

ПОЖАРОВЗРЫВБЕЗОПАСНОСТЬ/FIRE AND EXPLOSION SAFETY. 2024. Т. 33. № 5. С. 87–98
POZHAROVZRYVOBEZOPASNOST/FIRE AND EXPLOSION SAFETY. 2024; 33(5):87-98

НАУЧНАЯ СТАТЬЯ/RESEARCH PAPER

УДК 681.5:658.5

<https://doi.org/10.22227/0869-7493.2024.33.05.87-98>

Модель прогнозирования класса готовности датчиков термохимического газосигнализатора для предотвращения пожаров и взрывов

Илья Вадимович Самарин , Андрей Юрьевич Строгонов,
Алексей Вячеславович Крючков

Российский государственный университет нефти и газа (национальный исследовательский университет) имени И.М. Губкина,
г. Москва, Россия

АННОТАЦИЯ

Введение. Актуальность рассматриваемой в статье проблемы заключается в необходимости совершенствования автоматизации и интеллектуализации организационного управления пожаровзрывобезопасностью на объектах топливно-энергетического комплекса. Дрейф нуля из-за влияния ряда параметров у термохимических датчиков снижает их чувствительность, что требует разработки новых подходов в реализации их технического обслуживания (ТО). Модель прогнозирования класса готовности датчиков, основанная на сверточной нейронной сети (СНС), позволяет скорректировать установленный процесс принятия решений о ТО, предотвращая опасные ситуации на ранних этапах развития.

Задача исследования. Повышение эффективности работы лиц, принимающих решения (ЛПР) при планировании работ бригад, выполняющих диагностику и техническое обслуживание вспомогательного оборудования, используемого в том числе для обеспечения пожарной безопасности (ПБ).

Методы. Для расчета значений классификации при прогнозировании класса готовности датчиков газосигнализаторов использовался метод стратегического планирования, основанный на важности признаков (динамического стратегического планирования с использованием математического программирования). В соответствии с ним класс готовности определялся как сумма бинарных значений признаков, умноженных на нормированное значение их важности.

Результаты и их обсуждение. Для проведения расчетов и оценки результатов применения СНС авторами была разработана программа на языке программирования Python. С ее помощью был сгенерирован общий набор данных, из которого в соотношении 9:1 были выбраны обучающий и тестовый наборы. После их формирования СНС прошла обучение. Тестирование показало, что ЛПР может прогнозировать класс готовности датчиков газосигнализаторов с вероятностью 89 %.

Выводы. Представленная в статье СНС позволяет повысить эффективность работы ЛПР при планировании работ бригад, выполняющих диагностику и техническое обслуживание вспомогательного оборудования для ПБ. Принцип работы данной СНС может быть использован для решения других аналогичных задач планирования и управления.

Ключевые слова: сверточная нейронная сеть; пожарная безопасность; техническое обслуживание; предупреждение пожаров и взрывов; прогнозирование готовности; метод стратегического планирования

Для цитирования: Самарин И.В., Строгонов А.Ю., Крючков А.В. Модель прогнозирования класса готовности датчиков термохимического газосигнализатора для предотвращения пожаров и взрывов // Пожаровзрывобезопасность/Fire and Explosion Safety. 2024. Т. 33. № 5. С. 87–98. DOI: 10.22227/0869-7493.2024.33.05.87-98

✉ Самарин Илья Вадимович, e-mail: ivs@gubkin.ru

Model of predicting the readiness class of thermochemical gas alarm sensors for fire and explosion prevention

Ilya V. Samarin , Andrey Yu. Strogonov, Aleksey V. Kryuchkov

National University of Oil and Gas "Gubkin University", Moscow, Russian Federation

ABSTRACT

Introduction. The relevance of the problem considered in the paper is in the need to improve the automation and intellectualization of organizational management of fire and explosion safety at the facilities of the fuel and energy complex. Zero drift due to the influence of a number of parameters in thermochemical sensors reduces

their sensitivity, which requires the development of new approaches in the implementation of their maintenance. The sensor readiness class prediction model, based on a convolutional neural network (CNN), allows to adjust the established decision-making process, preventing dangerous situations at early stages of development.

Objective. To increase the efficiency of decision makers (DM) in planning the work of teams performing diagnostics and maintenance of auxiliary equipment used, among other things, to ensure fire safety (FS).

Methods. To calculate the classification values when predicting the readiness class of gas alarm sensors, a strategic planning method based on the importance of features (dynamic strategic planning using mathematical programming) was used. According to it, the readiness class was defined as the sum of the binary values of the features multiplied by the normalized value of their importance.

Results and discussion. To carry out calculations and evaluate the results of the CNN application, the authors developed a programme in the Python programming language. It was used to generate a common data set from which training and test sets were selected in a ratio of 9:1. After their formation, the CNN was trained. Testing showed that the DM can predict the readiness class of gas alarm sensors with a probability of 89 %.

Conclusions. The CNN presented in the paper allows to increase the efficiency of the DM work when planning the work of teams performing diagnostics and technical maintenance of auxiliary equipment for FS. The principle of operation of this CNN can be used to solve other similar planning and management tasks.

Keywords: convolutional neural network; fire safety; maintenance; fire and explosion prevention; forecasting readiness; strategic planning method

For citation: Samarin I.V., Stroganov A.Yu., Kryuchkov A.V. Model of predicting the readiness class of thermochemical gas alarm sensors for fire and explosion prevention. *Pozharovzryvobezopasnost/Fire and Explosion Safety*. 2024; 33(5):87-98. DOI: 10.22227/0869-7493.2024.33.05.87-98 (rus).

✉ Ilya Vadimovich Samarin, e-mail: ivs@gubkin.ru

Введение

Новые подходы к развитию отраслей промышленности требуют внедрения самых современных технологий, которые стремительно меняют характер работ, в том числе, на предприятиях топливно-энергетического комплекса (ТЭК). Использование таких подходов всегда связано с применением новых поколений информационных технологий (ИТ). Одним из таких поколений являются системы искусственного интеллекта (ИИ), реализуемые с помощью программного обеспечения (ПО), включаемого в автоматизированные системы управления (АСУ) предприятиями (АСУП) и технологическими процессами (АСУТП).

Развитие ИТ, связанных с ИИ, опирается на накопленные в электронном виде знания, которые, как правило, чаще всего администрируют правительства государств, владея и храня «от имени своего народа огромные объемы данных» [1]. Владение данными предусматривает разработку порядка их использования субъектами экономической деятельности. Для этого в РФ была разработана Национальная стратегия развития ИИ на период до 2030 года¹. В соответствии с ней одной из приоритетных задач является «разработка и развитие программного обеспечения, в котором используются системы искусственного интеллекта» (п. 24, б). Таким ПО, как правило, являются нейронные сети. Учитывая специфичность решаемых ими конкретных задач, их следует отнести к специальным ПО (СПО) в АСУТП.

Применение технологий ИИ меняет саму суть науки об управлении. Появляются новые противоречия, возникающие, в том числе, и в производственной сфере и приводящие к напряжению внутри процессов управления на объектах ТЭК. Примером точки напряжения в управлении может служить «противоречие между огромными потоками данных, накапливаемых в производственных процессах, в частности — в системах промышленной автоматизации и контроля в виде данных объективной измерительной информации, поступающей с датчиков и различных средств измерений технологического оборудования» и «необходимостью их оперативного анализа с целью извлечения полезной информации и принятия оперативных управляющих решений» [2]. Оперативным анализом и принятием решений на производствах и внутри любых социальных систем занимаются лица, принимающие решения (ЛПР).

Возникающее из-за большого объема данных противоречие затрудняет для ЛПР обеспечение пожарной безопасности (ПБ) объектов ТЭК. Несмотря на то что разработанные в недавнем времени принципы автоматизации работы в области ПБ, сконцентрированные в автоматизированных системах пожаровзрывобезопасности (АСПВБ), позволили разработать немало приложений для поддержки управления [3, 4], проблема обеспечения качественного технического обслуживания оборудования в составе таких систем информирования АСУТП первого уровня, как автоматизированные системы предотвращения пожаров и взрывов, остается по-прежнему актуальной [5].

«Цифровые двойники» (Digital Twins — DT) объектов ТЭК, изначально представлявшие собой СПО «управления жизненным циклом продукта, именуемого PLM-системами (англ. Product lifecycle

¹ Национальная стратегия развития ИИ на период до 2030 года утверждена Указом Президента РФ от 10.10.2019 № 490. URL: <http://static.government.ru/media/acts/files/1201910110003.pdf> (05.07.2024).

management)» [6], были предназначены в том числе для облегчения принятия ЛПР необходимых оперативных управленческих решений в АСУТП и ее составной части — АСПВБ. ДТ стали применяться внутри ПО АСПВБ в том числе для анализа устойчивости АСПВБ с использованием методов моделирования величины энтропии АСПВБ [7]. Однако увеличение точек контроля и объемов данных, анализ которых следовало бы проводить ЛПР за все меньшее время, вынудило к применению систем ИИ уже внутри ДТ. И как показала практика применения таких систем, «сокращаются потери времени на подготовительные, заключительные работы, перерывы и форс-мажорные ситуации, связанные с человеческим фактором» [8].

Примером подобных подготовительных работ и форс-мажорных ситуаций являются датчики газоанализаторов, относящиеся к подсистеме АСПВБ по предотвращению пожаров и взрывов. Для них необходимо регулярное (не менее 4–8 раз в год в зависимости от типа) техническое обслуживание (ТО) с использованием поверочной газовой смеси (ПГС), предназначенное для предотвращения дрейфа нуля. Но если для механических систем данный вопрос давно и основательно прорабатывался (например, [9]), то для систем, связанных с химическими или иными чувствительными элементами, он пока недостаточно хорошо изучен. Например, о данной проблеме пишут [10] в контексте использования подобных датчиков на производственных предприятиях угольной промышленности. Однако звучит только лишь формулировка проблемы, а для ее решения предлагается рассматривать датчики другого типа.

Учитывая разнообразие применяемых в настоящее время приборов оценки состояния среды на объектах ТЭК при построении нейронной сети для определения порядка их ТО, следует выбрать одну из применяемых марок. Очевидно, выбор следует проводить исходя из стоимости, определяющей распространенность датчика. Анализ применения показал, что термохимические датчики (ТХД) имеют низкую стоимость и потому наиболее распространены. Еще одним важным обстоятельством в их пользу (для рассмотрения в качестве основы для исследования) является их способность контролировать одновременно несколько десятков различных горючих составов, в большинстве своем свыше 20.

Для ТХД дрейф нуля обусловлен внутренними процессами в катализаторе, которые происходят не только после его установки на объект, но даже и при его хранении. Снижение их чувствительности может достигать значительных величин. Так, по оценкам экспертов ЗАО «Промкатализ», хранение ТХД на складах в течение года может привести

к отклонениям от нормативных показателей до 10 %, что соответствует степени разрушения катализатора до 0,83 % в месяц. Помимо этого, дрейф нулевых показаний также может быть вызван сильным ветром, туманом, дождем, морозом, выбросом каталитически активных веществ и другими факторами, о чем прямо говорит рабочая документация ТХД.

Тем не менее ЛПР для обеспечения на объектах ТЭК ПБ необходима максимально точная информация. Ее получение обеспечивает своевременное проведение ТО на всех без исключения приборах, входящих в систему информирования АСУТП первого уровня и фиксирующих положение дел в реальном масштабе времени. Для подсистем АСПВБ по предотвращению пожаров и взрывов это — фиксирование опасных ситуаций, которые могут привести к пожару, с помощью анализа химического состава окружающей среды в зоне установки датчика ТХД для его предупреждения на наиболее ранней стадии.

Внедрение систем ИИ на базе нейронных сетей, включенных в ДТ и в АСПВБ, обеспечивает ЛПР оперативный анализ и выдачу данных о необходимости проведения ТО по устранению дрейфа нуля на конкретных приборах с учетом протекающих на объекте ТЭК технологических процессов.

Статья посвящена созданию на основе данных об одном из ТХД нейронной сети и ее обучению с целью добиться наиболее точного анализа состояния установленных на объектах ТЭК приборов информирования АСУТП первого уровня.

Задача исследования

Несмотря на то что в более общем контексте описанное выше противоречие [2] привело на глобальном уровне к «снижению ожиданий»² от внедрения систем, использующих технологии ИИ, их включение в СПО АСПВБ дает свой положительный результат.

Для отслеживания базовой линии процесса ТО газосигнализаторов, устанавливаемых на объектах ТЭК, имеют важное значение их количество и пространственное расположение. В этом смысле характер ТО может определяться как состоянием датчиков, так и регламентным временем их ТО, определяемым эксплуатационной документацией. Помимо этого, важен также состав бригад: располагаемое ЛПР количество людей по отношению к общему количеству датчиков.

Если не выделять модель и марку датчиков, устанавливаемых на объекте ТЭК, то в общем виде задача исследования может быть сформулирована в качестве неравенства, определяющего то, как бригада

² 4 тренда, которые преобладают в цикле Gartner Hype for AI, 2021 г. URL: <https://www.gartner.com/en/articles/the-4-trends-that-prevail-on-the-gartner-hype-cycle-for-ai-2021> (дата обращения: 05.07.2024).

ТО вводит установленные на объекте датчики в эксплуатацию. Покажем это с помощью формул.

Пусть на объекте ТЭК есть $N_{\text{тип}}$ типов датчиков. Для каждого из типов необходим свой комплекс мероприятий, определяемый его руководством по эксплуатации. Обозначив через $t_{\text{мерД}}^{\text{общ}(j)}$ регламентное время проведения мероприятий по ТО одного датчика j -го типа, включающего в себя комплекс более мелких мероприятий в количестве $N_{\text{мерД}j}$, представим его вектором:

$$t_{\text{мерД}}^{\text{общ}(j)} = \{t_{\text{мерД}}^{(1j)}, t_{\text{мерД}}^{(2j)}, \dots, t_{\text{мерД}}^{(N_{\text{мерД}j})}\}, \quad (1)$$

для одного датчика имеем:

$$t_{\text{мерД}}^{\text{общ}(j)} = \sum_{i=1}^{N_{\text{мерД}j}} t_{\text{мерД}}^{(ij)}, \quad (2)$$

где $t_{\text{мерД}}^{\text{общ}(j)}$ — время проведения i -й составной части мероприятий ТО.

Тогда для всех датчиков j -го типа объекта ТЭК имеем:

$$t_{\text{мерД}}^{\text{общ}(j)}_{\text{ОТЭК}} = \sum_{i=1}^{N_{\text{Д}j}} t_{\text{мерД}}^{(ij)\text{общ}}, \quad (3)$$

где $N_{\text{Д}j}$ — общее количество датчиков j -го типа на объекте ТЭК;

$t_{\text{мерД}}^{(ij)\text{общ}}$ — общее время проведения мероприятий ТО для i -й датчика j -го типа.

Время проведения мероприятий ТО объекта ТЭК для датчиков всех типов:

$$t_{\text{мер}}^{\text{общ}}_{\text{ОТЭК}} = \sum_{j=1}^{N_{\text{тип}}} t_{\text{мерД}}^{\text{общ}(j)}_{\text{ОТЭК}}. \quad (4)$$

При этом вектор времен проведения ТО по типам датчиков:

$$t_{\text{мерД}}^{\text{общ}} = \{t_{\text{мерД}}^{\text{общ}(1)}_{\text{ОТЭК}}, t_{\text{мерД}}^{\text{общ}(2)}_{\text{ОТЭК}}, \dots, t_{\text{мерД}}^{\text{общ}(N_{\text{тип}})}_{\text{ОТЭК}}\}. \quad (5)$$

При наличии в бригаде по проведению ТО $N_{\text{Бр}}$ человек, и учитывая, что для проведения мероприятий ТО датчиков с использованием ПГС необходимы как минимум 2 человека, имеем время завершения полного ТО $t_{\text{мер}}^{\text{общ}}$ объекта:

$$t_{\text{мер}}^{\text{общ}} = \frac{2t_{\text{мерД}}^{\text{общ}}_{\text{ОТЭК}}}{N_{\text{Бр}}}. \quad (6)$$

Для того чтобы ЛПР был уверен в том, что система информирования первого уровня АСУТП в подсистеме АСПВБ по предотвращению пожаров и взрывов была готова к работе, необходимо, чтобы бригада ТО успела устранить последствия дрейфа нуля для

всех групп датчиков. Фактически это решение задачи линейного программирования:

$$t_{\text{мер}}^{\text{общ}} \leq \min_j t_{\text{мерД}}^{\text{общ}}. \quad (7)$$

Формула (7) может позволить ЛПР определить дисциплину ТО на объекте ТЭК: порядок обхода бригадой ТО установленных датчиков для проведения мероприятий ТО в том числе с использованием ПГС. Но, учитывая, что помимо регламентного значения времени ТО, использованного в формуле (7), ему требуется фиксирование событий непогоды, выбросов вредных веществ и иных влияющих на состояние датчиков факторов, дисциплина ТО будет постоянно меняться. Допуская, что состояния датчиков будут различны (каждый из них при проведении ТО с ПГС «теряет» часть катализатора), и учитывая перечисленные возможные опасные для датчиков события, в отличие от (7) получаем более сложную задачу.

Внедрение ДТ, которые также называют Индустрией 4.0, значительно увеличивает как число датчиков, так и суммарный поток информации от них. В современных условиях ввиду потребности одновременного решения ЛПР многих сложных задач управления (включающих анализ и принятие решений), ЛПР зачастую сложно оперативно, своевременно и корректно менять дисциплину ТО. Поэтому внутри указанной подсистемы АСПВБ необходима разработка средства поддержки управления, позволяющего анализировать классы готовности датчиков, оказывая ему обоснованную помощь. Вариантом такого средства может быть нейронная сеть, как СПО АСПВБ, накапливающая обучающую информацию для анализа и выдачи рекомендаций по решениям. Изначально в ней может быть реализован только один из типов датчиков. Проведенный выше анализ показал, что выбор ТХД обоснован и может дать нужный результат. Модель датчика для создания такого СПО внутри данного класса приборов не так важна. Дальнейшее развитие сети будет зависеть от добавления в исходный набор новых признаков для данного и других датчиков.

Ввиду достаточной распространенности СТМ-10, широко применяемого на многих нефтеперерабатывающих предприятиях РФ, уместно сделать его отправной точкой формирования набора данных для обучения системы ИИ. Все типы и марки ТХД, включая и СТМ-10, работают по принципу определения энергии окисляемого ими газа с помощью катализатора. Выделяемая энергия внутри датчика Q может быть рассчитана по формуле:

$$C_x H_y + \left(x + \frac{y}{2}\right) O_2 = xCO_2 + \frac{y}{2} H_2O + Q, \quad (8)$$

где x и y — количество атомов углерода и водорода в химическом соединении окисляемого углеводорода.

В зависимости от величины Q прогнозируется или определяется нижний концентрационный предел распространения пламени (НКПР), обычно выражаемый в процентах. НКПР — минимальное содержание горючего вещества в однородной смеси с окислительной средой, при котором возможно распространение пламени по смеси на любое расстояние от источника зажигания³. Его используют в качестве предельных значений порогов предупреждения и срабатывания систем пожаротушения. От того, насколько точно датчики в подсистеме АСПВБ по предотвращению пожаров и взрывов (приборы информирования АСУТП первого уровня) отслеживают значение данного показателя, зависит успешность обеспечения ПБ на объектах ТЭК.

Методы решения

Для решения задач поддержки управления при разработке и построении системы ИИ в СПО АСПВБ, а также ее обучения, следует выбрать тип нейронной сети. Как было сказано выше, задача прогнозирования состояния датчиков требует от строящейся нейронной сети и ЛПР применения «методов анализа данных, концентрирующихся на прогнозировании будущего поведения ... с целью принятия оптимальных решений» [11].

Бригады ТО обеспечивают надежность показаний датчиков, проводя их поверку и калибровку. Для динамического формирования маршрутов специалистов в соответствии с описанными выше изменениями, влияющими на дрейф нуля в ТХД, ЛПР нужна оперативная информация о текущем состоянии каждого из них. Отдельные датчики могут быть повреждены, отдельные заменены, у некоторых из них возможен отказ в функционировании. В переводе на язык систем ИИ состояние датчика будет соответствовать определенному классу, выбором которого она должна будет заниматься. Решения об изменении дисциплины ТО будут приниматься ЛПР с учетом класса состояния каждого из датчиков. Такой вид решаемых сетью задач называется задачами классификации, суть которых заключается в предсказании категории изучаемых объектов или их разделении по заранее заданным признакам. Перечисленные выше факторы, обуславливающие дрейф нуля, в данном случае становятся параметрами, совокупность которых будет определять класс ТХД в нейронной сети. Их уточнение будет проведено ниже.

Методы решения задач классификации в нейронных сетях связаны с моделями глубокого обучения. Они основаны «на нескольких уровнях представления данных» и способны «отображать сложные отношения между входящими и исходящими данными ... путем их преобразования или извлечения из них функций» [12]. Глубина сети зависит от количества входных и выходных слоев. Она создает распределенное представление об объекте анализа: каждый ее уровень состоит сразу из многих точек анализа [13–17]. Алгоритмы глубокого обучения хорошо справляются с изменениями, порождаемыми, например, с классификацией точек на местности, связанными с определением мест возгораний [16]. Краткая характеристика ряда аспектов глубокого обучения приведена в [17].

При выборе типа нейронной сети важно сократить количество используемых для ее обучения признаков, не потеряв при этом в качестве классификации. Такую эффективность в совокупности с высокой скоростью обучения дают сверточные нейронные сети (СНС). Кроме этого, при их использовании повышается точность решения задач прогнозирования за счет создания паттернов мониторинга путем комбинирования сверточных слоев [18]. Благодаря операциям свертки применяемые в сверточных слоях фильтры могут извлекать локальные паттерны необработанных данных, уточняющие состояние оборудования. Результаты применения отдельных СНС [18] показывают их преимущества перед традиционными методами машинного обучения (случайный лес, метод опорных векторов и многослойный персептрон). Поэтому уместно использовать именно этот тип нейронных сетей для разработки стратегий по изменениям в дисциплине ТО.

Приняв за точку отсчета в обучении СНС газосигнализатор типа СТМ-10, выберем необходимые данные для прогнозирования его состояния. Руководство по эксплуатации данного прибора подробно описывает как сами аспекты его правильной установки и эксплуатации, так и факторы, влияющие на его корректную работу⁴. Учитывая, что для проработки всех особенностей его корректной работы при установке на объекте ТЭК понадобится фиксация значений нескольких сотен признаков, выберем сначала для разработки и испытания СНС небольшое их количество. Эти признаки приведены в табл. 1.

Минимальные и максимальные значения признаков (см. табл. 1) определяются согласно руководству по эксплуатации СТМ-10 и установленным стандар-

³ ГОСТ 12.1.044–89. Система стандартов безопасности труда. Пожаровзрывоопасность веществ и материалов. Номенклатура показателей и методы их определения. М. : Стандартинформ, 2006, 216 с. (п. 2.5.1.).

⁴ Сигнализаторы СТМ-10. Руководство по эксплуатации. Альбом приложений. АПИ2 840.069 РЭ1. URL: http://www.analitpribor-smolensk.ru/products/bezopasnost_gazoanalizatory/stacionarnye_gazoanalizatory/signalizator_stm10/ (дата обращения: 10.07.2024).

тами безопасности ПДК⁵. Ряд максимальных значений намеренно завышен для формирования у СНС представления о более высоких классах состояний ТХД.

Состав набора данных для обучения СНС должен содержать не только значения признаков, но также и значение класса готовности, который определит действия ЛПР по изменению дисциплины ТО. Поэтому строки в обучающем и тестовом наборах имеют следующую структуру:

$$X_j = \{x_{j1}, x_{j2}, \dots, x_{jN_{np}}, y_j\}, \quad (9)$$

где j — номер строки обучающего и тестового наборов;

$x_{j1}, x_{j2}, \dots, x_{jN_{np}}$ — значения признаков (в нашем случае из табл. 1);

N_{np} — число признаков в строке обучающего и тестового наборов (в нашем случае 10);

y_j — значение класса состояния ТХД.

Общая структура набора данных для обучения СНС представлена также на рисунке. Она содержит те же элементы, что и вектор (9).

Для определения значений готовности ТХД (y_j , см. (9)) следует считать, что отдельные признаки взаимно независимы. Тогда, используя математическую модель, аналогичную изложенной в [19], будем считать значение класса готовности целевой функцией, основанной на значениях двоичных функций признаков $f(x_{ji})$. Для каждой из них запишем:

$$f(x_{ji}) = \begin{cases} 0, & \{x_{ji} \geq x_{ji}^{(min)} | x_{ji} \leq x_{ji}^{(max)}\}; \\ 1, & \{x_{ji} \leq x_{ji}^{(min)} | x_{ji} \geq x_{ji}^{(max)}\}, \end{cases} \quad (10)$$

где x_{ji} — значение i -го признака из вектора (9) в j -й строке;

$x_{ji}^{(min)}$ и $x_{ji}^{(max)}$ — минимальное и максимальное значение i -го признака (см. табл. 1) для j -й строки.

Каждый из признаков x_{ji} имеет для ЛПР определенную важность:

$$\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_{N_{np}}\}. \quad (11)$$

Для корректного расчета значений y_j следует считать важность нормированной величиной:

$$\sum_{i=1}^{N_{np}} \alpha_i = 1. \quad (12)$$

В общем случае она может изменяться, так как задачи, стоящие перед ЛПР, могут заставить его менять приоритеты:

$$\alpha(t) = \{\alpha_1(t), \alpha_2(t), \dots, \alpha_{N_{np}}(t)\}. \quad (13)$$

⁵ ГОСТ 12.1.005–88. Система стандартов безопасности труда. Общие санитарно-гигиенические требования к воздуху рабочей зоны. URL: <https://internet-law.ru/gosts/gost/1583>

Таблица 1. Признаки для обучения модели СНС
Table 1. Signs for training a CNN model

Название, ед. изм. Name, unit of measurement	Значение Meaning	
	min	max
Диапазон атм. давления, мм рт. ст. Atmospheric pressure range, mmHg	630	800
Диапазон влажности воздуха, % Air humidity range, %	30	98
Напряженность внешнего электрического поля, кВ/м The intensity of the external electric field, kV/m	5,5	10,0
Напряженность внешнего магнитного поля, А/м The strength of the external magnetic field, A/m	220	400
Содержание пыли в воздухе, мг/куб. м Dust content in the air, mg/cubic metre	3,5	10,0
Вибрации с частотой 25 Гц, амплитуда, мм Vibrations with a frequency of 25 Hz, amplitude, mm	0,05	0,12
Содержание вредных веществ. Сера, мг/м ³ The content of harmful substances. Sulfur, mg/m ³	0,01	6,60
Содержание вредных веществ. Мышьяк, мг/м ³ The content of harmful substances. Arsenic, mg/m ³	0,01	0,05
Содержание вредных веществ. Пыль сурьмы, мг/м ³ The content of harmful substances. Antimony dust, mg/m ³	0,01	0,24
Содержание вредных веществ. Сероводород, мг/м ³ The content of harmful substances. Hydrogen sulfide, mg/m ³	0,01	10,2

Придерживаясь изложенной в [19] математической модели, запишем аддитивную целевую функцию для значений класса состояния ТХД:

$$y_j = \sum_{i=1}^{N_{np}} \alpha_i(t) f(x_{ji}). \quad (14)$$

Другим вариантом расчета y_j может быть модель, изложенная в [20].

Для упрощения расчетов значения y_j в строках обучающего и тестового набора СНС следует сделать нормированными или дискретными. В послед-

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	...	x_k	y
742	39	5	265	7	8	0,01	0	15	0	...	...	8
...	...	...	...	...	...	...	...	...	...	...	...	...

Вид набора данных для СНС
Type of dataset for the CNN

нем случае значения класса готовности ТХД будут частью множества Y :

$$Y: y_j \in \{1, 2, \dots, N_{\text{пр}}\}. \quad (15)$$

В нашем случае y_j будет принимать значения от 0 до 9. Значение 0 — полная готовность. Для остальных значений класса готовности ТХД ниже приведены характеристики, описывающие рекомендуемые действия ЛПР:

- (0–3) — наблюдение;
- (4–7) — корректировка плана несрочная;
- (8–9) — срочная корректировка плана.

Результаты и обсуждение

Для построения СНС первым шагом был сгенерирован массив исходных данных, включающий набор из случайных значений признаков (см. табл. 1). С этой целью на языке программирования Python была написана программа генерации синтетического набора данных для решения с помощью сверточной нейронной сети задачи классификации состояний выносных датчиков газосигнализаторов на объектах ТЭК по данным газосигнализаторов СТМ-10. Программа может генерировать набор данных, работая по следующему алгоритму.

Значения каждого из 10 предложенных признаков записывались в отдельный массив, формируемый из случайных значений, находящихся между $x_{ji}^{(\min)}$ и $x_{ji}^{(\max)}$. Затем из полученных 10 массивов объемом 1000 элементов каждый случайным образом одновременно выбирались значения признаков x_{ji} . Полученные 10 значений заносятся в отдельный массив, прототип строки входного набора, для которого по формуле (14) рассчитывается значение класса готовности. Изначально в целях отработки правильности работы программы важность каждого из признаков была зафиксирована равной 1. Полученное в результате значение класса состояния выносного датчика записывается в массив со значениями признаков. Объем сгенерированного таким образом входного набора составил свыше 59 000 записей, что соответствует общепринятым рекомендациям к объемам набора данных для обеспечения более высокой точности модели при ее обучении. Количество записей определяет диапазон изменения индекса j (см. формулы (9)–(15)). Пример полученного входного набора показан в табл. 2.

После получения массива исходных данных на языке программирования (ЯП) Python с использованием предназначенных для задач машинного обучения библиотек TensorFlow, Keras и Scikit-learn была реализована программа построения модели СНС. Для нее входной набор был разделен на обучающий и тестовый в соотношении 4:1 (80 % на обучение и 20 % на тест). Для оценки производительности модели была выбрана метрика ассигасы (измеряет процент правильно классифицированных образцов, качество модели). Перед работой СНС в обучающем наборе были проведены проверка на пустые значения и масштабирование признаков.

При разбиении данных использовали параметр `random_state` с целью контроля рандомизации и для гарантии, что каждый раз будем получать одно и то же разделение на тренировочную и тестовую выборки, что важно при наблюдении динамики изменения значения параметра по оценке качества модели в СНС при каждой новой генерации.

Для решения задачи классификации с использованием СНС на данных, которые не являются изображениями, используются одномерные сверточные слои. В Python они реализованы через оператор одномерных сверточных фильтров `Conv1D`. С его помощью происходит извлечение из последовательности значений признаков и их свертка.

На начальной стадии создания СНС, учитывая, что сгенерированный входной набор был получен программно, а не из журналов регистрации объектов ТЭК, можно допустить, что она будет содержать не большое количество слоев. Моделирование допускает внутри СНС два сверточных слоя: слой подвыборки и плотный (полносвязный) слой. Результаты моделирования в СНС будут находиться в выходном слое. В дальнейшем, по мере увеличения количества реальных данных во входном наборе, число слоев в ней можно будет увеличить.

Для создания СНС с двумя сверточными слоями будем использовать следующую последовательность действий:

1. Добавляем последовательно первый и второй сверточный слой. Для каждого из них используем 64 фильтра, ядро размером 3 и функцию активации ReLU, которая используется для глубоких нейронных сетей.
2. Для обработки одномерных данных добавляем слой подвыборки (слой пулинга) с размером

Таблица 2. Пример входного набора СНС
Table 2. An example of an input set for CNN

Давление Pressure	Влажность Humidity	Электриче- ское поле Electric field	Магнитное поле Magnetic Field	Пыль Dust	Сера Sulfur	Мышьяк Arsenic	Сурьма Antimony	Сероводород Hydrogen Sulfide	Вибрация Vibration	Класс готовности Readiness class
631	46	0,1279	76,939	7,938	6,410	0,036	0,082	1,321	0,724	4
672	48	10,746	376,566	5,123	3,342	0,029	0,127	6,168	0,915	2
685	49	3,429	277,475	7,041	1,715	0,011	0,212	0,879	0,069	1
633	52	7,546	77,886	8,630	4,202	0,003	0,138	10,492	0,265	3
671	86	6,691	115,738	4,346	0,149	0,036	0,153	2,951	0,466	2
737	42	3,412	221,173	11,782	2,898	0,048	0,143	3,952	0,009	1
661	54	8,802	336,984	10,734	4,265	0,039	0,144	8,214	0,376	2
631	89	10,636	298,427	10,061	3,326	0,026	0,018	8,105	0,151	3
780	44	5,291	192,099	1,049	0,636	0,017	0,025	4,466	0,007	3
762	50	5,228	290,546	3,721	3,194	0,031	0,005	11,666	0,111	1
776	30	8,529	5,35488	0,339	0,149	0,029	0,109	4,298	0,056	2
719	61	11,793	302,342	7,615	7,119	0,025	0,101	5,965	0,063	2
704	98	1,443	214,605	11,398	2,859	0,039	0,131	8,068	0,079	3

окна пулинга 2. Пулинг — один из типов техники скользящего окна, где используется статистическая функция некоторого типа для сокращения объема данных. Скользящее окно (условный квадрат или вектор из данных), называемое фильтром, является входом некоторой функции, значение которой затем используется сетью в качестве нового входного параметра. Если размер входа (n, n) или (n) , то на следующем этапе сеть заменит его на 1 значение функции-фильтра. В данном случае (n) будет размером окна пулинга. Будем использовать функцию $\max_2(x_{j1}, x_{j2})$ для так называемого максимального пулинга. Это означает, что функция в слое будет выбирать максимальное значение из каждых 2 соседних элементов в последовательности, например (x_{j1}, x_{j2}) .

3. Преобразуем с помощью оператора сглаживания слоя Flatten() полученные на предыдущем шаге выходы сверточных слоев в одномерный вектор.

4. Добавляем полносвязный слой со 100 нейронами и функцией активации ReLU для нелинейного преобразования признаков после пулинга.

5. При обучении СНС с большим количеством параметров она может слишком точно запоминать данные обучающего набора. Тогда на новых, ранее не вводимых данных, она будет делать неправильные выводы. Для предотвращения спонтанного и незапланированного переобучения модели СНС (регуляризации) добавляем так называемый слой выпадения с помощью оператора языка Python Dropout(). Здесь же устанавливаем вероятность исключения нейронов 0,5.

6. Добавляем выходной слой с 9 нейронами и функцией активации softmax для многоклассовой классификации.

Созданная таким образом СНС на ЯП Python должна пройти компиляцию и апробацию. Для этого сначала компилируем ее со следующими значениями параметров:

- `optimizer='adam'` — тип оптимизатора (выбран градиентный оптимизатор из модуля Keras ЯП Python); используется во многих СНС для обновления весов при преобразовании значений признаков в модели во время обучения;
- `loss='categorical_crossentropy'` — функция потерь для задач многоклассовой классификации с категориальным выходом; нам необходимо иметь при обучении более чем два класса состояния датчиков;
- `metrics=['accuracy']` — оператор задает различные метрики при работе СНС, позволяющие отслеживать процесс ее обучения; выбираем одну метрику «ассигасу» для отслеживания точности во время обучения.

После компиляции проводим апробацию, представляющую собой сам процесс обучения СНС на обучающем наборе (80 % строк от входного). Для этого, помимо перечисленных, выше задаем дополнительное условие, которое заключается в следующем.

Процесс обучения модели должен быть остановлен до обработки всех строк обучающего набора в случае, если интерпретатор ЯП Python, в котором будет выполняться модель, зафиксирует, что модель

Таблица 3. Результаты обучения модели СНС**Table 3.** Learning results of the CNN model

Эпоха Epoch of training	Время обучения, с Training time, seconds	Accuracy (качество, точность модели quality, accuracy of the model)	Loss (значение функции потерь the value of the loss function)	Val_accuracy (качество, точность модели на валидационной выборке the quality and accuracy of the model based on the validation selection)	Val_loss (значение функции потерь на валидационной выборке the value of the loss function in the validation selection)
1	17	0,3766	1,4694	0,5502	1,0279
2	11	0,5507	1,0123	0,6320	0,8544
3	11	0,6137	0,8941	0,6561	0,8023
4	11	0,6417	0,8291	0,6939	0,7238
5	11	0,6649	0,7729	0,6977	0,7116
6	11	0,6825	0,7449	0,7251	0,6501
...	...	...	...	...	...
93	11	0,8781	0,3005	0,8918	0,2896
94	11	0,8775	0,3086	0,8929	0,2870
95	11	0,8815	0,2964	0,8782	0,3053
96	11	0,8778	0,3104	0,8961	0,2860
97	11	0,8819	0,2973	0,8858	0,2953
98	11	0,8812	0,2945	0,8907	0,3047
99	11	0,8801	0,3020	0,8864	0,2941
100	11	0,8779	0,3008	0,8888	0,2994
Итого / Total				0,8910	0,2960

начинает «ухудшаться» на валидационной выборке. Подобная остановка обучения предусмотрена для предотвращения переобучения СНС. В связи с этим предусмотрена остановка обучения в случае, если интерпретатор ЯП Python установит, что значение функции потерь на валидационном наборе (val_loss) не будет уменьшаться в течение 10 эпох подряд.

Полученная таким образом СНС обучается в течение 100 эпох (итераций по обучающему набору данных) с использованием оптимизатора adam и параметра categorical_crossentropy функции потерь, учитывая, что нам необходимо иметь на выходе 10 классов готовности ТХД. Для контроля полученных при ее обучении результатов используется тестовый набор (20 % строк от входного), подключаемый интерпретатором ЯП Python для формирования метрик точности обучения в конце каждой эпохи. Динамика результатов обучения модели показана в табл. 3.

Итоговое значение метрики ассурасу (качество модели) составило 0,8910 (модель правильно классифицирует 89 % образцов), а значение функции потерь — 0,2960 (средняя ошибка модели на данных). Учитывая случайный характер генерации исходного набора данных и отсутствие шага донна-

стройки параметров модели, полученные результаты позволяют сделать вывод об адекватности функционирования модели и соответствия результатов поставленной в задаче цели.

Выводы

Полученные при моделировании результаты показывают, что даже сгенерированные случайным образом значения признаков СНС позволяют добиться ее адекватности в предсказании состояний датчиков в подсистемах АСПВБ по предотвращению пожаров и взрывов. Это подтверждает тезис о необходимости включения в комплекс средств поддержки управления ЛПР объектов ТЭК систем ИИ, которые в современных условиях помогут ему более оперативно принимать решения об изменениях дисциплины ТО в любых системах информирования первого уровня АСУТП.

Применение полученных результатов математического и программного моделирования является актуальным и дает возможность в дальнейшем проводить такие же исследования для различных других типов исходных данных: типов приборов, объектов классификации, процессов управления с известными ЛПР метриками и т.п.

СПИСОК ИСТОЧНИКОВ

1. Юсупова Д.М. Аспекты внедрения искусственного интеллекта в цифровую трансформацию экономики и в системы электронного правительства // Экономика и социум. 2023. № 4 (107)-2. С. 801–815. URL: www.iucr.ru
2. Шкодырев В.П. Эволюция в кибернетике: управление, основанное на знаниях // Системный анализ в проектировании и управлении : сб. науч. тр. XXVI Междунар. науч.-практ. конф. В 3-х частях. Санкт-Петербург, 2023. С. 51–58. DOI: 10.18720/SPBPU/2/id23-34
3. Топольский Н.Г. Основы автоматизированных систем пожаровзрывобезопасности объектов. М. : МИПБ МВД России, 1997. 164 с.
4. Абросимов А.А., Топольский Н.Г., Федоров А.В. Автоматизированные системы пожаровзрывобезопасности нефтеперерабатывающих производств. М. : МИПБ МВД России, 1999. 244 с.
5. Федоров А.В., Гаплаев А.А.-Б., Топольский Н.Г., Самарин И.В. Автоматизация контроля и испытаний систем управления противопожарной защитой объектов топливно-энергетического комплекса / ред. А.В. Федоров. М. : РГУ нефти и газа (НИУ) им. И.М. Губкина, Академия ГПС МЧС России, 2019. 183 с.
6. Быкова В.Н., Ким Е., Гаджиалиев М.Р., Мусиенко В.О., Оруджев А.О., Туровская Е.А. Применение цифрового двойника в нефтегазовой отрасли // Актуальные проблемы нефти и газа. 2020. Вып. 1 (28). С. 8. DOI: 10.29222/ipng.2078-5712.2020-28.art8
7. Бутузов С.Ю., Пранов Б.М., Прус Ю.В., Семиков В.Л., Яковлев О.В. Модель оценки устойчивости автоматизированных систем пожаровзрывобезопасности // Пожаровзрывобезопасность/Fire and Explosion Safety. 2017. Т. 26. № 6. С. 14–20. DOI: 10.18322/PVB.2017.26.11.14-20. EDN YMCOHG.
8. Аблаев Р.Р., Абрамова Л.С., Аблаев А.Р. Импортзамещение и реструктуризация экспортных потоков в области высокотехнологического производства // Московский экономический журнал. 2023. № 3. С. 216–229. DOI: 10.55186/2413046X_2023_8_3_130
9. Крылов А.А. Исследование неустойчивости дрейфа нуля МЭМС-гироскопов и способов ее учета при калибровке // Известия Тульского государственного университета. Технические науки. 2020. Вып. 1. С. 64–69.
10. Abdullah Al-hammadi S.R.A., Liang Y. A review study on methane gas sensors // North American Academic Research. 2021. Vol. 4. Issue 5. Pp. 303–309. DOI: 10.5281/zenodo.4884736
11. Губенко А.М. Подходы к применению технологий искусственного интеллекта для решения задач автоматизированного управления в сложных организационно-технических системах // Техника средств связи. 2023. № 4 (164). С. 66–71. DOI: 10.24412/2782-2141-2023-4-66-71
12. Харитонова Ю.С., Савина В.С., Паньини Ф. Предвзятость алгоритмов искусственного интеллекта: вопросы этики и права // Вестник Пермского университета. Юридические науки. 2021. Вып. 53. С. 488–515. DOI: 10.17072/1995-4190-2021-53-488-515. EDN EUKCPY.
13. Ikram Ben Ahmed I, Wael Ouarda, Chokri Ben Amar, Khouloud Boukadi. DEES-breast: deep end-to-end system for an early breast cancer classification // Evolving Systems. 2024. Vol. 15. Pp. 1845–1863. DOI: 10.1007/s12530-024-09582-9
14. Sourour Brahimi, Ibrahim Soumaya, Chokri Ben Amar. An object recognition method based on deep BCNN with Reinforced Dense Blocks, Conference : 2023 International Conference on Cyberworlds (CW), October 2023. DOI: 10.1109/CW58918.2023.00044
15. Rim Fakhfakh, Anis Ben Ammar, Chokri Ben Amar. Deep Learning-Based Recommendation: Current Issues and Challenges // (IJACSA) International Journal of Advanced Computer Science and Applications. 2017. Vol. 8. No. 12. DOI: 10.14569/IJACSA.2017.081209
16. Zeineb Daoud, Amal Ben Hamida, Chokri Ben Amar. Fire object detection and tracking based on deep learning model and Kalman filter // Arabian Journal for Science and Engineering. 2023. No. 49 (6). DOI: 10.1007/s13369-023-08127-7
17. Velibor Božić. Machine learning vs deep learning, March 2024. DOI: 10.13140/RG.2.2.16632.21762
18. Shams Forruque Ahmed, Md. Sakib Bin Alam, Maruf Hassan, Mahtabin Rodela et al. Deep learning modelling techniques: current progress, applications, advantages, and challenges // Artificial Intelligence Review. 2023. No. 56 (11). Pp. 13521–13617. DOI: 10.1007/s10462-023-10466-8
19. Топольский Н.Г., Самарин И.В., Строгонов А.Ю. Методика оценки готовности к работе оборудования АСПВБ первого уровня информирования на объектах ТЭК в особых условиях // Пожаровзрывобезопасность/Fire and Explosion Safety. 2019. Т. 28. № 1. С. 35–46. DOI: 10.18322/PVB.2019.28.01.35-46. EDN QHUIWX.
20. Топольский Н.Г., Самарин И.В., Строгонов А.Ю. Модель оценки обеспечения комплексной безопасности в АСУТП с применением диагностики пожарных извещателей для построения автоматизированной системы поддержки управления пожаровзрывобезопасностью // Пожаровзрывобезопасность/Fire and Explosion Safety. 2018. Т. 27. № 11. С. 15–22. DOI: 10.18322/PVB.2018.27.11.15-22

REFERENCES

1. Yusupova D.M. Aspects of the introduction of artificial intelligence into the digital transformation of the economy and into electronic government systems. *Economics and Society*. 2023; 4(107-2):801-815. URL: www.iupr.ru (rus).
2. Shkodyrev V.P. Evolution in cybernetics: knowledge-based management. *System analysis in design and management. Collection of scientific papers of the XXVI International Scientific and Practical Conference. In 3 parts*. Saint Petersburg, 2023; 51-58. DOI: 10.18720/SPBPU/2/id23-34 (rus).
3. Topolsky N.G. *Fundamentals of automated fire and explosion safety systems for facilities*. Moscow, MIPB of the Ministry of Internal Affairs of Russia, 1997; 164. (rus).
4. Abrosimov A.A., Topolsky N.G., Fedorov A.V. *Automated fire and explosion safety systems for oil refineries*. Moscow, MIPB of the Ministry of Internal Affairs of Russia, 1999; 244. (rus).
5. Fedorov A.V., Gaplaev A.A.-B., Topolsky N.G., Samarin I.V. *Automation of control and testing of fire protection control systems for fuel and energy complex facilities* / Ed. by A.V. Fedorov. Moscow, Gubkin Russian State University of Oil and Gas (NRU), Academy of GPS of the Ministry of Emergency Situations of Russia, 2019; 183. (rus).
6. Bykova V.N., Kim E., Gadzhialiev M.R., Musienko V.O., Orujev A.O., Turovskaya E.A. The use of a digital double in the oil and gas industry. *Actual problems of oil and gas*. 2020; 1(28):8. DOI: 10.29222/ipng.2078-5712.2020-28.art8 (rus).
7. Butuzov S.Yu., Pranov B.M., Prus Yu.V., Semikov V.L., Yakovlev O.V. A model for assessing the stability of automated fire and explosion safety systems. *Pozharovzryvbezopasnost/Fire and explosion safety*. 2017; 26(6):14-20. DOI: 10.18322/PVB.2017.26.11.14-20. EDN YMCOHG. (rus).
8. Ablaev R.R., Abramova L.S., Ablaev A.R. Import substitution and restructuring of export flows in the field of high-tech production. *Moscow Economic Journal*. 2023; 3:216-229. DOI: 10.55186/2413046X_2023_8_3_130 (rus).
9. Krylov A.A. Study of the instability of the zero drift of MEMS gyroscopes and ways of accounting for it during calibration. *Proceedings of Tula State University. Technical Sciences*. 2020; 1:64-69. (rus).
10. Abdullah Al-hammadi S.R.A., Liang Y. A Review Study on Methane Gas Sensors. *North American Academic Research*. 2021; 4(5):303-309. DOI: 10.5281/zenodo.4884736
11. Gubenko A.M. Approaches to the use of artificial intelligence technologies for solving automated control problems in complex organizational and technical systems. *Technology of communication tools*. 2023; 4(164):66-71. DOI: 10.24412/2782-2141-2023-4-66-71 (rus).
12. Kharitonova Yu.S., Savina V.S., Pagnini F. Bias of artificial intelligence algorithms: issues of ethics and law. *Bulletin of the Perm University. Legal sciences*. 2021; 53:488-515. DOI: 10.17072/1995-4190-2021-53-488-515. EDN EUKCPY. (rus).
13. Ikram Ben Ahmed1, Wael Ouarda, Chokri Ben Amar, Khoulood Boukadi. DEES-breast: deep end-to-end system for an early breast cancer classification. *Evolving Systems*. 2024; 15:1845-1863. DOI: 10.1007/s12530-024-09582-9
14. Sourour Brahimi, Ibrahim Soumaya, Chokri Ben Amar. *An object recognition method based on deep BCNN with Reinforced Dense Blocks, Conference : 2023 International Conference on Cyberworlds (CW)*. October 2023. DOI: 10.1109/CW58918.2023.00044
15. Rim Fakhfakh, Anis Ben Ammar, Chokri Ben Amar. Deep Learning-Based Recommendation: Current Issues and Challenges. *IJACSA International Journal of Advanced Computer Science and Applications*. 2017; 8(12). DOI: 10.14569/IJACSA.2017.081209
16. Zeineb Daoud, Amal Ben Hamida, Chokri Ben Amar. Fire object detection and tracking based on deep learning model and Kalman filter. *Arabian Journal for Science and Engineering*. 2023; 49(6). DOI: 10.1007/s13369-023-08127-7
17. Velibor Božić. *Machine learning vs deep learning*. March 2024. DOI: 10.13140/RG.2.2.16632.21762
18. Shams Forruque Ahmed, Md. Sakib Bin Alam, Maruf Hassan, Mahtabin Rodela et al. Deep learning modelling techniques: current progress, applications, advantages, and challenges. *Artificial Intelligence Review*. 2023; 56(11):13521-13617. DOI: 10.1007/s10462-023-10466-8
19. Topolsky N.G., Samarin I.V., Stroganov A.Yu. Methodology for assessing the readiness for operation of first-level information security equipment at fuel and energy complex facilities in special conditions. *Pozharovzryvbezopasnost/Fire and explosion safety*. 2019; 28(1):35-46. DOI: 10.18322/PVB.2019.28.01.35-46. EDN QHUIWX. (rus).
20. Topolsky N.G., Samarin I.V., Stroganov A.Yu. A model for assessing integrated safety in automated process control systems using fire detectors diagnostics to build an automated fire and explosion safety management support system. *Pozharovzryvbezopasnost/Fire and explosion safety*. 2018; 27(11):15-22. DOI: 10.18322/PVB.2018.27.11.15-22 (rus).

Поступила 15.07.2024, после доработки 28.07.2024;

принята к публикации 01.08.2024

Received July 15, 2024; Received in revised form July 28, 2024;

Accepted August 1, 2024

Информация об авторах

САМАРИН Илья Вадимович, д.т.н., доцент, заведующий кафедрой автоматизации технологических процессов, Российский государственный университет нефти и газа (национальный исследовательский университет) имени И. М. Губкина, Россия, 119991, г. Москва, Ленинский пр-т, 65, корп. 1; РИНЦ ID: 867674; ORCID: 0000-0003-2430-5311; e-mail: ivs@gubkin.ru

СТРОГОНОВ Андрей Юрьевич, старший преподаватель кафедры автоматизации технологических процессов, Российский государственный университет нефти и газа (национальный исследовательский университет) имени И. М. Губкина, Россия, 119991, г. Москва, Ленинский пр-т, 65, корп. 1; РИНЦ ID: 936562; ORCID 0000-0001-7994-5987; e-mail: strogonov.a@gubkin.ru

КРЮЧКОВ Алексей Вячеславович, к.т.н., доцент кафедры комплексной безопасности критически важных объектов, Российский государственный университет нефти и газа (национальный исследовательский университет) имени И. М. Губкина, Россия, 119991, г. Москва, Ленинский пр-т, 65, корп. 1; РИНЦ ID: 1047095; ORCID 0000-0002-5665-7058; e-mail: kruchkov.v@gubkin.ru

Вклад авторов:

Самарин И.В. — научное руководство; доработка текста; итоговые выводы.

Строгонов А.Ю. — концепция исследования; проведение экспериментов и моделирования; разработка программы для проведения расчетов и оценки результатов; написание исходного текста; итоговые выводы.

Крючков А.В. — доработка текста; проверка корректности и адекватности проводимых экспериментов и моделирования; тестирование программы для проведения расчетов и оценки результатов; итоговые выводы.

Авторы заявляют об отсутствии конфликта интересов.

Information about the authors

Ilya V. SAMARIN, Dr. Sci. (Eng.), Docent, Head of Department of Automation of Technological Processes, Gubkin Russian State University of Oil and Gas (National Research University), Leninskiy Avenue, 65, Bldg. 1, Moscow, 119991, Russian Federation; ID RISC: 867674; ORCID: 0000-0003-2430-5311; e-mail: ivs@gubkin.ru

Andrey Yu. STROGONOV, Senior Lecturer of Department of Automation of Technological Processes, Gubkin Russian State University of Oil and Gas (National Research University), Leninskiy Avenue, 65, Bldg. 1, Moscow, 119991, Russian Federation; ID RISC: 936562; ORCID 0000-0001-7994-5987; e-mail: strogonov.a@gubkin.ru

Aleksey V. KRYUCHKOV, Cand. Sci. (Eng.), Associate Professor of Department of Integrated Security of Critical Facilities, Gubkin Russian State University of Oil and Gas (National Research University), Leninskiy Avenue, 65, Bldg. 1, Moscow, 119991, Russian Federation; ID RISC: 1047095; ORCID 0000-0002-5665-7058; e-mail: hook66@list.ru

Contribution of the authors:

Samarin I. V. — scientific guidance; revision of the text; final conclusions.

Strogonov A. Yu. — concept of the study; conducting experiments and modeling; developing a program for calculations and evaluation of results; writing the source text; final conclusions.

Kruchkov A. V. — revision of the text; verification of the correctness and adequacy of the experiments and simulations; testing of the program for calculations and evaluation of the results; final conclusions.

The authors declare no conflicts of interests.