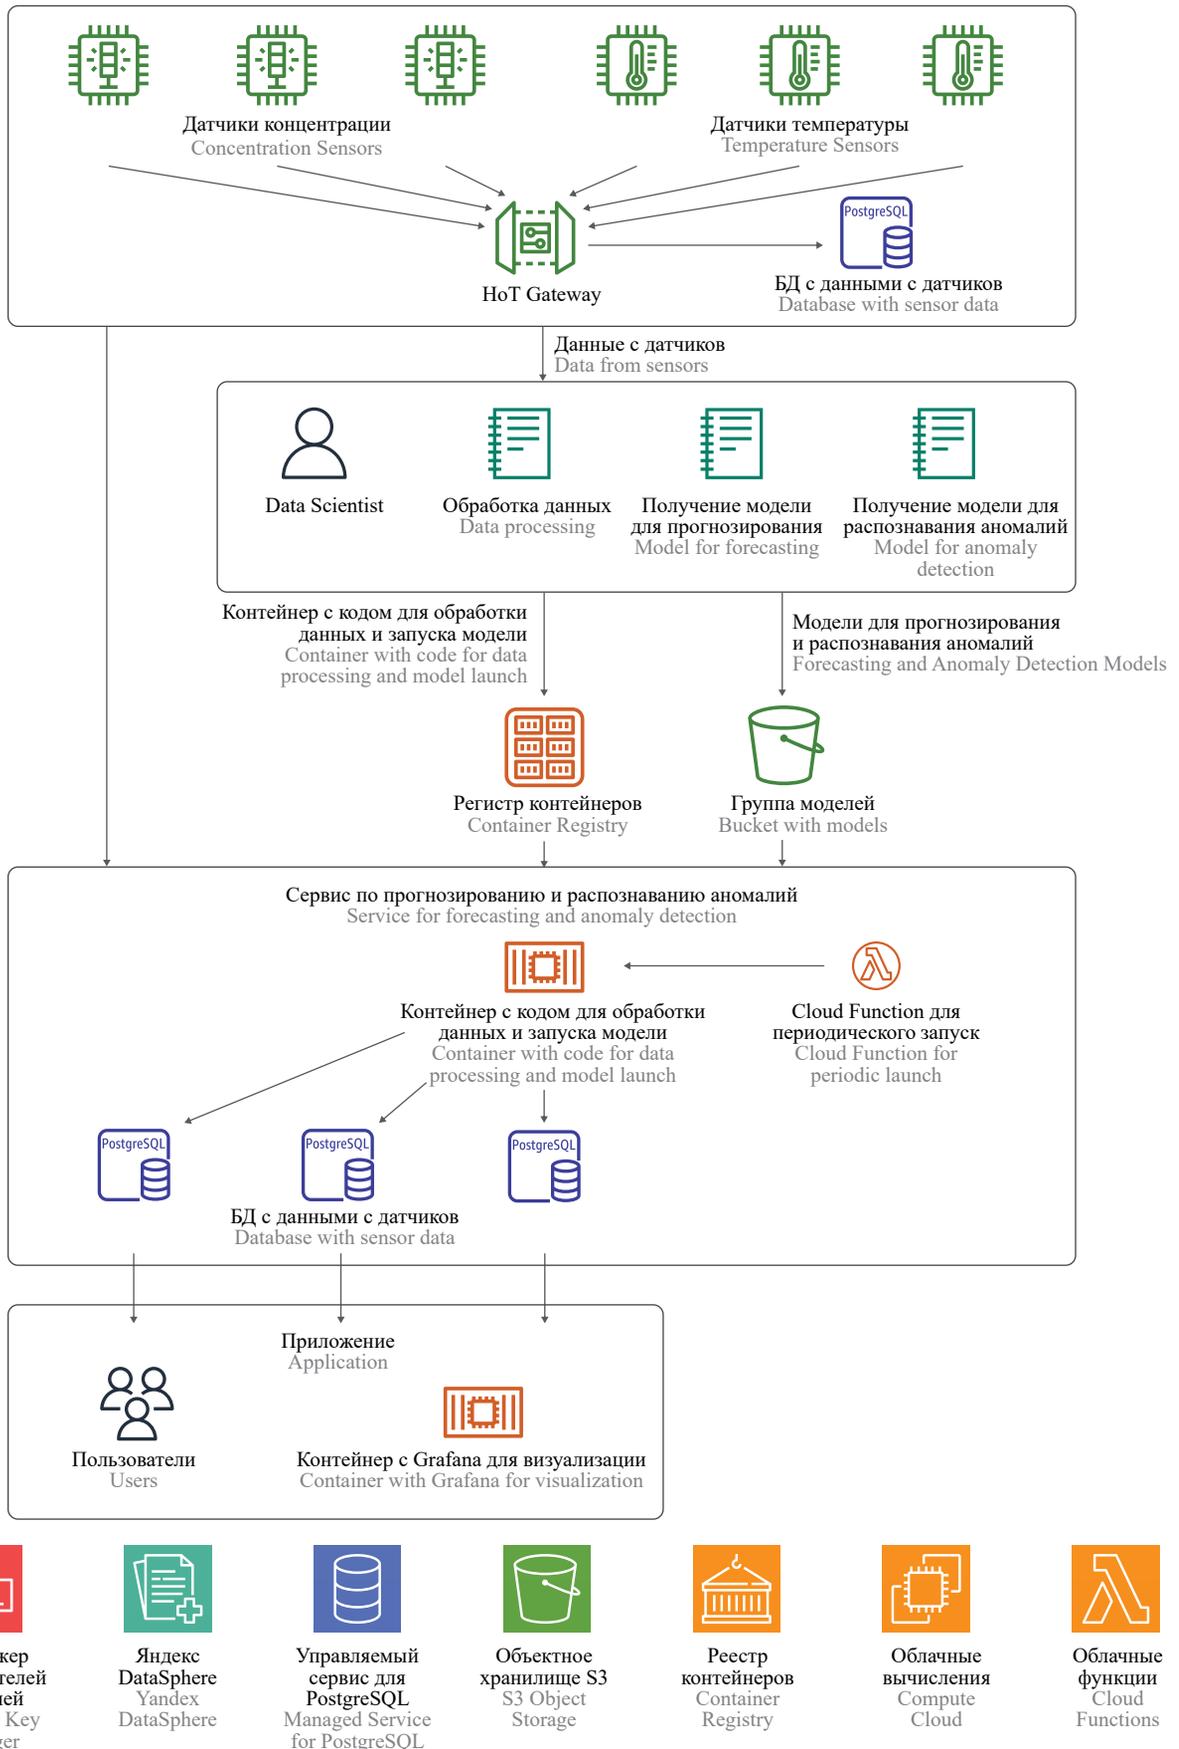


Рис. 9. Архитектура сервиса «Умный полигон»
Fig. 9. Architecture of the “Smart Polygon” service

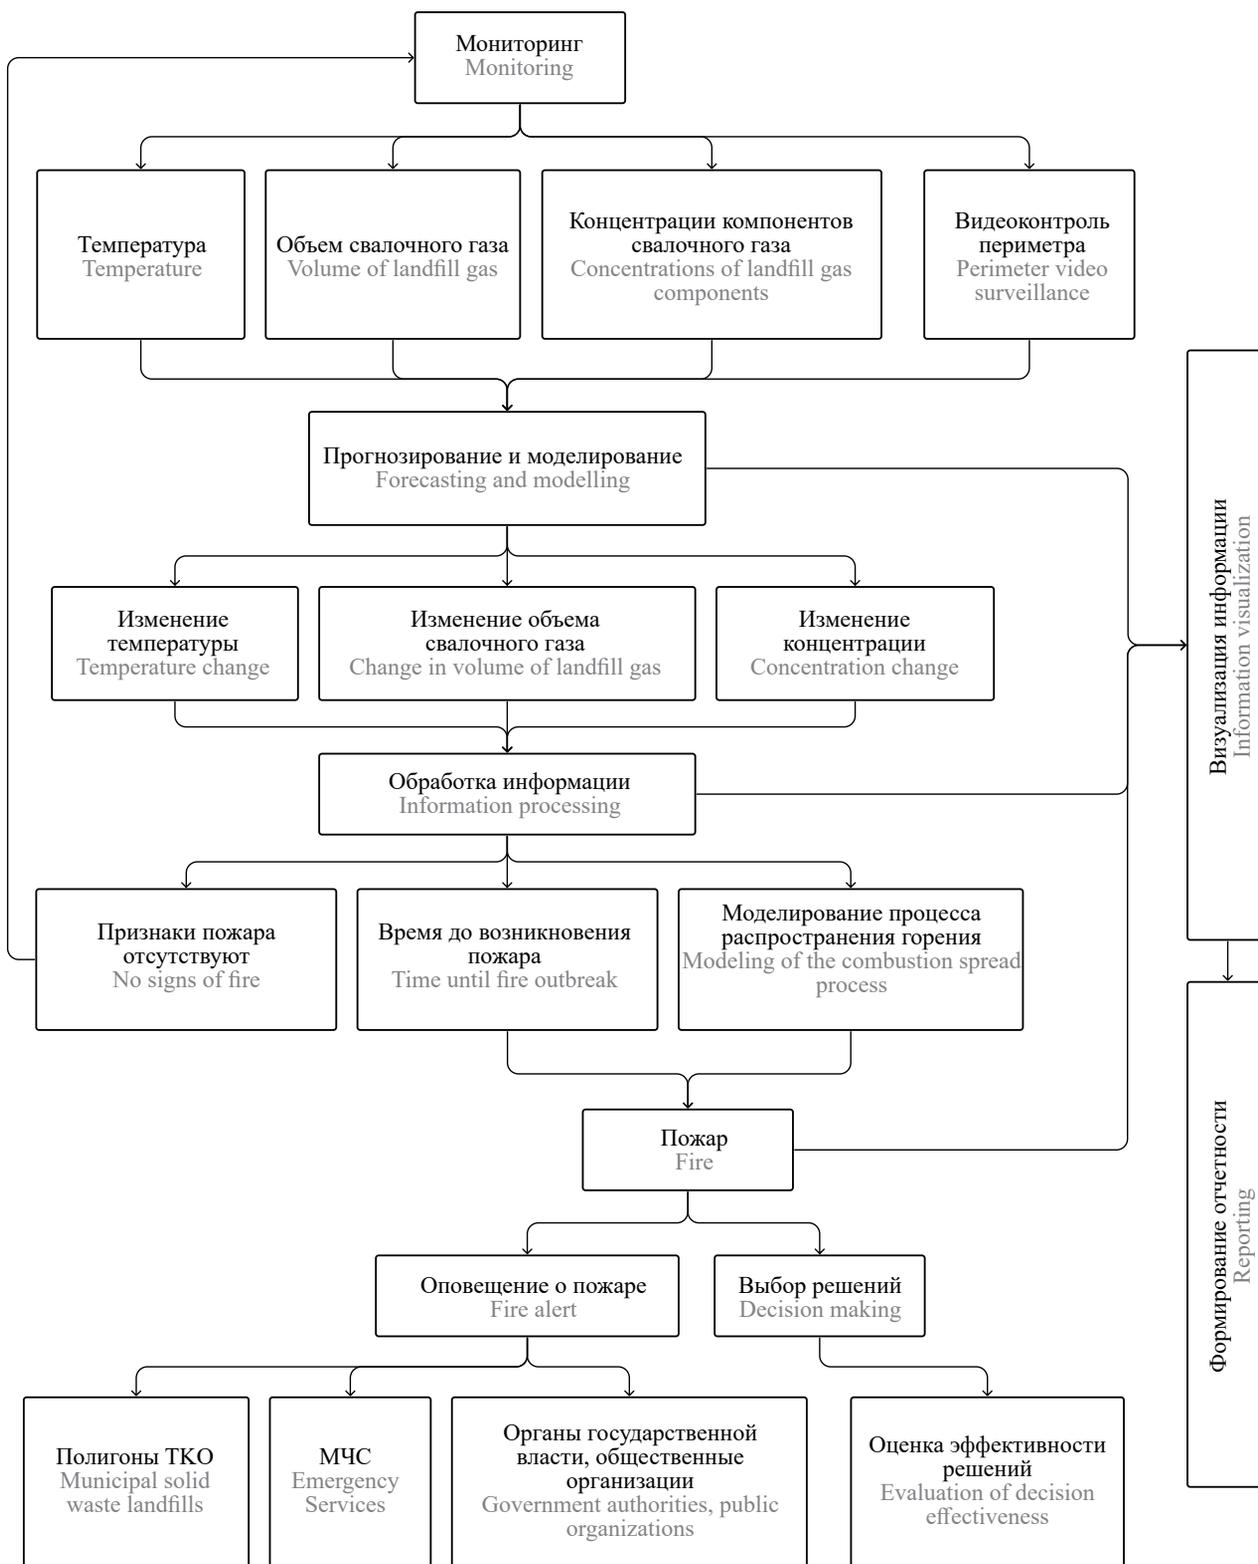


Рис. 10. Структура комплексной платформы [14]
 Fig. 10. Structure of the integrated platform [14]

платформы, предназначенной для риск-ориентированного прогнозирования, снижения экологической и пожарной опасности мест размещения и накопления отходов на основе методов искусственного интеллекта с использованием облачных

технологий. Структура платформы представлена на рис. 10.

Второй модуль «Система поддержки принятия решений» планируется как компьютерная автоматизированная система, включающая пользователь-

ский интерфейс и программные интеллектуальные средства для поддержки принятия решений, направленных на предупреждение и тушение пожаров.

Выводы

1. Проведенный сравнительный анализ систем мониторинга мест размещения и накопления ТКО показал нерешенность вопросов прогнозирования возникновения и развития пожара, поддержки принятия решений. Возможность подключения к системе группы полигонов в большинстве случаев не предусмотрена, отсутствует функция визуализации полученной информации.

2. Разработана система показателей для оценки пожароопасных состояний мест размещения и накопления отходов, включающая температуру, массовые доли метана, углекислого газа, азота и кислорода, расходы газа и жидкости.

3. Создана модель, позволяющая на основе полученных с датчиков данных прогнозировать динамику изменения ключевых параметров и давать оценку пожарной опасности мест размещения и накопления отходов с учетом выбранного горизонта планирования. В связи с тем, что реальные данные с полигонов ожидаются со значительно более сложными зависимостями, чем в синтетических данных, в качестве типа модели выбраны полносвязные нейронные сети

прямого распространения. Проведена оценка модели на основе тестовой выборки, обоснован метод для обнаружения аномалий на основе обучения без учителя.

4. Разработана модель, позволяющая на основе полученных с датчиков данных обнаруживать очаги горения, в том числе скрытые, с указанием их местоположения и границ.

Определены и представлены характеристики основных сценариев, определяющих структуру и использование сервиса «Умный полигон». Разработана его архитектура. Применение сервиса «Умный полигон» позволяет визуализировать информацию о состоянии мест захоронения отходов и результатах прогнозирования; сформировать отчет по полигону за выбранный период; осуществлять своевременное оповещение и передачу необходимой информации о возможности или возникновении горения; выбирать наилучшие решения, направленные на минимизацию пожарного риска, и проводить контроль их эффективности.

5. Проведено тестирование разработанных моделей.

Результаты проведенного исследования войдут в качестве модуля в состав комплексной платформы для риск-ориентированного прогнозирования, снижения экологической и пожарной опасности мест размещения и накопления ТКО.

СПИСОК ИСТОЧНИКОВ

1. Королева Л.А., Свидзинская Г.Б., Хайдаров А.Г., Ивахнюк Г.К. Применение модели Хольта – Уинтерса и эксергетического метода для прогнозирования безопасного обращения с отходами в Российской Федерации // Безопасность труда в промышленности. 2021. № 11. С. 34–40. DOI: 10.24000/0409-2961-2021-11-34-40
2. Kumar A., Agrawal A. Recent trends in solid waste management status, challenges, and potential for the future Indian cities : a review // Current Research in Environmental Sustainability. 2020. Vol. 2. P. 10001. DOI: 10.1016/j.crsust.2020.100011
3. Liao C.-H., Chiu A. SF Evaluate municipal solid waste management problems using hierarchical framework // Procedia — Social and Behavioral Sciences. 2011. Vol. 25. Pp. 353–362. DOI: 10.1016/j.sbspro.2011.10.554
4. Анализ выполнения мероприятий, обеспечивающих экологическую безопасность Российской Федерации, в части ликвидации объектов накопленного вреда и формирования комплексной системы обращения с твердыми коммунальными отходами : отчет о результатах экспертно-аналитического мероприятия // Бюллетень Счетной палаты РФ. 2020. № 9 (274). С. 6–43.
5. Пожары и пожарная безопасность в 2022 году : информ.-аналит. сб. Балашиха : ФГБУ ВНИИПО МЧС России, 2023. 80 с.
6. Jafari N.A., Stark T.D., Thalhamer T. Spatial and temporal characteristics of elevated temperatures in municipal solid waste landfills // Waste Management. 2016. Vol. 59. Pp. 286–301. DOI: 10.1016/j.wasman.2016.10.052
7. Hanson D., Yeşiller N., Onnen M.T. et al. Development of numerical model for predicting heat generation and temperatures in MSW landfills // Waste Management and Research. 2013. Vol. 33 (10). Pp. 1993–2000. DOI: 10.1016/j.wasman.2013.04.003
8. Samain S. Development of a subsurface landfill fire risk-index // Masters in Science. Rowan University, 2018. DOI: 10.13140/RG.2.2.24248.37123
9. Саати Т., Кернс К. Аналитическое планирование. Организация систем / пер. с англ. Вачнадзе Р.Г. М. : Радио и связь, 1991.

10. Titov A., Tumanov A., Timofeev A., Tumanov V., Denisov V. Autonomous safety system for MSW landfills // E3S Web International Conference on Efficient Production and Processing. 2020. Vol. 161. P. 01043. DOI: 10.1051/conf/202016101043
11. Daugela I., Visockiene J.S., Kumpiene J. Detection and analysis of methane emissions from a landfill using unmanned aerial drone systems and semiconductor sensors // *Detritus*. 2020. Vol. 10. Pp. 127–138. DOI: 10.31025/2611-4135/2020.13942
12. Хайдаров А.Г., Королева Л.А., Смирнов А.С. Прогнозирование возникновения и распространения подземных пожаров на полигонах твердых коммунальных отходов // Вестник Санкт-Петербургского университета Государственной противопожарной службы МЧС России. 2022. № 4. С. 41–50.
13. Qdais H.A., Shatnaw N. Assessing and predicting landfill surface temperature using remote sensing and an artificial neural network // *International Journal of Remote Sensing*. 2019. Vol. 40. Issue 24. Pp. 9556–9571. DOI: 10.1080/01431161.2019.1633703
14. Amershi S., Begel A., Bird Ch., Deline R. Software engineering for machine learning : a case study // *IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE 2019)*. Montreal, QC, Canada, 2019. Pp. 291–300. DOI: 10.1109/ICSE-SEIP.2019.00042
15. Martin J.W., Stark T.D., Thalhamer T., Gerbasi-Graf G.T., Gortner R.E. Detection of aluminum waste reactions and associated waste fires // *Journal of Hazardous, Toxic & Radioactive Waste*. 2013. Vol. 17 (3). Pp. 164–174. DOI: 10.1061/(ASCE)HZ.2153-5515.0000171
16. Musilli A. Landfill elevated internal temperature detection and landfill fire index assessment for fire monitoring : theses and dissertations. USA : Rowan University, 2016. URL: <https://rdw.rowan.edu/etd/2340/>
17. Koroleva L.A., Antoshina T.N., Boyakhchyan A.A., Haidarov A.G., Ivakhnuk G.K. Comparative analysis of methods for determining the flammability of municipal solid waste as railway transport cargo // *IOP Conference Series: Earth and Environmental Science*. 2021. Vol. 938 (1). P. 012006. DOI: 10.1088/1755-1315/938/1/012006
18. Manjunatha G.S., Chavan D., Lakshmikanthan P., Singh L., Kumar S., Kumar R. Specific heat and thermal conductivity of municipal solid waste and its effect on landfill fires // *Waste Management*. 2020. Vol. 116. Pp. 120–130. DOI: 10.1016/j.wasman.2020.07.033
19. Millet I., Saaty T. On the relativity of relative measures-accommodating both rank preservation and rank reversals in the AHP // *European Journal of Operational Research*. 2000. Vol. 121 (1). Pp. 202–212. DOI: 10.1016/j.wasman.2020.07.033
20. Mohsen R. Estimation of greenhouse gas emissions in municipal solid waste landfills in ontario using mathematical models and direct measurements : dissertation. Canada : University of Guelph, 2019.
21. Zaeimi M.B., Rassafi A.A. Designing an integrated municipal solid waste management system using a fuzzy chance-constrained programming model considering economic and environmental aspects under uncertainty // *Waste Management*. 2021. Vol. 125. Pp. 268–279. DOI: 10.1016/j.wasman.2021.02.047
22. Королева Л.А., Подмарков В.В., Хайдаров А.Г. Система классификации зон полигонов твердых коммунальных отходов по пожарной опасности // *Проблемы управления рисками в техносфере*. 2022. № 4 (64). С. 31–39.
23. Lim B., Zohren S. Time-series forecasting with deep learning: a survey // *Philosophical Transactions of the Royal Society A : Mathematical, Physical and Engineering Sciences*. 2021. Vol. 379. No. 2194. P. 20200209. DOI: 10.1098/rsta.2020.0209
24. Nassif A.B., Talib M.A., Nasir Q., Dakalbab F.M. Machine Learning for Anomaly Detection : a systematic review // *IEEE Access*. 2021. Vol. 9. Pp. 78658–78700. DOI: 10.1109/ACCESS.2021.3083060

REFERENCES

1. Koroleva L.A., Svidzinskaya G.B., Khaydarov A.G., Ivakhnyuk G.K. Application of the Holt – Winters model and the exergetic method for predicting safe waste management in the Russian Federation. *Occupational safety in industry*. 2021; 11:34-40. DOI: 10.24000/0409-2961-2021-11-34-40 (rus).
2. Kumar A., Agrawal A. Recent trends in solid waste management status, challenges, and potential for the future Indian cities : a review. *Current Research in Environmental Sustainability*. 2020; 2:10001. DOI: 10.24000/0409-2961-2021-11-34-40
3. Liao C.-H., Chiu A. SF Evaluate municipal solid waste management problems using hierarchical framework. *Procedia — Social and Behavioral Sciences*. 2011; 25:353-362. DOI: 10.1016/j.sbspro.2011.10.554
4. ACRF Analysis of the implementation of measures ensuring the environmental safety of the Russian Federation in terms of the elimination of accumulated damage objects and the formation of a comprehensive system for solid municipal waste management: report on the results of an expert-analytical event. *Bulletin of the Accounting Chamber of the Russian Federation*. 2020; 9(274):6-43. (rus).

5. *Fires and fire safety in 2022 : inform.-analyte. col.* Balashikha, Federal State Budgetary Institution VNIPO of the Ministry of Emergency Situations of Russia. (rus).
6. Jafari N.A., Stark T.D., Thalhamer T. Spatial and temporal characteristics of elevated temperatures in municipal solid waste landfills. *Waste Management*. 2016; 59:286-301. DOI: 10.1016/j.wasman.2016.10.052
7. Hanson D., Yeşiller N., Onnen M.T. et al. Development of numerical model for predicting heat generation and temperatures in MSW landfills. *Waste Management and Research*. 2013; 33(10):1993-2000.
8. Samain S. Development of a subsurface landfill fire risk-index. *Masters in Science*. USA Rowan University, 2018.
9. Saati T., Kerns K. *Analytical planning. Organization of systems / trans. from English*. Vachnadze R.G. Moscow, Radio and Communications, 1991. (rus).
10. Titov A., Tumanov A., Timofeev A., Tumanov V., Denisov V. Autonomous safety system for MSW landfills. *E3S Web of Conferences*. 2020; 161:01043. DOI: 10.1051/conf/202016101043
11. Daugela I., Visockiene J.S., Kumpiene J. Detection and analysis of methane emissions from a landfill using unmanned aerial drone systems and a semiconductor sensors. *Detritus*. 2020; 10:127-138. DOI: 10.31025/2611-4135/2020.13942
12. Khaydarov A.G., Koroleva L.A., Smirnov A.S. Forecasting the occurrence and spread of underground fires at landfills of solid municipal waste. *Scientific and analytical journal "Vestnik Saint Petersburg university of State fire service of EMERCOM of Russia"*. 2022; 4:41-50. DOI: 10.1051/conf/202016101043 (rus).
13. Qdaisa H.A., Shatnaw N. Assessing and predicting landfill surface temperature using remote sensing and an artificial neural network. *International Journal of Remote Sensing*. 2019; 40(24):9556-9571. DOI: 10.1080/01431161.2019.1633703
14. Amershi S., Begel A., Bird Ch., Deline R. Software Engineering for Machine Learning : a Case Study. *IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE 2019)*. Montreal, QC, Canada, 2019; 291-300. DOI: 10.1109/ICSE-SEIP.2019.00042
15. Martin J.W., Stark T.D., Thalhamer T., Gerbasi-Graf G.T., Gortner R.E. Detection of aluminum waste reactions and associated waste fires. *Journal of Hazardous, Toxic & Radioactive Waste*. 2013; 17(3):164-174. DOI :10.1061/(ASCE)HZ.2153-5515.0000171
16. Musilli A. *Landfill elevated internal temperature detection and landfill fire index assessment for fire monitoring : theses and dissertations*. USA, Rowan University, 2016. URL: <https://rdw.rowan.edu/etd/2340/>
17. Koroleva L.A., Antoshina T.N., Boyakhchyan A.A., Haidarov A.G., Ivakhnuk G.K. Comparative analysis of methods for determining the flammability of municipal solid waste as railway transport cargo. *IOP Conference Series: Earth and Environmental Science*. 2021; 938(1):012006. DOI: 10.1088/1755-1315/938/1/012006
18. Manjunatha G.S., Chavan D., Lakshmikanthan P., Singh L., Kumar S., Kumar R. Specific heat and thermal conductivity of municipal solid waste and its effect on landfill fires. *Waste Management*. 2020; 116:120-130. DOI: 10.1016/j.wasman.2020.07.033
19. Millet I., Saaty T. On the relativity of relative measures-accommodating both rank preservation and rank reversals in the AHP. *European Journal of Operational Research*. 2000; 121(1):202-212. DOI: 10.1016/j.wasman.2020.07.033
20. Mohsen R. *Estimation of Greenhouse Gas Emissions in Municipal Solid Waste Landfills in Ontario Using Mathematical Models and Direct Measurements : dissertation*. Canada, University of Guelph, 2019.
21. Zaeimi M.B., Rassafi A.A. Designing an integrated municipal solid waste management system using a fuzzy chance-constrained programming model considering economic and environmental aspects under uncertainty. *Waste Management*. 2021; 125:268-279. DOI: 10.1016/j.wasman.2021.02.047
22. Koroleva L.A., Podmarkov V.V., Khaydarov A.G. Classification system of solid municipal waste landfill zones by fire hazard. *Problems of risk management in the technosphere*. 2022; 4(64):31-39. (rus).
23. Lim B., Zohren S. Time-series forecasting with deep learning : a survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 2021; 379(2194):20200209. DOI: 10.1098/rsta.2020.0209
24. Nassif A.B., Talib M.A., Nasir Q., Dakalbab F.M. Machine Learning for Anomaly Detection : a systematic review. *IEEE Access*. 2021; 9:78658-78700. DOI: 10.1109/ACCESS.2021.3083060

Поступила 01.03.2024, после доработки 25.03.2024;

принята к публикации 10.04.2024

Received March 1, 2024; Received in revised form March 25, 2024;

Accepted April 10, 2024

Информация об авторах

КОРОЛЕВА Людмила Анатольевна, д-р техн. наук, доцент, профессор кафедры пожарной, аварийно-спасательной техники и автомобильного хозяйства, Санкт-Петербургский университет Государственной противопожарной

Information about the authors

Lyudmila A. KOROLEVA, Dr. Sci. (Eng.), Docent, Professor of Fire, Rescue Equipment and Automotive Industry Department, Saint-Petersburg University of State Fire Service of the Ministry of the Russian Federation for Civil Defense, Emergencies and

службы Министерства Российской Федерации по делам гражданской обороны, чрезвычайным ситуациям и ликвидации последствий стихийных бедствий имени Героя Российской Федерации генерала армии Е.Н. Зиничева, Россия, 196105, г. Санкт-Петербург, Московский пр-т, 149; ведущий научный сотрудник лаборатории проблем экологии транспортных систем, Институт проблем транспорта им. Н.С. Соломенко Российской академии наук, Россия, 199178, г. Санкт-Петербург, 12-я линия ВО, 13; Scopus AuthorID: 57395471000; ResearcherID: HJZ-4255-2023; ORCID: 0000-0001-5661-5774; e-mail: lyudamil@mail.ru

ХАЙДАРОВ Андрей Геннадьевич, канд. техн. наук, доцент, генеральный директор, ООО «Аналитические системы», Россия, 191036, г. Санкт-Петербург, 3-я Советская ул., 7, пом. 5н; Scopus AuthorID: 57395680500; ResearcherID: ACX-2398-2022; ORCID: 0000-0003-0693-8027; e-mail: andreyhaydarov@gmail.com

Вклад авторов:

Королева Л.А. — сбор материала; проведение сравнительного анализа систем мониторинга; обоснование системы показателей для оценки пожарной опасности; подготовка данных для разработки и тестирования моделей; обработка материала; написание статьи; научное редактирование текста.

Хайдаров А.Г. — сбор материала; проведение сравнительного анализа систем мониторинга; обоснование системы показателей для оценки пожарной опасности; разработка моделей; их тестирование; разработка архитектуры сервиса; оформление графического материала; научное редактирование текста.

Авторы заявляют об отсутствии конфликта интересов.

Elimination on Consequences of Natural Disasters named after Hero of the Russian Federation, Army General E.N. Zinichev, Moskovskiy Avenue, 149, Saint Petersburg, 196105, Russian Federation; Leading Researcher at the Laboratory of Environmental Problems of Transport Systems, Solomenko Institute of Transport Problems of the Russian Academy of Sciences, 12th Line VO, 13, Saint Petersburg, 199178, Russian Federation; Scopus AuthorID: 57395471000; ResearcherID: HJZ-4255-2023; ORCID: 0000-0001-5661-5774; e-mail: lyudamil@mail.ru

Andrey G. KHAYDAROV, Cand. Sci. (Eng.), Docent, General Director, Limited Liability Company “Analytical Systems”, 3-ya Sovetskaya St., 7, room 5n, Saint-Petersburg, 191036, Russian Federation; Scopus AuthorID: 57395680500; ResearcherID: ACX-2398-2022; ORCID: 0000-0003-0693-8027; e-mail: andreyhaydarov@gmail.com

Contribution of the authors:

Koroleva L.A. — collecting material; conducting a comparative analysis of monitoring systems; substantiating a system of indicators for assessing fire danger; preparing data for models development and testing; processing material; writing an article; scientific text editing.

Khaydarov A.G. — collecting material; conducting a comparative analysis of monitoring systems; substantiating a system of indicators for assessing fire danger; developing models; testing them; developing a service architecture; designing graphic material; scientific text editing.

The authors declare no conflicts of interests.