2022

№ 2

МОНИТОРИНГОВЫЕ СИСТЕМЫ В ГОРНОМ ДЕЛЕ

УДК 622.864

СИСТЕМА МОНИТОРИНГА МЕСТОПОЛОЖЕНИЯ ГОРНОРАБОЧИХ НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ И ИНТЕРНЕТА ВЕЩЕЙ

Т. С. Джетинкая¹, С. Сенан², З. Орман²

¹Стамбульский университет Гелишим, 34000, г. Стамбул, Турция ²Стамбульский университет Джеррахпаша, E-mail: ssenan@iuc.edu.tr, 34320, г. Стамбул, Турция

С помощью технологий сочетания глубокого обучения и интернета вещей разработана система отслеживания горнорабочих с целью выявления их местоположения во время возможной внештатной ситуации. Для анализа ее эффективности проведены испытания и выполнена оценка результативности. Выявлено, что наибольшая точность составила 97%.

Интернет вещей (IoT), отслеживание местоположения горнорабочих, искусственная нейронная сеть, глубокое обучение, LSTM-модель

DOI: 10.15372/FTPRPI20220215

Горнодобывающая промышленность — отрасль производства с высоким риском внештатных ситуаций. При анализе статистики внештатных ситуаций выявлено, что их частота в горнодобывающей промышленности крайне высока. Риск летального исхода при несчастных случаях здесь выше по сравнению с другими видами добычи полезных ископаемых [1, 2]. Благодаря применению постоянно развивающихся технологий, особое значение приобретают превентивные меры предосторожности, в частности создание системы отслеживания местоположения горнорабочих [3–5].

При использовании систем мониторинга на основе глобальной системы позиционирования (GPS) на некоторых участках точность измерения показателей среды может снижаться либо передача данных из центра мониторинга вообще прекращаться. Поэтому при отслеживании местоположения и мониторинге показателей среды стала широко применяться технология интернета вещей (IoT).

Работа выполнена при поддержке Научно-исследовательского проектного подразделения Стамбульского университета Джеррахпаша (проекты № ВҮР-2020-35080, ВҮР-2021-35609).

В общем виде IoT — система, обеспечивающая коммуникацию между двумя взаимосвязанными ЭВМ без влияния со стороны человека в поле информационных технологий [6]. Она связана с такими областями исследований, как технология радиочастотной идентификации (RFID), сеть беспроводных датчиков или межмашинное взаимодействие [5]. Необходимые системы могут быть разработаны во многих областях путем обработки информации, полученной от устройств из сети IoT-систем. Например, в системе мониторинга возможно заранее выделить неблагоприятные ситуации, которые могут произойти, и минимизировать ущерб при наступлении такой ситуации благодаря известному местоположению или окончательному состоянию объекта в системе. IoT-система может быть использована для разработки технологии предотвращения внештатных ситуаций при добыче полезных ископаемых [6-8].

Искусственные нейронные сети (ИНС) служат для решения важных задач во многих областях деятельности: финансовое дело, метеорология, геонауки, медицина, горное дело и др. В горном деле они представляют интерес для многих исследований [9–13]. Следует отметить научные работы, где ИНС и ІоТ используются совместно [14–16]. В последние годы метод глубокого обучения, относящийся к типу многослойной нейронной сети, более предпочтителен ввиду высокого потенциала при работе с большим объемом данных. При этом модели глубокого обучения могут меняться в зависимости от решаемой проблемы.

В настоящей работе система быстрого определения местоположения рабочего в случае внештатной ситуации в шахте спроектирована с помощью технологий IoT и глубокого обучения с целью представления полезной информации для поисково-спасательной деятельности. Контрольные приемники, распределенные в шахте, считывают показатель силы принимаемого сигнала (RSSI), отправляемого из передатчика, находящегося у рабочего. Расстояние между рабочим и ближайшим контрольным приемником рассчитывается по формуле из [17] на основе данных RSSI по отслеживанию рабочих. Тем не менее при изменении показателей окружающей среды рассчитанное расстояние уменьшается и нужно вводить в применяемую формулу коэффициент окружающей среды k либо воспользоваться моделью долгой краткосрочной памяти (LSTM), основанной на методе глубокого обучения и автоматической оценке коэффициента k. Для работы LSTM необходим сбор информации, включающий значения RSSI, коэффициенты окружающей среды и рассчитанные расстояния, после чего она определяет оптимальное значение k.

ОБЗОР ЛИТЕРАТУРЫ

Развитие электронных устройств и технологий беспроводной связи позволяет разрабатывать новые методы обеспечения безопасности в шахтах и осуществлять управление на горнодобывающих предприятиях. Технологии мониторинга — обязательная составляющая подземной добычи полезных ископаемых. В [18] дан обзор технологий позиционирования в условиях шахт.

Мониторинг показателей среды осуществляется датчиками, входящими в беспроводную сеть, установленную в шахте [19, 20]. Для отслеживания местоположения рабочих применяются технологии радиочастотной идентификации, широкополосной связи (UWB) и инерциальной навигационной системы [21, 22]. В [7] для разработки эффективной системы связи в шахте с целью мониторинга параметров среды и отслеживания местоположения рабочих с помощью беспроводной сети датчиков используется ІоТ-технология. В шахте при добыче образуются различные вредные вещества, из-за удаления которых могут произойти внештатные ситуации, что требует принятия определенных мер. В [8] предложен мониторинг отвалов отходов в режиме реального времени и система предварительного оповещения их состояния на основе IoT и облачных вычислений (CC). В [9] для решения угрозы выброса метана использованы локальные линейные модели и модель ARIMA. С целью минимизации повреждений в шахте при взрывных работах применялся метод множественной регрессии и ИНС таким образом, чтобы в результате взрывов минеральные породы раскалывались на большие куски, а не на мелкие обломки [10]. В [11] изучена безопасность работы в условиях природных угроз, вызванных повышенным давлением воздуха в шахте при взрывных работах. Для оценки уровня угрозы волн, возникающих из-за взрыва, обоснован метод, в основе которого лежит нейронная сеть, построенная по принципу работы головного мозга.

В [12, 13] для оценки амплитуд главного горизонтального напряжения на основе выходных данных бурения предложено сочетать ИНС и критерий разрушения породы. Разработана модель машинного обучения для прогнозирования максимального горизонтального напряжения с учетом данных по вывалу породы. Ввиду ограниченности экспериментальных данных имелись трудности при определении минимального горизонтального напряжения и использовалась ИНС-модель и критерий разрушения породы Кулона для прогнозирования амплитуд горизонтального напряжения.

В [14] для выбора метода подземной добычи применены ИНС и теории игр. При построении модели бо́льший приоритет получили условия обеспечения безопасности в шахте. Исходя из условий в шахте, свойств массива пород, природных факторов и условий вентиляции для выявления наиболее подходящего метода добычи разработаны шесть ИНС-моделей.

Прогнозирование возможных происшествий в шахтах может осуществляться с помощью мониторинга данных сейсмической активности. Технологии глубокого обучения при анализе данных с датчиков позволяют получать надежные результаты. Области с микросейсмической активностью в районе шахты обнаруживаются сверточными нейронными сетями [23–25].

Для решения инженерных задач служат различные ИНС-модели: длинная короткосрочная память (LSTM), глубокая сеть доверия (DBN) и искусственная углеводородная сеть (AHN) [15, 16, 26, 27]. В области горного дела есть работы совместного применения искусственной нейронной сети и интернета вещей. Для выявления отказов кранового оборудования в шахте рекомендован метод, основанный на ІоТ и ИНС, состоящей из трех слоев (обнаружения, сетевого, применения) [28]. С помощью ІоТ собираются данные с датчиков, установленных на отвалах пустой породы, и осуществляется их мониторинг в режиме реального времени [29]. Установка системы предварительного оповещения выполнялась с помощью нейронной сети генеральной регрессии (GM-GRNN) и модели Грея, построенной на облачной платформе. Для мониторинга качества воздуха и прогнозирования факторов его загрязнения в угольных шахтах применяется машинное обучение "Azure" (AML) на платформе "Studio" [30]. На основе Arduino установлены сенсорные модули, включенные в ІоТ-сеть, а для прогнозирования на AML-платформе использован ИНС-метод многослойного восприятия (ML-ANN). В табл. 1 представлен анализ научных работ по применению технологий IoT, ИНС или их сочетаний. Выявлено, что IoT часто рассматривается в контексте систем мониторинга в горном деле. В последние годы широкое распространение получили различные ИНС-модели и системы в сочетании с IoT. Цель настоящей работы — разработка системы отслеживания горнорабочих с помощью сочетания подхода глубокого обучения, являющегося многослойной ИНС-моделью, и технологии IoT.

Год публикации, источник	Область знаний	Метод	
2016 [3]	Алгоритм отслеживания рабочих в подземных условиях	IoT	
2016 [4]	Умный датчик и система отслеживания для подземной добычи	ΙοΤ	
2019 [7]	Мониторинг среды, отслеживание рабочих, диспетчерское наблюдение и подземная беспроводная система связи	IoT, система связи Wi-Fi Ad Hoc	
2012 [8]	Безопасность отвалов, мониторинг отвалов хвостов и система предварительного оповещения (TDMPAS)	IoT, облачные вычисления (СС)	
2016 [10]	Прогнозирование объема больших кусков, образованных в результате взрывных работ в открытой выработке	Метод множественной регрессии, ИНС	
2020 [11]	Прогнозирование превышения давления воздуха	Нейронная сеть, построенная по принципу головного мозга (BI-ENN)	
2020 [12]	Оценка амплитуд главного горизонтального напряжения по данным обрушения стенок скважины	ИНС, подход Моги – Кулона	
2020 [14]	Разработка метода подземной добычи	ИНС, теория игр	
2018 [23]	Обнаружение микросейсмических событий и определение их местоположения в шахтах	Сверточные нейронные сети, глубокое обучение	
2021 [24]	Обнаружение и определение местоположения микросейсмических событий	Глубокие нейронные сети	
2020 [25]	Автоматическое обнаружение микросейсмических событий по данным с распределенных акустических датчиков, установленных в скважинах	Сверточные нейронные сети	
2018 [28]	Разработка метода диагностики шахтного кранового оборудования	Самоорганизующиеся карты (SOM), ІоТ	
2017 [29]	Разработка системы предварительного оповещения для безопасности отвалов пустых пород	Нейронная сеть генеральной регрессии (GRNN), IoT	
2018 [30]	Мониторинг качества воздуха в шахте и прогнозирование факторов его загрязнения	Многослойная нейронная сеть, IoT	

ТАБЛИЦА 1. Научные работы в сфере горного дела по применению технологий ІоТ, ИНС и их сочетания

АНАЛИЗ МАТЕРИАЛОВ И МЕТОДОВ

Интернет вещей. ІоТ-технологии позволяют управлять электрическими устройствами, подключенными к общей сети датчиков, и применяются в энергетике, медицине, транспорте, сельском хозяйстве, а также для отслеживания объектов и в системах оповещения [31]. Системы GPS, определяющие местоположение объектов через спутники, наиболее предпочтительны благодаря высокой точности при позиционировании в стационарных условиях. Однако они не всегда подходят из-за проблем соединения со спутником при отслеживании местоположения внутри сооружений (внутреннее позиционирование), поэтому актуальны компактные IoT-устройства, работающие на протоколах беспроводной связи [32].

Показатель силы принимаемого сигнала (RSSI). В системах, спроектированных для отслеживания внутреннего местоположения, используется значение RSSI, показывающее силу принимаемого сигнала от IoT-устройств. В основе отслеживания местоположения лежат изменения силы принимаемого сигнала в зависимости от расстояния его распространения [33]. В настоящей работе получены значения RSSI в трех средах: наружной (улица), внутренней (помещение) и подземной (шахта). Местоположение рабочего, т. е. расстояние от рабочего до ближайшего контрольного приемника, рассчитывается по формуле [17]:

$$r = 1 + \left(\frac{-P_r - k - P_0}{20}\right)^{10},\tag{1}$$

где P_r — значение RSSI от передатчика, находящегося у рабочего, дБм; k — коэффициент среды; P_0 — инструментальная погрешность, дБм. Коэффициенты k, инструментальная погрешность P_0 определяются на основе опыта.

Глубокое обучение. Оно представляет собой ИНС с многослойной структурой и является методом машинного обучения, обеспечивающим эффективные результаты в таких областях, как обработка изображений, опознавание речи и обработка языка. Глубокое обучение служит для выявления взаимозависимостей в массиве данных.

Существуют различные системы, в основе которых лежит совместное использование ІоТ-технологий и глубокого обучения. Глубокое обучение описано в научных работах, рассматривающих ІоТ для анализа данных с датчиков, прогнозирования взаимозависимости между данными. Модель глубокого обучения LSTM применяется для оценки данных во временных отрезках в IoT-системах [27, 34].

На рис. 1 представлены структуры простой и глубокой нейронных сетей. Простая сеть представляется тремя слоями: входным, скрытым и выходным. Информация проходит из входного слоя в выходной через скрытый. Сложные искусственные нейронные сети с несколькими скрытыми слоями необходимы для решения проблемы оценки и классификации большого объема данных. Структуры ИНС, содержащие более трех скрытых слоев, называются глубокими нейронными сетями, а процесс их обучения — глубоким обучением. В данной работе поставлена цель разработать систему отслеживания местоположения горнорабочих по данным, полученным с беспроводных датчиков с течением времени. Как отмечалось, коэффициент среды k для определения местоположения рабочего определяется вручную. Предложена LSTM-модель для автоматического его вычисления.



Рис. 1. Структура простой (а) и глубокой (б) нейронных сетей

Долгая краткосрочная память (LSTM). Рекуррентные нейронные сети (PHC) используются для обработки данных, полученных во временных отрезках. Временные отрезки набор данных, находящихся в состоянии постоянного изменения в зависимости от времени и может отсортировываться по временному признаку. В PHC создается замкнутая структура путем возвратно-поступательных операций: на выход поступают данные с предыдущего временного отрезка. Во время обратного процесса возникают ситуации, когда требуется большое количество данных с предыдущего временного отрезка, вызванные уменьшением или занулением производной функции или ее увеличением до очень больших значений. Процесс обучения PHC в этом случае осложняется. Разработана архитектура LSTM, содержащая входной слой, выходной слой и слой забывания, отсутствующий в структуре PHC [35, 36]. В LSTM присутствует система фильтров для удаления из памяти предыдущих данных, не нуждающихся в обработке. С помощью фильтра выявляются данные для хранения в памяти модели. На рис. 2 показана структура LSTM-модели, состоящая из трех фильтров: входного, забывания и выходного.



Рис. 2. Архитектура LSTM-модели

В архитектуре LSTM-модели x_t показывает поток x временных отрезков через слой LSTM, h_t , c_t — состояние ячейки памяти на выходе в момент шага t соответственно, f — фильтр забывания, g — кандидат на доступ к ячейке, i, o — входной и выходной фильтры. Функция фильтра забывания, как первого фильтра в архитектуре LSTM, — выявление информации, которую необходимо удалить из ячеек памяти. Данный фильтр определяет, какое количество информации, содержащейся в ячейке памяти c_{t-1} в предыдущий момент, пройдет в ячейку c [21]. Оно подчиняется уравнению

$$f_t = \sigma_g (W_f x_t + R_f h_{t-1} + b_f),$$

где W — весовая матрица обучения; R — рекуррентные весовые значения; b — состояние отклонения; σ — логистическая сигмоидная функция.

Входной фильтр определяет количество новой информации, способное войти в ячейку памяти в данный момент:

$$i_t = \sigma_g (W_i x_t + R_i h_{t-1} + b_i)$$

и поступить в выходной фильтр

$$o_t = \sigma_g (W_o x_t + R_o h_{t-1} + b_o)$$

Величина *g* обозначает кандидата на доступ к ячейке:

$$g_t = \sigma_g (W_g x_t + R_g h_{t-1} + b_g) \, .$$

В LSTM-модели для получения оптимального значения коэффициента среды k используются три входных нейрона: тип среды (улица, помещение, подземная среда), рассчитанное расстояние и фактическое расстояние.

Набор данных. Сбор данных для экспериментальной системы отслеживания рабочих осуществляется с помощью передатчика, находящегося в шахте у рабочего, контрольного приемника и центрального приемника (центр мониторинга). Для физического моделирования шахтной среды значения RSSI измеряются в областях, именуемых средой в наборе данных: внутренняя область (помещение), подземная и наружная область (улица). Количество галерей, передатчиков и приемников меняется в зависимости от среды.

Набор собранных данных соответствует следующим условиям:

— стационарные контрольные приемники связаны с центром мониторинга;

— у каждого работника есть передатчик, транслирующий RSSI-сигнал;

— сигналы, транслируемые от передатчиков, передаются в центр мониторинга через контрольные приемники;

— расстояние между рабочим и ближайшим контрольным приемником вычисляется по формуле (1).

Набор данных при каждом измерении включает такие параметры, как уникальный идентификационный номер (ID), среда проведения измерения, коэффициент среды k, инструментальная погрешность P_0 , фактическое и рассчитанное расстояние, разница значений. В табл. 2 представлен фрагмент собранного набора данных.

	ç	k	P_0	Расстояние, см		_
ID	Среда			фактическое	рассчитанное	Разница, см
1	1	22	25	150	151	1
2	1	22	25	150	170	20
3	1	22	25	150	144	-6
4	1	22	25	200	170	-30
67	2	19	23	150	150	0
68	2	19	23	150	156	6
69	2	19	23	150	154	4
70	2	19	23	200	189	-11
132	3	18	23	150	131	-19
133	3	18	23	150	128	-22
134	3	18	23	150	150	0
135	3	18	23	200	200	0

ТАБЛИЦА 2. Фрагмент набора данных

Полный набор данных включает значения расстояний, полученных в результате 225 измерений при разных расстояниях и в разной среде. На улице выполнено 76 измерений, в помещении — 84, под землей — 65. На рис. 3 приведено сравнение фактических и рассчитанных расстояний.



Рис. 3. Фактическое и рассчитанное расстояние для улицы (*a*), помещения (б) и подземной среды (*в*): черные столбцы — фактическое расстояние между передатчиком и контрольным приемником в ходе испытаний; белые — расстояния, рассчитанные по формуле (1)

ПРЕДЛАГАЕМАЯ СИСТЕМА

Спроектирована система отслеживания местоположения рабочих для шахтных условий (рис. 4). В зависимости от среды использования системы количество галерей, передатчиков и контрольных приемников может меняться. Контрольные приемники связаны с единым центром мониторинга. Каждый рабочий имеет передатчик для передачи RSSI-сигнала. Через контрольные приемники этот сигнал направляется в центр мониторинга. На их основе определяется расстояние между рабочим и ближайшим контрольным приемником. Так как контрольные приемники стационарные, расчет расстояния от рабочего до приемника не представляет сложности.



Рис. 4. Принципиальная схема спроектированной системы отслеживания

Данные для анализа собраны в рамках спроектированной системы. На рассчитанное расстояние оказывают влияние факторы среды, поэтому необходимо дополнительно изменять коэффициент среды k. Разработанная LSTM-модель автоматически оценивает оптимальное значение k. Среда, коэффициент среды, фактическое и рассчитанное расстояние выступают в качестве признаков модели. Для их масштабирования выполнена нормализация, затем определены данные для обучения и проверки (на обучение приходится 70%, на проверку — 30%). Среда, рассчитанное и фактическое расстояния — входные данные, коэффициент k — выходные. В таком виде LSTM-модель прошла обучение. Входной слой состоит из 3 нейронов, скрытый — из 32 LSTM-слоев, выходной — из 1 нейрона (рис. 5). За счет процесса выпадения узлов, в котором найдены ключевые весовые значения, получен плотный слой модели. На выходе система предоставляет оптимальный коэффициент среды k. На основе оценки эффективности модели k рассчитан с точностью 97.14%.



Рис. 5. Структура LSTM-сети: *R* — активация блока линейной ректификации

На рис. 6 представлена блок-схема предлагаемой системы отслеживания местоположения рабочих.



Рис. 6. Блок-схема предлагаемой системы отслеживания местоположения рабочих

РЕЗУЛЬТАТЫ ИСПЫТАНИЙ

LSTM-модель разработана на основе набора данных, полученных IoT-системой, созданной для отслеживания местоположения рабочих. Она прошла испытание, где в качестве выходных данных представлен коэффициент среды для расчета оптимального расстояния между рабочим и ближайшим приемником с целью выявления местоположения рабочего в шахте и обеспечения доступа к нему при возможной внештатной ситуации. Параметрами эффективности выбраны ошибки, необходимые для оценки результатов анализа статистической регрессии.

Для сравнения результатов рассмотрены следующие статистические параметры:

RMSE — отклонение от математического ожидания:

$$\text{RMSE} = \sqrt{\frac{\sum_{j=1}^{n} e_j^2}{n}};$$

МАЕ — измерение точности прогнозируемых результатов:

$$MAE = \frac{1}{n} \sum_{t=1}^{n} \left| e^{t} \right|;$$

МАРЕ — точность в виде процентного соотношения:

MAPE =
$$\frac{100\%}{n} \sum_{t=1}^{n} \frac{e^{t}}{y^{t}};$$

*R*² — пропорция вариации зависимой переменной, прогнозируемая исходя из независимых переменных:

$$R^{2} = 1 - \frac{\sum_{i}^{i} (y_{i} - \hat{y}_{i})^{2}}{\sum_{i}^{i} (y_{i} - \overline{y}_{i})^{2}}.$$

Здесь e — разница между фактическим и спрогнозированным значением; n — количество наблюдений; y, \hat{y} — фактические и спрогнозированные значения соответственно.

Испытания спроектированной LSTM-модели проводились при разных периодах дискретизации. В табл. 3 представлены значения статистических параметров.

Период дискретизации	Точность, %	RMSE	MAE	R^2	MAPE, %
100	94.2857	0.569844	0.0955364	0.581279	0.922194
200	97.1429	0.590166	0.0219730	0.550882	0.620171
500	95.2381	0.657668	0.0113096	0.442268	1.000250
1000	95.2381	0.657668	0.0113096	0.442268	1.000250
5000	77.1429	5.315270	0.0732450	35.430400	12.448800

ТАБЛИЦА 3. Результаты испытаний

Обучение LSTM-модели при разных периодах дискретизации дает различные значения точности. Лучший результат получен при периоде дискретизации 200 (табл. 3). Максимальная точность оценки коэффициента среды составила 97.14%, т. е. спроектированная система отслеживания рабочих может эффективно применяться на практике. На рис. 7 показан график, связанный с потерями обучения и оценкой модели, обучение которой осуществлялось при периоде дискретизации 200. Значения потери используются для демонстрации успешности предлагаемой модели. Снижение потерь со временем говорит о положительных результатах процесса внедрения модели.



Рис. 7. Потери обучения модели при периоде дискретизации 200: *1* — потери, рассчитанные при обучении; *2* — потери оценки спрогнозированных данных

выводы

Разработана система определения местоположения горнорабочих при возникновении внештатной ситуации в шахте. Передача RSSI-сигналов осуществляется передатчиками, находящимися у рабочих. Затем сигналы считываются стационарными контрольными приемниками и передаются в центр мониторинга. На основе данных сигналов определяется расстояние от рабочего до ближайшего контрольного приемника. Выявлено, что такие факторы среды, как ее размер, находящиеся объекты и препятствия, влияют на распространение сигнала, становясь причиной ошибки при расчете расстояния, вследствие чего в применяемую формулу необходимо дополнительно вводить коэффициент среды. Для его автоматической оценки применялась LSTM-архитектура глубокого обучения. Предложена система отслеживания местоположения горнорабочих, использующая технологию интернета вещей, чья точность повышена благодаря применению LSTM-модели.

СПИСОК ЛИТЕРАТУРЫ

- Viktorov S. D., Osokin A. A., and Shlyapin A. Principles of the method of submicron particle emission recording for the accident prediction in underground mineral mining, J. Min. Sci., 2017, Vol. 53, No. 5. — P. 962–966.
- 2. Hudecek V. Analysis of safety precautions for coal and gas outburst-hazardous strata, J. Min. Sci., 2008, Vol. 44, No. 5. P. 464–472.
- 3. Ji W. L. and Sun K. Locating and tracking system of underground miner based on IoT, DEStech Transactions on Eng. Technol. Res., (ICAMM), 2016. P. 320–324.
- 4. Zhang X. Smart sensor and tracking system for underground mining, Ph.D dissertation, University of Saskatchewan, Canada, 2016.
- **5.** Atzori L., Iera A., and Morabito G. Understanding the internet of things: definition, potentials, and societal role of a fast evolving paradigm, Ad Hoc Networks, 2017, Vol. 56. P. 122–140.
- 6. Barnewold L. and Lottermoser B. G. Identification of digital technologies and digitalisation trends in the mining industry, Int. J. Min. Sci. Technol., 2020, Vol. 30, No. 6. P. 747–757.
- Ikeda H., Kawamura Y., Tungol Z. P. L., Moridi M. A., and Jang H. Implementation and verification of a Wi-Fi ad hoc communication system in an underground mine environment, J. Min. Sci., 2019, Vol. 55, No. 3. — P. 505–514.
- 8. Sun E., Zhang X., and Li Z. The internet of things (IoT) and cloud computing (CC) based tailings dam monitoring and pre-alarm system in mines, Safety Sci., 2012, Vol. 50, No. 4. P. 811–815.
- Sikora M., Krzystanek Z., Bojko B., and Spiechowicz K. Application of a hybrid method of machine learning for description and on-line estimation of methane hazard in mine workings, J. Min. Sci., 2011, Vol. 47, No. 4. — P. 493-505.
- Ghiasi M., Askarnejad N., Dindarloo S. R., and Shamsoddini H. Prediction of blast boulders in open pit mines via multiple regression and artificial neural networks, Int. J. Min. Sci. Technol., 2016, Vol. 26, No. 2. — P. 183–186.
- Temeng V. A., Ziggah Y. Y., and Arthur C. K. A novel artificial intelligent model for predicting air overpressure using brain inspired emotional neural network, Int. J. Min. Sci. Technol., 2020, Vol. 30, No. 5. — P. 683–689.
- Lin H., Singh S., Oh J., Canbulat I., Kang W. H., Hebblewhitea B., and Staceyc T. R. A combined approach for estimating horizontal principal stress magnitudes from borehole breakout data via artificial neural network and rock failure criterion, J. Rock Mech. Min. Sci., 2020, Vol. 136. — P. 104539.
- Lin H., Kang W. H., Oh J., and Canbulat I. Estimation of in-situ maximum horizontal principal stress magnitudes from borehole breakout data using machine learning, J. Rock Mech. Min. Sci., 2020, Vol. 126. — P. 104199.
- 14. Özyurt M. C. and Karadogan A. A. New model based on artificial neural networks and game theory for the selection of underground mining method, J. Min. Sci., 2020, Vol. 56, No. 1. P. 66–78.
- 15. Wu D., Shi H., Wang H., Wang R., and Fang H. A feature-based learning system for Internet of Things applications, IEEE Internet of Things J., 2019, Vol. 6, No. 2. P. 1928–1937.
- **16.** Ponce H. and Gutiérrez S. An indoor predicting climate conditions approach using Internet-of-Things and artificial hydrocarbon networks, Measurement, 2019, Vol. 135. P. 170–179.
- 17. Saray T., Cetinkaya A., and Mendi S. E. Monitoring of miner by RF signal, 2017 International Conference on Computer Science and Engineering (UBMK), IEEE, 2017. http://toc.proceedings.com/36788webtoc.pdf.
- **18.** Seguel F., Palacios-Játiva P., Azurdia-Meza C. A., Krommenacker N., Charpentier P., and Soto I. Underground mine positioning: A review, IEEE Sens. J., 2021.

- **19.** Zrelli A. and Ezzedine T. Design of optical and wireless sensors for underground mining monitoring system, Optik, 2018, Vol. 170. P. 376-383.
- Song J., Zhu Y., and Dong F. Automatic monitoring system for coal mine safety based on wireless sensor network, 2011 Cross Strait Quad-Regional Radio Science and Wireless Technology Conference, IEEE, 2011, Vol. 2. — P. 933–936.
- Thrybom L., Neander J., Hansen E., and Landernas K. Future challenges of positioning in underground mines, IFAC-PapersOnLine, 2015, Vol. 48, No. 10. — P. 222–226.
- 22. Liu Z., Li C., Wu D., Dai W., Geng S., and Ding Q. A wireless sensor network based personnel positioning scheme in coal mines with blind areas, Sensors, 2010, Vol. 10, No. 11. P. 9891–9918.
- Huang L., Li J., Hao H., and Li X. Micro-seismic event detection and location in underground mines by using Convolutional Neural Networks (CNN) and deep learning, Tunnel. Underground Space Technol., 2018, Vol. 81. — P. 265–276.
- 24. Wamriew D., Pevzner R., Maltsev E., and Pissarenko D. Deep neural networks for detection and location of microseismic events and velocity model inversion from microseismic data acquired by distributed acoustic sensing array, Sensors, 2021, Vol. 21, No. 19, 6627.
- 25. Binder G. and Tura A. Convolutional neural networks for automated microseismic detection in downhole distributed acoustic sensing data and comparison to a surface geophone array, Geophys. Prospect., 2020, Vol. 68, No. 9. P. 2770–2782.
- Wang B., Kong W., Guan H., and Xiong N. N. Air quality forecasting based on gated recurrent long short term memory model in Internet of Things, IEEE Access, 2019, Vol. 7. — P. 69524–69534.
- 27. Cheng Y., Wan S., and Choo K. R. Deep belief network for meteorological time series prediction in the internet of things, IEEE Internet of Things J., 2019, Vol. 6, No. 3. P. 4369–4376.
- 28. Li J., Xie J., Yang Z., and Li J. Fault diagnosis method for a mine hoist in the internet of things environment, Sensors, 2018, Vol. 18, No. 6, 1920.
- Dong L., Shu W., Sun D., Li X., and Zhang L. Pre-alarm system based on real-time monitoring and numerical simulation using internet of things and cloud computing for tailings dam in mines, IEEE Access, 2017, Vol. 5. — P. 21080–21089.
- **30.** Jo B. and Khan R. M. A. An internet of things system for underground mine air quality pollutant prediction based on azure machine learning, Sensors, 2018, Vol. 18, No. 4, 930.
- **31.** Jung W., Kim S. H., Hong S. P., and Seo J. An AIoT monitoring system for multi-object tracking and alerting, Computers, Materials & Continua, 2021, Vol. 67, No. 1. P. 337–348.
- **32.** Sadowski S. and Spachos P. RSSI-based indoor localization with the internet of things, IEEE Access, 2018, Vol. 6. P. 30149–30161.
- **33. Wang S.** Wireless network indoor positioning method using nonmetric multidimensional scaling and RSSI in the internet of things environment, Math. Probl. Eng., 2020, Article ID 8830891. 7 p.
- 34. Zhang W., Guo W., Liu X., Liu Y., Zhou J., Li B., Lu Q., and Yang S. LSTM-based analysis of industrial IoT equipment, IEEE Access, 2018, Vol. 6. — P. 23551–23560.
- 35. Wang F., Xuan Z., Zhen Z., Li K., Wang T., and Shi M. A day-ahead PV power forecasting method based on LSTM-RNN model and time correlation modification under partial daily pattern prediction framework, Energy Convers. Manage., 2020, Vol. 212, No. 2. P. 112766.
- **36.** Sezer O. B., Gudelek M. U., and Ozbayoglu A. M. Financial time series forecasting with deep learning: A systematic literature review: 2005–2019, Applied Soft Computing, 2020, Vol. 90. P. 106181.

Поступила в редакцию 20/I 2022 После доработки 10/II 2022 Принята к публикации 14/III 2022