



ТЕХНОЛОГИЧЕСКАЯ БЕЗОПАСНОСТЬ В МИНЕРАЛЬНО-СЫРЬЕВОМ КОМПЛЕКСЕ И ОХРАНА ОКРУЖАЮЩЕЙ СРЕДЫ



Научная статья

<https://doi.org/10.17073/2500-0632-2022-2-111-125>

Прогнозирование выбросов пыли (PM_{2.5}) на угольных разрезах с помощью нейронной сети с функциональными связями, оптимизированной различными алгоритмами

С.-Н. Буй¹  , Х. Нгуен¹  , К.-Т. Ле¹  , Т.-Н. Ле²¹ Ханойский университет горного дела и геологии, Ханой, Вьетнам² Vinacomin – Minerals Holding Corporation, Ханой, Вьетнам✉ buixuannam@humg.edu.vn

Аннотация

Загрязнение воздуха PM_{2.5} (твердые частицы размером 2,5 мк и менее) представляет собой не только значительную опасность для здоровья человека в повседневной жизни, но и опасный риск для рабочих при открытых горных работах, особенно на угольных разрезах. PM_{2.5} на угольных разрезах могут вызывать заболевания легких (например, пневмокониоз, рак легких) и сердечно-сосудистые заболевания из-за длительного воздействия вдыхаемой пыли. Поэтому точное прогнозирование PM_{2.5} имеет большое значение для минимизации загрязнения PM_{2.5} и улучшения качества воздуха на рабочих местах. В данном исследовании изучались метеорологические условия и выбросы PM_{2.5} на угольном разрезе во Вьетнаме с целью разработки новой интеллектуальной модели для прогнозирования выбросов и загрязнения PM_{2.5}, применялась нейронная сеть с функциональными связями (FLNN) для прогнозирования загрязнения PM_{2.5} в зависимости от метеорологических условий (в частности, температуры, влажности, атмосферного давления, направления и скорости ветра). Вместо традиционных алгоритмов для обучения модели FLNN был использован алгоритм поиска методом голодных игр (HGS). Важнейшая роль HGS в данном исследовании заключается в оптимизации весов в модели FLNN, которая была названа моделью HGS-FLNN. Также были рассмотрены три другие гибридные модели, основанные на FLNN и метаэвристических алгоритмах, т.е. ABC (искусственная пчелиная колония)-FLNN, GA (генетический алгоритм)-FLNN и PSO (оптимизация роя частиц)-FLNN, для оценки возможности прогнозирования PM_{2.5} на угольных разрезах и сравнения их результатов с результатами модели HGS-FLNN. Исследования показали, что HGS-FLNN является лучшей моделью с самой высокой точностью прогнозирования загрязнения воздуха PM_{2.5} (в среднем до 94–95 %, при этом точность других моделей варьировалась от 87 до 90 %), а также наиболее стабильной моделью с наименьшей относительной ошибкой (в диапазоне от –0,3 до 0,5 %).

Ключевые слова

угольный разрез, загрязнение воздуха, пыль, PM_{2.5}, здоровье человека, поиск методом голодных игр, нейронная сеть с функциональными связями, оптимизация, разрез Кок Сау, провинция Куангнинь, Вьетнам

Благодарности

Данное исследование было финансово поддержано Министерством образования и профессиональной подготовки (МОЕТ) Вьетнама в рамках гранта № B2018-MDA-03SP. Авторы также благодарят Центр горных и электромеханических исследований Ханойского университета горного дела и геологии (HUMG), Вьетнам; инженеров и руководителей угольного разреза Кок Сау, провинция Куангнинь, Вьетнам, за помощь и сотрудничество.

Для цитирования

Bui X.-N., Nguyen H., Le Q.-T., Le T.-N. Forecasting PM_{2.5} emissions in open-pit mines using a functional link neural network optimized by various optimization algorithms. *Mining Science and Technology (Russia)*. 2022;7(2):111–125. <https://doi.org/10.17073/2500-0632-2022-2-111-125>



SAFETY IN MINING AND PROCESSING INDUSTRY AND ENVIRONMENTAL PROTECTION

Research paper

Forecasting PM_{2.5} emissions in open-pit mines using a functional link neural network optimized by various optimization algorithmsX.-N. Bui¹  , H. Nguyen¹  , Q.-T. Le¹  , T.-N. Le²¹ Hanoi University of Mining and Geology, Hanoi, Vietnam² Vinacomin – Minerals Holding Corporation, Hanoi, Vietnam buixuannam@humg.edu.vn**Abstract**

PM_{2.5} air pollution is not only a significant hazard to human health in everyday life but also a dangerous risk to workers operating in open-pit mines (OPMs), especially open-pit coal mines (OPCMs). PM_{2.5} in OPCMs can cause lung-related (e.g., pneumoconiosis, lung cancer) and cardiovascular diseases due to exposure to airborne respirable dust over a long time. Therefore, the precise prediction of PM_{2.5} is of great importance in the mitigation of PM_{2.5} pollution and improving air quality at the workplace. This study investigated the meteorological conditions and PM_{2.5} emissions at an OPCM in Vietnam, in order to develop a novel intelligent model to predict PM_{2.5} emissions and pollution. We applied functional link neural network (FLNN) to predict PM_{2.5} pollution based on meteorological conditions (e.g., temperature, humidity, atmospheric pressure, wind direction and speed). Instead of using traditional algorithms, the Hunger Games Search (HGS) algorithm was used to train the FLNN model. The vital role of HGS in this study is to optimize the weights in the FLNN model, which was finally referred to as the HGS-FLNN model. We also considered three other hybrid models based on FLNN and metaheuristic algorithms, i.e., ABC (Artificial Bee Colony)-FLNN, GA (Genetic Algorithm)-FLNN, and PSO (Particle Swarm Optimization)-FLNN to assess the feasibility of PM_{2.5} prediction in OPCMs and compare their results with those of the HGS-FLNN model. The study findings showed that HGS-FLNN was the best model with the highest accuracy (up to 94–95 % in average) to predict PM_{2.5} air pollution. Meanwhile, the accuracy of the other models ranged 87 % to 90 % only. The obtained results also indicated that HGS-FLNN was the most stable model with the lowest relative error (in the range of –0.3 to 0.5 %).

Keywords

open-pit coal mine, air pollution, dust, PM_{2.5}, human health, hunger games search, functional link neural network, optimization, Coc Sau open-pit coal mine, Quang Ninh province, Vietnam

Acknowledgments

This study was financially supported by the Ministry of Education and Training (MOET) of Vietnam under grant number B2018-MDA-03SP. The authors also thank the Center for Mining, Electro-Mechanical Research of Hanoi University of Mining and Geology (HUMG), Vietnam; the engineers and managers of the Coc Sau open-pit coal mine, Quang Ninh province, Vietnam for their help and cooperation.

For citation

Bui X.-N., Nguyen H., Le Q.-T., Le T.-N. Forecasting PM_{2.5} emissions in open-pit mines using a functional link neural network optimized by various optimization algorithms. *Mining Science and Technology (Russia)*. 2022;7(2):111–125. <https://doi.org/10.17073/2500-0632-2022-2-111-125>

Введение

«Горное дело – это ещё не всё, но без горного дела всё – ничто», – сказал Макс Планк, знаменитый немецкий физик-теоретик. Практически всё, например, металлы, цемент, строительные материалы, мосты, стекло, башни/здания, уголь, энергетические установки и т.д. – коренным образом зависят от добычи полезных ископаемых. Горнодобывающая промышленность оказывает положительный экономический эффект на развитие стран мира и энергетическую безопасность каждой страны. Однако горнодобывающая промышленность также оказывает значительное негативное воздействие на окружающую среду, в частности, генерируя загрязнители воздуха (например, взвешенные твердые частицы (TSP), вдыхаемые

частицы пыли с диаметром 1,0, 2,5, 10 и меньше мк (PM_{1.0}, PM_{2.5}, PM₁₀ соответственно)) [1–3] рис. 1). Открытые горные работы оказывают более серьезное воздействие на окружающую среду по сравнению с подземными рудниками (шахтами) из-за проведения работ на открытом воздухе. В зависимости от размера частиц негативное воздействие на здоровье человека/профессиональное воздействие может быть более или менее значительным [4, 5]. Среди мелких частиц, образующихся при добыче полезных ископаемых открытым способом, частицы, образующиеся на угольных разрезах, считаются наиболее опасными из-за их различных размеров, химического и минералогического состава (в частности, уголь, минералы, органические соединения и т.д.) [6].

На угольных разрезах многие виды работ могут производить пыль (т.е. $PM_{2.5}$), например, бурение, взрывные работы, выемка грунта, транспортировка и т.д. Радиус воздействия пыли может увеличиваться из-за конкретных метеорологических условий (например, направление и скорость ветра). В последние годы с экспоненциальным ростом потребления энергии разработка угольных разрезов смещается на большие глубины для увеличения добычи угля [8]. На глубоких угольных разрезах не может эффективно использоваться естественная вентиляция. Это приводит к наличию огромного количества тонких частиц в местах ведения горных работ. Эти частицы являются источником опасности для горняков и могут вызывать серьезные последствия для здоровья [9, 10].

Для управления выбросами пыли на открытых горных работах многие исследователи измеряли и анализировали количество твердых частиц (PM) различных размеров, чтобы оценить их воздействие в зависимости от размера. Они предложили решения по снижению загрязнения воздуха [11–13]. Д-р Эмануэль Кодэ с соавт. (Центр NIOSH по прямым показаниям и сенсорным технологиям) (Dr. Emanuele Cauda et al., NIOSH Center for Direct Reading and Sensor Technologies) исследовали распределение твердых частиц из различных источников, и их результаты показали, что выбросы пыли в угольных разрезах являются значитель-

ным источником твердых частиц (рис. 2), а их прогноз и контроль являются весьма актуальной задачей.

Другим подходом к решению проблемы загрязнения пылью является оценка/прогнозирование выбросов/концентрации пыли на угольных разрезах. Большинство исследований прошлых периодов, связанных с выбросами твердых частиц на угольных разрезах, были сосредоточены на оценке концентраций твердых частиц при ведении этих горных работ [14, 15]. В последние годы искусственный интеллект (ИИ) широко применяется для прогнозирования концентрации/выбросов пыли на открытых горных работах. Он также рекомендуется как надежный инструмент для использования в других секторах [16–20]. В целях прогнозирования загрязнения воздуха на угольных разрезах Лал Б. и Трипати С.С. [21] применили модель нейронной сети с многоуровневым перцептроном (MLP) для прогнозирования концентрации пыли в индийском угольном разрезе. Их исследование подтвердило высокую точность модели MLP в прогнозировании концентрации пыли. Bakhtavar E. et al. [22] также применили модель искусственной утяжеленной нейронной сети с взвешиванием причинно-следственных связей (ACWNN) для прогнозирования выбросов пыли при взрывных работах при ведении открытых горных работ. Они применили нечеткую когнитивную карту для получения весов входов для нейронной



а



б



в



г

Рис. 1. Загрязнение воздуха в угольных разрезах из различных источников: а – загрязнение воздуха транспортом [7]; б – загрязнение воздуха экскаваторами; в – загрязнение воздуха различными работами; г – загрязнение воздуха взрывами

сети прогнозирования выбросов пыли. Однако в исследовании прогнозировалось только горизонтальное и вертикальное распределение пыли. Учитывая другие виды работ в угольных разрезах (например, буровые работы), Вуй Н.-Н. et al. [23] предсказал выброс PM_{10} с помощью модели регрессии опорных векторов, оптимизированной методом роя частиц (PSO). Используя технику глубокого обучения (например, долгую краткосрочную память – LSTM), Ли Л. et al. [24] предсказал выбросы $PM_{2.5}$ и PM_{10} в разрезе при RMSE (среднеквадратическая ошибка) 29,517 и 23,204, MAPE (средняя абсолютная ошибка в процентах) 11,573 % и 8,537 % соответственно. Лу Х. et al. [25] предложили гибридную модель PSO-GBM (Gradient Boosting Machine – система градиентного бустинга) для прогнозирования концентрации $PM_{2.5}$ на основе другого алгоритма машинного обучения. В их исследовании наблюдалась высокая сходимость с коэффициентом корреляции от 0,920 до 0,942.

Концентрации/выбросы пыли были изучены с точки зрения измерения и прогнозирования. В большинстве случаев они измерялись и прогнозировались на основе отдельных видов деятельности в угольных разрезах. Хотя несколько моделей ИИ были предложены и успешно применены для прогнозирования выбросов/концентраций пыли, их действенность была ограничена из-за диапазона метеорологических условий в различных районах и надежности различных интеллектуальных моделей. В карьерах $PM_{2.5}$ были оценены как гораздо более опасные, чем PM_{10} в рабочей среде. Они могут вызывать обструктивные респираторные расстройства и заболевания, связанные с поражением легких и сердечно-сосудистой системы [26–28]. Поэтому в данном исследовании мы разработали интеллектуальную систему оценки качества воздуха для измерения выбросов $PM_{2.5}$ в разрезах. Мы использовали технологию интернета вещей для пере-

дачи данных на рабочие станции. Затем была разработана новая гибридно-нейросетевая модель на основе функциональной связанной нейронной сети (FLNN) и алгоритма поиска голодных игр (HGS), сокращенно называемая HGS-FLNN модель, для прогнозирования выбросов $PM_{2.5}$ в глубоком угольном разрезе. Следует отметить, что предложенная модель HGS-FLNN ранее не разрабатывалась и не применялась для прогнозирования выбросов пыли в разрезах. Полученные результаты модели HGS-FLNN затем сравнивались с тремя другими гибридными моделями, т.е. ABC (искусственная пчелиная колония)-FLNN, GA (генетический алгоритм)-FLNN и PSO (оптимизация методом роя частиц)-FLNN, чтобы подчеркнуть выдающиеся характеристики модели HGS-FLNN.

1. Сбор данных

Для оценки выбросов $PM_{2.5}$ при добыче угля открытым способом был исследован разрез Кок Сау во Вьетнаме (рис. 3). Это один из самых больших и глубоких вьетнамских угольных разрезов с глубиной 300 м по состоянию на июль 2021 г.¹ Из-за неправильной формы и большой глубины качество воздуха в разрезе, особенно в отношении $PM_{2.5}$, очень плохое. Из-за большой глубины разреза не может использоваться естественная вентиляция. Поэтому воздействие высоких концентраций $PM_{2.5}$ является значительным. Как описано выше, категория частиц $PM_{2.5}$ является одной из самых неблагоприятных, способных вызывать профессиональные заболевания. Следовательно, прогнозирование $PM_{2.5}$ в этом разрезе направлено на поиск подходящих решений для снижения загрязнения воздуха (в частности, концентрации $PM_{2.5}$) в рабочей среде разреза.

¹ Coc Sau Coal Company (Угольная компания “Кок Сау”). Summary report of production in 2021, Coc Sau (in Vietnamese) (Краткий отчет о производстве в 2021 году, Кок Сау). 2021 (на вьетнамском языке).




Рис. 2. Распределение пыли из различных источников по размерам

Источник: Nanozen (официальный сайт). Dust specific calibrated real-time particle monitors.

(Калиброванные по размеру частиц пыли счетчики частиц, дающие показания в режиме реального времени.) 2020. <https://nanozen.com/nanozette-q120/> [Accessed: 03/10/2021]

Набор данных для разработки моделей ИИ для прогнозирования $PM_{2.5}$ был собран с помощью трех измерительных станций (рис. 3). Каждая станция была разработана как система измерения качества воздуха, способная измерять не только $PM_{2.5}$, но и метеорологические условия, такие как температура T , атмосферное давление AP , влажность H , направление и скорость ветра WD , WS . Эти станции ежедневно измеряли все параметры и передавали данные в технический отдел организации, ведущей горные работы, через сеть 4G. Ранее выполненные исследования показали, что метеорологические условия значительно влияют на выбросы пыли в разрезе [29, 30]. Поэтому в настоящем исследовании они использовались в качестве входных переменных для прогнозирования $PM_{2.5}$. Поскольку геометрия разреза существенно не меняется с углублением, загрязнение $PM_{2.5}$ за время эксплуатации считается стабильным. Стоит отметить, что для решения задачи на основе регрессионного анализа в данном исследовании направления ветра (например, запад, восток, север, юг) были преобразованы в числовые значения. Набор данных представлен в табл. 1.

Таблица 1

Выбросы $PM_{2.5}$ и метеорологические условия в районе исследования

Категория	$PM_{2.5}$	Температура	Влажность	Атмосферное давление	Направление ветра	Скорость ветра
Минимальное	10	18,5	83,4	985,5	1	0,1
1-й квартал	23	22,4	91,7	1 000,3	3	2,4
Медианное	34	23,4	94,7	1 004,4	10	3,3
Среднее	34,98	23,43	94,3	1 004,3	8,534	3,285
3-й квартал	44	24,5	97,1	1 008,2	12	4,2
Максимальное	90	28,8	100	1 023,9	16	7,5

2. Проектирование модели HGS-FLNN для прогнозирования $PM_{2.5}$

В целях прогнозирования $PM_{2.5}$ в данном исследовании мы выбрали FLNN (нейронную сеть с функциональными связями), разновидность ANN (искусственной нейронной сети) в форме одноуровневой архитектуры [31, 32]. Уникальный механизм этой сети основан на входных переменных и нелинейных функциональных расширениях [33]. Она может генерировать скрытые нейроны и вычислять сумму весов. Такой подход позволяет уменьшить сложности, связанные с проблемами регрессии [34]. Для обучения модели FLNN могут применяться простые методы алгоритма минимальной среднеквадратичной ошибки (LMS), обратного распространения ошибки обучения (BP) или градиентного спуска для обновления весов модели. Архитектура модели FLNN показана на рис. 4.

Модель FLNN (см. рис. 4) имеет много узлов, сформированных с большим количеством весов. В связи с этим обновление весов в сети является сложной задачей для модели FLNN с традиционными алгоритмами обучения (например, BP, LMS) [35]. При обучении модели FLNN с помощью традиционных алгоритмов обучения могут возникать локальные оптимумы. Это может снизить эффективность модели FLNN при прогнозировании $PM_{2.5}$.

Чтобы преодолеть эту проблему, можно использовать алгоритмы оптимизации для обучения сети с целью оптимизации весов модели FLNN. Метаэвристические алгоритмы являются хорошим выбором, поскольку они позволяют модели FLNN достичь глобального оптимума [36, 37]. В данном исследовании для обучения модели FLNN вместо традиционных алгоритмов был выбран HGS (поиск голодных игр), новый метаэвристический алгоритм, предложенный Yang Y. et al. [38]. HGS является высококонкурентным




Рис. 3. Район исследования и расположение станций измерения качества воздуха



алгоритмом в решении проблем оптимизации [39]. Он был разработан на основе действий голодных особей в рое во время охоты на добычу или поиска пищи. Подробности HGS можно найти в оригинальном исследовании [38]. Блок-схема HGS представлена на рис. 5.

Была разработана новая гибридная модель ИИ на основе FLNN и алгоритма HGS для прогнозирования $PM_{2.5}$ в угольных разрезах, названная моделью HGS-FLNN. Алгоритм HGS был разработан и использован

для обучения и создания весов для модели FLNN на основе действий, вызванных голодом. Затем обновляли веса для сети и рассчитывали ошибку модели. При оптимизации модели FLNN для прогнозирования $PM_{2.5}$ использовали среднеквадратическую ошибку (RMSE) в качестве функции потерь для оценки эффективности модели, чтобы определить, удовлетворяется ли критерий или нет. Предложенная схема модели HGS-FLNN представлена на рис. 6.




Рис. 4. Архитектура модели FLNN




Рис. 5. Упрощенная блок-схема алгоритма оптимизации HGS




Рис. 6. Предложенная модель HGS-FLNN для прогнозирования $PM_{2.5}$ в карьерах

3. Создание и развитие модели HGS-FLNN для прогнозирования $PM_{2.5}$

Модель HGS-FLNN для прогнозирования $PM_{2.5}$ в угольном разрезе была разработана, как описано на рис. 6. Перед разработкой HGS-FLNN и других моделей набор данных был случайным образом разделен на две части в соотношении 4:1 для разработки и тестирования моделей соответственно. Кроме того, наборы данных были нормализованы путем масштабирования от 0 до 1, чтобы повысить точность моделей и минимизировать ошибки.

Перед оптимизацией модели FLNN были установлены и откалиброваны функциональное расширение и параметры HGS. Функция Чебышева была выбрана в качестве функции расширения модели FLNN для передачи данных входных переменных (т.е. температуры, влажности, атмосферного давления, направления и скорости ветра (T, H, AP, WD, WS)) в скрытые узлы. Кроме того, функция активации ReLu (Rectified Linear Unit – блок линейной ректификации) использовалась для преобразования данных (весов) в узлах модели FLNN. Для оптимизатора HGS рассматривались различные количества голодающих особей, например, 50, 100, 150, 200, 250, 300, 350, 400, 450, 500 – для оценки производительности оптимизатора. Вероятность обновления позиции переключения была выбрана равной 0,03 с порогом 1000. Для каждой голодающей особи и ее позиции HGS создавал веса, а затем обновлял их в модели FLNN. Наконец, были рассчитаны значения среднеквадратической ошибки (RMSE) и была выбрана наилучшая модель с наименьшим значением RMSE, как показано на рис. 7. Для этой цели использо-

валась библиотека Meaipy, разработанная N.V. Thieu². Кривые эффективности показывают, что эффективность обучения модели HGS-FLNN и значения RMSE превосходны. Следующая глава посвящена тестированию и оценке эффективности модели.




Рис. 7. Эффективность оптимизации модели HGS-FLNN для прогнозирования $PM_{2.5}$

² Thieu N.V. A collection of the state-of-the-art meta-heuristics algorithms in Python (Коллекция современных алгоритмов метаэвристики на языке Python): Meaipy. 2020.



4. Разработка других моделей для прогнозирования $PM_{2.5}$

PSO (оптимизация роя частиц), GA (генетический алгоритм) и ABC (искусственная пчелиная колония) – известные метаэвристические алгоритмы – широко используются для решения проблем оптимизации [40–48]. В данном исследовании мы гибридизировали модель FLNN (для прогнозирования $PM_{2.5}$ в угольных разрезах) с этими алгоритмами, чтобы получить соответственно модели, называемые PSO-FLNN, GA-FLNN и ABC-FLNN. Следует отметить, что это также новые гибридные модели, связанные с прогнозированием загрязнения воздуха, особенно в целях прогнозирования $PM_{2.5}$. Основные принципы алгоритмов PSO, GA и ABC представлены в следующих исследованиях [49–61]. Стоит также отметить, что в данном исследовании роль PSO, GA и ABC аналогична роли оптимизатора HGS, а разработка моделей PSO-FLNN, GA-FLNN и ABC-FLNN аналогична разработке модели HGS-FLNN.

4.1. PSO-FLNN (Нейронная сеть с функциональными связями с алгоритмом оптимизации методом роя частиц)

Для разработки модели PSO-FLNN использовалась та же схема с функцией Чебышева и функцией активации ReLu (аналогично модели HGS-FLNN). Различное количество роев также задавалось в интервале 50–500, как и в модели HGS-FLNN. Параметры PSO были заданы следующим образом: $C_1 = 1,2$, $C_2 = 1,2$, $W_{\min} = 0,4$, $W_{\max} = 0,9$. PSO также был реализован с 1000 итераций через объективную функцию RMSE. Затем была определена наилучшая модель PSO-FLNN на основе наименьшей RMSE (рис. 8).




Рис. 8. Эффективность оптимизации модели PSO-FLNN для прогнозирования $PM_{2.5}$

4.2. Нейронная сеть с функциональными связями с генетическим алгоритмом оптимизации (GA-FLNN)

Для разработки модели GA-FLNN использовалась та же схема с функцией Чебышева и функцией активации ReLu (аналогичная той, что использовалась для моделей HGS-FLNN и PSO-FLNN). Различное количество роев также задавалось в интервале 50–500, как и для моделей HGS-FLNN и PSO-FLNN. Параметры GA были заданы следующим образом: $P_c = 0,85$, $P_m = 0,05$. Алгоритм GA также был реализован с 1000 итераций через объективную функцию RMSE. Затем была определена наилучшая модель GA-FLNN на основе наименьшей RMSE (рис. 9).




Рис. 9. Эффективность оптимизации модели GA-FLNN для прогнозирования $PM_{2.5}$

4.3. Нейронная сеть с функциональными связями с алгоритмом оптимизации методом искусственной пчелиной колонии (ABC-FLNN)

Как и модели PSO-FLNN и GA-FLNN, модель ABC-FLNN для прогнозирования $PM_{2.5}$ также была разработана на основе тех же подходов. Была использована та же структура исходной модели FLNN (т.е. входы, функция расширения, функция активации). Далее оптимизатор ABC реализовал глобальный поиск для обеспечения набора количества весов. После этого они обновлялись в соответствии с исходной моделью FLNN, и вычислялась среднеквадратическая ошибка (RMSE). Различные количества пчел также были установлены равными 50–500, как и для моделей HGS-FLNN, PSO-FLNN и GA-FLNN. Величина окрестности для элиты и других пчел (как параметр ABC) был задан равным 16,4. Алгоритм ABC оптимизировал начальную модель FLNN посредством 1000 ите-

раций через объективную функцию RMSE, как показано на рис. 10. В конечном итоге, наилучшая модель ABC-FLNN была определена на основе наименьшего значения RMSE. Кривые обучения на рис. 10 показывают, что эффективность обучения модели ABC-FLNN хорошая. В следующей главе описаны тестирование и оценка эффективности.




Рис. 10. Эффективность оптимизации модели ABC-FLNN для прогнозирования $PM_{2.5}$

5. Результаты и их обсуждение

Рис. 5–8 показывают, что модели HGS-FLNN, ABC-FLNN, PSO-FLNN и GA-FLNN хорошо обучены и демонстрируют хорошую сходимость. Однако только по этим рисункам трудно определить, какая модель является лучшей для прогнозирования $PM_{2.5}$. Мы использовали статистические показатели, такие как MAE (средняя абсолютная ошибка), RMSE (среднеквадратическая ошибка), R^2 (коэффициент детерминированности) и MAPE (средняя абсолютная ошибка в процентах) для оценки точности разработанных гибридных моделей на основе FLNN. Они полезны не только для оценки точности моделей, но и для определения свойств разработанных моделей (например, переобучения (чрезмерная аппроксимация), недо-

подгонка) (недостаточная аппроксимация). Результаты представлены в табл. 2.

Данные табл. 2 показывают, что модель HGS-FLNN очевидно превосходит другие модели. В модели HGS-FLNN MAE (средняя абсолютная ошибка) составляет от 1,405 до 1,497, в то время как модели ABC-FLNN, PSO-FLNN и GA-FLNN дают более высокие ошибки (MAE 1,776, 2,326, 3,693 соответственно в наборе данных обучения, и MAE 2,246, 2,453, 3,602 соответственно в наборе данных тестирования). Аналогично MAE, значения RMSE в модели HGS-FLNN, равные 2,652 и 2,700 (на этапах обучения и тестирования соответственно), ниже, чем у других моделей. Этапы обучения и тестирования других моделей дали более высокие значения RMSE (в диапазоне 3,298–5,938 и 3,857–5,672 соответственно). Примечательно, что MAPE (средняя абсолютная ошибка в процентах) составила всего лишь 5,4 % при обучении модели HGS-FLNN и 5,7 % при тестировании соответствующего набора данных. Другими словами, MAPE в прогнозировании $PM_{2.5}$ на основе модели HGS-FLNN составила 5,4–5,7 % (принимая во внимание только метеорологические условия).

Что касается уровня регрессии в моделях (т.е. коэффициента детерминированности R^2), результаты также показали, что модель HGS-FLNN продемонстрировала самый высокий R^2 на обоих этапах. Кроме того, как было замечено, разработанные модели не продемонстрировали чрезмерной аппроксимации. Другими словами, этапы обучения и тестирования показали практически аналогичную точность результатов по прогнозированию $PM_{2.5}$ в данном исследовании. Визуализация уровней регрессии моделей на рис. 9 и 10 показывает наилучшую корреляцию между предсказанными и измеренными данными в модели HGS-FLNN по сравнению с другими моделями. В то время как корреляция в модели HGS-FLNN идеальна, другие модели (т.е. ABC-FLNN, PSO-FLNN и GA-FLNN) демонстрируют более низкую корреляцию, особенно модель GA-FLNN. Модель GA-FLNN продемонстрировала самую низкую эффективность в прогнозировании $PM_{2.5}$ в данном исследовании. Модели PSO-FLNN и ABC-FLNN продемонстрировали лучшую корреляцию/эффективность, чем модель GA-FLNN.

Переходя к результатам обучения моделей на основе FLNN (см. рис. 5–8) и внимательно рассматривая линии эффективности и значения RMSE, можно увидеть, что результаты обучения модели HGS-FLNN

Таблица 2

Статистические показатели для проверки моделей на основе FLNN для прогнозирования $PM_{2.5}$

Модель	Обучение				Испытания			
	MAE	RMSE	R^2	MAPE (%)	MAE	RMSE	R^2	MAPE (%)
HGS-FLNN	1,405	2,652	0,967	5,4	1,497	2,700	0,966	5,7
ABC-FLNN	1,776	3,298	0,949	7,0	2,246	3,857	0,931	9,7
PSO-FLNN	2,326	3,968	0,930	8,7	2,453	3,962	0,933	9,1
GA-FLNN	3,693	5,938	0,837	12,5	3,602	5,672	0,852	12,9



намного лучше, чем у других моделей с более низкими значениями RMSE. Этот вывод подтверждает результаты, представленные в табл. 2 и на рис. 9–10. Другими словами, это подтверждает, что алгоритм HGS в данном случае работает лучше, чем другие алгоритмы (т.е. ABC, PSO и GA). Это утверждение не означает, что алгоритм HGS лучше алгоритмов ABC, PSO и GA во всех случаях. Это зависит от наборов данных, используемых в каждом конкретном исследовании. Тем не менее алгоритм HGS считается лучшим для прогнозирования $PM_{2.5}$ в угольных разрезах, по крайней мере, в данном исследовании. Чтобы измерить точность модели HGS-FLNN на практике, была рассчитана относительная ошибка (RE), как показано на рис. 13. Как видно на рисунке, в модели HGS-FLNN

относительная ошибка очень мала. Большинство значений RE находится в диапазоне от $-0,3$ до $0,5$. Только одна точка данных выходит за пределы этого диапазона, но и это значение RE невелико – $0,699$. В то же время другие модели демонстрируют более высокие значения RE, варьирующиеся от $-0,63$ до $2,194$. Заметим, что статистические показатели модели ABC-FLNN (см. табл. 2) свидетельствуют о ее лучшей эффективности по сравнению с моделями PSO-FLNN и GA-FLNN. Тем не менее модель ABC-FLNN показала некоторые точки данных с самой высокой RE, как показано на рис. 13. В итоге данное исследование позволило сделать уверенный вывод о том, что модель HGS-FLNN является наилучшей для прогнозирования $PM_{2.5}$.




Рис. 11. Корреляция между предсказанными и измеренными данными в моделях FLNN (набор обучающих данных) при оптимизации на основе роевых алгоритмов




Рис. 12. Корреляция между предсказанными и измеренными данными в моделях FLNN (набор данных для тестирования) при оптимизации роевых алгоритмов




Рис. 13. Сравнение относительных ошибок рассмотренных моделей



Закключение

PM_{2.5} в угольных разрезах представляет собой серьезную профессиональную опасность для здоровья шахтеров. Эти твердые частицы в воздухе могут вызывать респираторные, легочные, сердечно-сосудистые и онкологические заболевания. Отчеты по ранее проведенным исследованиям показывают, что увеличение загрязнения воздуха – концентрации PM_{2.5} на 10 мкг/м³ – приводит к увеличению частоты рака легких на 36%. Между тем, выбросы PM_{2.5} в угольных разрезах, измеренные в данном исследовании, варьировались от 10 до 90 мкг/м³. Это действительно опасные уровни для здоровья шахтеров. Поэтому точное прогнозирование загрязнения воздуха PM_{2.5} имеет решающее значение с точки зрения гигиены труда

и выбора решений для снижения загрязнения PM_{2.5} в угольных разрезах. В данном исследовании предложена новая модель HGS-FLNN для прогнозирования загрязнения PM_{2.5} в угольных разрезах со средней точностью 94–95 %. Кроме того, были разработаны, рассмотрены и оценены три другие гибридные модели для прогнозирования PM_{2.5}. Однако их точность оказалась ниже – в диапазоне от 87 % до 90 %. Полученные результаты также показали, что модель HGS-FLNN является наиболее стабильной моделью с очень низкой относительной ошибкой. Таким образом, мы считаем, что эта модель может уверенно использоваться при проектировании и ведении горных работ в угольных разрезах для прогнозирования и контроля загрязнения PM_{2.5}.

Список литературы / References

1. Aneja V.P., Isherwood A., Morgan P. Characterization of particulate matter (PM₁₀) related to surface coal mining operations in Appalachia. *Atmospheric Environment*. 2012;54:496–501. <https://doi.org/10.1016/j.atmosenv.2012.02.063>
2. Chakraborty M., Ahmad M., Singh R. et al. Determination of the emission rate from various opencast mining operations. *Environmental Modelling & Software*. 2002;17(5):467–480. [https://doi.org/10.1016/S1364-8152\(02\)00010-5](https://doi.org/10.1016/S1364-8152(02)00010-5)
3. Nie B.-S., Li X.-C., Yang T. et al. Distribution of PM_{2.5} dust during mining operation in coal workplace. *Journal of China Coal Society*. 2013;38(1):33–37. (In Chinese) URL: <https://www.ingentaconnect.com/content/jccs/jccs/2013/00000038/00000001/art00006#>
4. Kurth L.M., McCawley M., Hendryx M., Lusk S. Atmospheric particulate matter size distribution and concentration in West Virginia coal mining and non-mining areas. *Journal of Exposure Science & Environmental Epidemiology*. 2014;24:405–411. <https://doi.org/10.1038/jes.2014.2>
5. Li Z., Ma Z., van der Kuijp T.J. et al. A review of soil heavy metal pollution from mines in China: pollution and health risk assessment. *Science of the Total Environment*. 2014;468–469:843–853. <https://doi.org/10.1016/j.scitotenv.2013.08.090>
6. Dos Santos Pedroso-Fidelis G., Farias H.R., Mastella G.A. et al. Pulmonary oxidative stress in wild bats exposed to coal dust: A model to evaluate the impact of coal mining on health. *Ecotoxicology and Environmental Safety*. 2020;191:110211. <https://doi.org/10.1016/j.ecoenv.2020.110211>
7. Hendryx M., Islam M.S., Dong G.-H., Paul G. Air pollution emissions 2008–2018 from Australian coal mining: implications for public and occupational health. *International Journal of Environmental Research and Public Health*. 2020;17(5):1570. <https://doi.org/10.3390/ijerph17051570>
8. Luo H., Zhou W., Jiskani I.M., Wang Z. Analyzing characteristics of particulate matter pollution in open-pit coal mines: Implications for Green Mining. *Energies*. 2021;14(9):2680. <https://doi.org/10.3390/en14092680>
9. Moreno T., Trechera P., Querol X. et al. Trace element fractionation between PM₁₀ and PM_{2.5} in coal mine dust: Implications for occupational respiratory health. *International Journal of Coal Geology*. 2019;203:52–59. <https://doi.org/10.1016/j.coal.2019.01.006>
10. Song Y., Wang X., Maher B.A. et al. The spatial-temporal characteristics and health impacts of ambient fine particulate matter in China. *Journal of Cleaner Production*. 2016;112:1312–1318. <https://doi.org/10.1016/j.jclepro.2015.05.006>
11. Alvarado M., Gonzalez F., Fletcher A., Doshi A. Towards the development of a low cost airborne sensing system to monitor dust particles after blasting at open-pit mine sites. *Sensors*. 2015;15(8):19667–19687. <https://doi.org/10.3390/s150819667>
12. Nambiar M.K., Robe F.R., Seguin A.M. et al. Diurnal and seasonal variation of area-fugitive methane advective flux from an open-pit mining facility in Northern Canada using WRF. *Atmosphere*. 2020;11(11):1227. <https://doi.org/10.3390/atmos11111227>
13. Trechera P., Moreno T., Córdoba P. et al. Comprehensive evaluation of potential coal mine dust emissions in an open-pit coal mine in Northwest China. *International Journal of Coal Geology*. 2021;235:103677. <https://doi.org/10.1016/j.coal.2021.103677>
14. Chaulya S. Assessment and management of air quality for an opencast coal mining area. *Journal of Environmental Management*. 2004;70(1):1–14. <https://doi.org/10.1016/j.jenvman.2003.09.018>
15. Patra A.K., Gautam S., Kumar P. Emissions and human health impact of particulate matter from surface mining operation – A review. *Environmental Technology & Innovation*. 2016;5:233–249. <https://doi.org/10.1016/j.eti.2016.04.002>



16. Alam G., Ihsanullah I., Naushad M., Sillanpää M. Applications of artificial intelligence in water treatment for optimization and automation of adsorption processes: recent advances and prospects. *Chemical Engineering Journal*. 2022;427:130011. <https://doi.org/10.1016/j.cej.2021.130011>
17. Li B.-H., Hou B.-C., Yu W.-T., Lu X.-B., Yang C.-W. Applications of artificial intelligence in intelligent manufacturing: a review. *Frontiers of Information Technology & Electronic Engineering*. 2017;18:86–96. <https://doi.org/10.1631/FITEE.1601885>
18. Nguyen H., Bui N.X., Tran H.Q., Le G.H.T. A novel soft computing model for predicting blast – induced ground vibration in open – pit mines using gene expression programming. *Journal of Mining and Earth Sciences*. 2020;61:107–116. (In Vietnamese) <https://doi.org/10.46326/jmes.ktlt2020.09>
19. Nguyen L.Q. A novel approach of determining the parameters of Asadi profiling function for prediction ground subsidence due to inclined coal seam mining at Quang Ninh coal basin. *Journal of Mining and Earth Sciences*. 2020;61:86–95. (In Vietnamese) [https://doi.org/10.46326/jmes.2020.61\(2\).10](https://doi.org/10.46326/jmes.2020.61(2).10)
20. Tayarani-N M.-H. Applications of artificial intelligence in battling against COVID-19: a literature review. *Chaos, Solitons & Fractals*. 2020;142:110338. <https://doi.org/10.1016/j.chaos.2020.110338>
21. Lal B., Tripathy S.S. Prediction of dust concentration in open cast coal mine using artificial neural network. *Atmospheric Pollution Research*. 2012;3(2):211–218. <https://doi.org/10.5094/APR.2012.023>
22. Bakhtavar E., Hosseini S., Hewage K., Sadiq R. Green blasting policy: simultaneous forecast of vertical and horizontal distribution of dust emissions using artificial causality-weighted neural network. *Journal of Cleaner Production*. 2021;283:124562. <https://doi.org/10.1016/j.jclepro.2020.124562>
23. Bui X.-N., Lee C.W., Nguyen H. et al. Estimating PM₁₀ concentration from drilling operations in open-pit mines using an assembly of SVR and PSO. *Applied Sciences*. 2019;9(14):2806. <https://doi.org/10.3390/app9142806>
24. Li L., Zhang R., Sun J. et al. Monitoring and prediction of dust concentration in an open-pit mine using a deep-learning algorithm. *Journal of Environmental Health Science and Engineering*. 2021;19:401–414. <https://doi.org/10.1007/s40201-021-00613-0>
25. Lu X., Zhou W., Qi C. et al. Prediction into the future: A novel intelligent approach for PM_{2.5} forecasting in the ambient air of open-pit mining. *Atmospheric Pollution Research*. 2021;12(6):101084. <https://doi.org/10.1016/j.apr.2021.101084>
26. Gautam S., Prasad N., Patra A.K. et al. Characterization of PM_{2.5} generated from opencast coal mining operations: A case study of Sonapur Bazar Open-cast Project of India. *Environmental Technology & Innovation*. 2016;6:1–10. <https://doi.org/10.1016/j.eti.2016.05.003>
27. Huang Y., Bao M., Xiao J. et al. Effects of PM_{2.5} on cardio-pulmonary function injury in open manganese mine workers. *International Journal of Environmental Research and Public Health*. 2019;16(11):2017. <https://doi.org/10.3390/ijerph16112017>
28. Wanjun T., Qingxiang C. Dust distribution in open-pit mines based on monitoring data and fluent simulation. *Environmental Monitoring and Assessment*. 2018;190:632. <https://doi.org/10.1007/s10661-018-7004-9>
29. Oguntoké O., Ojelede M.E., Annegarn H.J. Frequency of mine dust episodes and the influence of meteorological parameters on the Witwatersrand area, South Africa. *International Journal of Atmospheric Sciences*. 2013;2013:128463. <https://doi.org/10.1155/2013/128463>
30. Silvester S., Lowndes I., Hargreaves D. A computational study of particulate emissions from an open pit quarry under neutral atmospheric conditions. *Atmospheric Environment*. 2009;43(40):6415–6424. <https://doi.org/10.1016/j.atmosenv.2009.07.006>
31. Pao Y. *Adaptive pattern recognition and neural networks*. CWRU: Case Western Reserve University; 1989. <https://doi.org/10.5860/choice.26-6311>
32. Patra J.C., Pal R.N. A functional link artificial neural network for adaptive channel equalization. *Signal Processing*. 1995;43(2):181–195. [https://doi.org/10.1016/0165-1684\(94\)00152-P](https://doi.org/10.1016/0165-1684(94)00152-P)
33. Nguyen T., Tran N., Nguyen B.M., Nguyen G. A resource usage prediction system using functional-link and genetic algorithm neural network for multivariate cloud metrics. In: *2018 IEEE 11th Conference on Service-Oriented Computing and Applications (SOCA)*. 2018. Pp. 49–56. <https://doi.org/10.1109/SOCA.2018.00014>
34. Majhi B., Naidu D. Pan evaporation modeling in different agroclimatic zones using functional link artificial neural network. *Information Processing in Agriculture*. 2021;8(1):134–147. <https://doi.org/10.1016/j.inpa.2020.02.007>
35. Nguyen T., Nguyen B.M., Nguyen G. Building Resource Auto-scaler with Functional-Link Neural Network and Adaptive Bacterial Foraging Optimization. In: Gopal TV, Watada J (eds.) *Theory and Applications of Models of Computation. TAMC 2019. Lecture Notes in Computer Science*. Springer, Cham. 2019. Pp. 501–517. https://doi.org/10.1007/978-3-030-14812-6_31
36. Kaveh A. *Advances in metaheuristic algorithms for optimal design of structures*. Springer, Cham; 2014. <https://doi.org/10.1007/978-3-319-05549-7>
37. Ting T., Yang X.-S., Cheng S., Huang K. Hybrid metaheuristic algorithms: past, present, and future. In: Yang X. S. (ed.) *Recent Advances in Swarm Intelligence and Evolutionary Computation. Studies in Computational Intelligence*. Springer, Cham; 2015. Pp. 71–83. https://doi.org/10.1007/978-3-319-13826-8_4



38. Yang Y., Chen H., Heidari A.A., Gandomi A.H. Hunger games search: Visions, conception, implementation, deep analysis, perspectives, and towards performance shifts. *Expert Systems with Applications*. 2021;177:114864. <https://doi.org/10.1016/j.eswa.2021.114864>
39. Nguyen H., Bui X.-N. A novel hunger games search optimization-based artificial neural network for predicting ground vibration intensity induced by mine blasting. *Natural Resources Research*. 2021;30:3865–3880. <https://doi.org/10.1007/s11053-021-09903-8>
40. Chen W., Sarir P., Bui X.-N. et al. Neuro-genetic, neuro-imperialism and genetic programming models in predicting ultimate bearing capacity of pile. *Engineering with Computers*. 2020;36:1101–1115. <https://doi.org/10.1007/s00366-019-00752-x>
41. Erkoc M.E., Karaboga N. A novel sparse reconstruction method based on multi-objective Artificial Bee Colony algorithm. *Signal Processing*. 2021;189:108283. <https://doi.org/10.1016/j.sigpro.2021.108283>
42. Fang Q., Nguyen H., Bui X.-N., Tran Q.-H. Estimation of blast-induced air overpressure in quarry mines using cubist-based genetic algorithm. *Natural Resources Research*. 2020;29:593–607. <https://doi.org/10.1007/s11053-019-09575-5>
43. Liu L., Moayed H., Rashid A.S.A. et al. Optimizing an ANN model with genetic algorithm (GA) predicting load-settlement behaviours of eco-friendly raft-pile foundation (ERP) system. *Engineering with Computers*. 2020;36:421–433. <https://doi.org/10.1007/s00366-019-00767-4>
44. Nguyen H., Bui H.-B., Bui X.-N. Rapid determination of gross calorific value of coal using artificial neural network and particle swarm optimization. *Natural Resources Research*. 2021;30:621–638. <https://doi.org/10.1007/s11053-020-09727-y>
45. Peng B., Wu L., Wang Y., Wu Q. Solving maximum quasi-clique problem by a hybrid artificial bee colony approach. *Information Sciences*. 2021;578:214–235. <https://doi.org/10.1016/j.ins.2021.06.094>
46. Xu Y., Wang X. An artificial bee colony algorithm for scheduling call centres with weekend-off fairness. *Applied Soft Computing*. 2021;109:107542. <https://doi.org/10.1016/j.asoc.2021.107542>
47. Zhang X., Nguyen H., Bui X.-N. et al. Evaluating and predicting the stability of roadways in tunnelling and underground space using artificial neural network-based particle swarm optimization. *Tunnelling and Underground Space Technology*. 2020;103:103517. <https://doi.org/10.1016/j.tust.2020.103517>
48. Zhang X., Nguyen H., Bui X.-N. et al. Novel soft computing model for predicting blast-induced ground vibration in open-pit mines based on particle swarm optimization and XGBoost. *Natural Resources Research*. 2020;29:711–721. <https://doi.org/10.1007/s11053-019-09492-7>
49. Akay B., Karaboga D., Gorkemli B., Kaya E. A survey on the artificial bee colony algorithm variants for binary, integer and mixed integer programming problems. *Applied Soft Computing*. 2021;106:107351. <https://doi.org/10.1016/j.asoc.2021.107351>
50. Aygun H., Turan O. Application of genetic algorithm in exergy and sustainability: A case of aero-gas turbine engine at cruise phase. *Energy*. 2022;238:121644. <https://doi.org/10.1016/j.energy.2021.121644>
51. Bai B., Zhang J., Wu X. et al. Reliability prediction-based improved dynamic weight particle swarm optimization and back propagation neural network in engineering systems. *Expert Systems with Applications*. 2021;177:114952. <https://doi.org/10.1016/j.eswa.2021.114952>
52. Kennedy J., Eberhart R. Particle swarm optimization. In: *Proceedings of ICNN'95 – International Conference on Neural Networks*. 1995. Pp. 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>
53. Kiran M.S., Hakli H., Gunduz M., Uguz H. Artificial bee colony algorithm with variable search strategy for continuous optimization. *Information Sciences*. 2015;300:140–157. <https://doi.org/10.1016/j.ins.2014.12.043>
54. Liang B., Zhao Y., Li Y. A hybrid particle swarm optimization with crisscross learning strategy. *Engineering Applications of Artificial Intelligence*. 2021;105:104418. <https://doi.org/10.1016/j.engappai.2021.104418>
55. Mirjalili S. Genetic algorithm. In: *Evolutionary Algorithms and Neural Networks. Studies in Computational Intelligence*. Springer, Cham; 2019. Pp. 43–55. https://doi.org/10.1007/978-3-319-93025-1_4
56. Pourzangbar A., Vaezi M. Optimal design of brace-viscous damper and pendulum tuned mass damper using Particle Swarm Optimization. *Applied Ocean Research*. 2021;112:102706. <https://doi.org/10.1016/j.apor.2021.102706>
57. Roy A., Dubey C.P., Prasad M. Gravity inversion of basement relief using Particle Swarm Optimization by automated parameter selection of Fourier coefficients. *Computers & Geosciences*. 2021;156:104875. <https://doi.org/10.1016/j.cageo.2021.104875>
58. Tapia A.R., del Nozal A., Reina D.G., Millán P. Three-dimensional optimization of penstock layouts for micro-hydropower plants using genetic algorithms. *Applied Energy*. 2021;301:117499. <https://doi.org/10.1016/j.apenergy.2021.117499>
59. Wang C., Guo C., Zuo X. Solving multi-depot electric vehicle scheduling problem by column generation and genetic algorithm. *Applied Soft Computing*. 2021;112:107774. <https://doi.org/10.1016/j.asoc.2021.107774>



60. Wang S.-C. Genetic algorithm. In: *Interdisciplinary Computing in Java Programming. The Springer International Series in Engineering and Computer Science*. Springer, Boston; 2003. Pp. 101–116. https://doi.org/10.1007/978-1-4615-0377-4_6

61. Xiang W.-L., Li Y.-Z., He R.-C., An M.-Q. Artificial bee colony algorithm with a pure crossover operation for binary optimization. *Computers & Industrial Engineering*. 2021;152:107011. <https://doi.org/10.1016/j.cie.2020.107011>

Информация об авторах

Суан-Нам Буй – доктор наук, профессор, департамент открытых горных работ, Ханойский университет горного дела и геологии, Ханой, Вьетнам; Исследовательская группа инноваций для устойчивой и ответственной добычи полезных ископаемых (ISRM), Ханойский университет горного дела и геологии, Ханой, Вьетнам; ORCID [0000-0001-5953-4902](https://orcid.org/0000-0001-5953-4902), Scopus ID [36892679300](https://orcid.org/36892679300); e-mail buixuannam@humg.edu.vn

Хоанг Нгуен – департамент открытых горных работ, Ханойский университет горного дела и геологии, Ханой, Вьетнам; Исследовательская группа инноваций для устойчивой и ответственной добычи полезных ископаемых (ISRM), Ханойский университет горного дела и геологии, Ханой, Вьетнам; ORCID [0000-0001-6122-8314](https://orcid.org/0000-0001-6122-8314), Scopus ID [57209589544](https://orcid.org/57209589544); e-mail nguyenhoang@humg.edu.vn

Ки-Тао Ле – департамент открытых горных работ, Ханойский университет горного дела и геологии, Ханой, Вьетнам; Исследовательская группа инноваций для устойчивой и ответственной добычи полезных ископаемых (ISRM), Ханойский университет горного дела и геологии, Ханой, Вьетнам; Scopus ID [57209279515](https://orcid.org/57209279515); e-mail lequithao@humg.edu.vn

Туан-Нгок Ле – заместитель генерального директора, Vinacomin – Minerals Holding Corporation, Ханой, Вьетнам; e-mail letuannngoc@vimico.vn

Information about the authors

Huan-Nam Bui – Dr.-Ing, Professor, Department of Surface Mining, Mining Faculty, Hanoi University of Mining and Geology; Research Group of Innovations for Sustainable and Responsible Mining (ISRM), Hanoi University of Mining and Geology; ORCID [0000-0001-5953-4902](https://orcid.org/0000-0001-5953-4902), Scopus ID [36892679300](https://orcid.org/36892679300); e-mail buixuannam@humg.edu.vn

Hoang Nguyen – Department of Surface Mining, Mining Faculty, Hanoi University of Mining and Geology; Research Group of Innovations for Sustainable and Responsible Mining (ISRM), Hanoi University of Mining and Geology; ORCID [0000-0001-6122-8314](https://orcid.org/0000-0001-6122-8314), Scopus ID [57209589544](https://orcid.org/57209589544); e-mail nguyenhoang@humg.edu.vn

Qui-Thao Le – Department of Surface Mining, Mining Faculty, Hanoi University of Mining and Geology; Research Group of Innovations for Sustainable and Responsible Mining (ISRM), Hanoi University of Mining and Geology; Scopus ID [57209279515](https://orcid.org/57209279515); e-mail lequithao@humg.edu.vn

Tuan-Ngoc Le – Deputy General Director, Vinacomin – Minerals Holding Corporation, Hanoi, Vietnam; e-mail letuannngoc@vimico.vn

Поступила в редакцию 17.01.2022
Поступила после рецензирования 22.02.2022
Принята к публикации 25.05.2022

Received 17.01.2022
Revised 22.02.2022
Accepted 25.05.2022