

Bài báo khoa học

Dự báo nồng độ bụi PM_{2.5} phát tán trong quá trình nổ mìn trên các mỏ lộ thiên sử dụng mạng nơ-ron nhân tạo và giải thuật tối ưu hóa bầy đàn cải tiến (APSO–MLP)

Nguyễn Hoàng^{1,2*}, Bùi Xuân Nam^{1,2}, Trần Quang Hiếu^{1,2}, Trần Khắc Hùng³, Nguyễn Tuấn Thành⁴

¹ Bộ môn Khai thác lộ thiên, Khoa Mỏ, Trường Đại học Mỏ – Địa chất, Số 18 Phố Viên, phường Đức Thắng, quận Bắc Từ Liêm, Hà Nội; nguyenhoang@humg.edu.vn; buixuannam@humg.edu.vn; tranquanghieu@humg.edu.vn

² Nhóm nghiên cứu mạnh Những tiến bộ trong khai thác mỏ bền vững và có trách nhiệm (ISRM), Trường Đại học Mỏ – Địa chất, Số 18 Phố Viên, phường Đức Thắng, quận Bắc Từ Liêm, Hà Nội

³ Viện Khoa học An toàn và Vệ sinh lao động (VNNIOSH); khachung722007@gmail.com

⁴ Trường Đại học Mỏ – Địa chất, Số 18 Phố Viên, phường Đức Thắng, quận Bắc Từ Liêm, Hà Nội; nguyentuanthanh@humg.edu.vn

* Tác giả liên hệ: nguyenhoang@humg.edu.vn; Tel.: +84–977218899

Ngày nhận bài: 6/02/2022; Ngày chấp nhận đăng: 16/03/2022; Ngày xuất bản: 25/8/2022

Tóm tắt: Trong bài báo này, bụi mịn PM_{2.5} sinh ra do quá trình nổ mìn trên mỏ lộ thiên đã được dự báo bởi các mô hình trí tuệ nhân tạo dựa trên mạng nơ-ron truyền thẳng nhiều lớp (*Multi-layer Perceptron Neural Network – MLP*) và các giải thuật “tối ưu hóa bầy đàn” được cải tiến (*Accelerated Particle Swarm Optimization – APSO*), giải thuật di truyền (*Genetic Algorithm – GA*), có tên gọi APSO–MLP và GA–MLP. Các thông số nổ mìn và điều kiện khí tượng đã được xem xét trong nghiên cứu này. Một mạng MLP đã được thiết kế để dự báo nồng độ bụi mịn PM_{2.5}. Các giải thuật tối ưu hóa APSO và GA đã được đưa vào để tối ưu hóa các trọng số của mô hình MLP nhằm cải thiện mức độ chính xác của mô hình MLP truyền thống trong quá trình dự báo. Các kết quả cho thấy cả hai mô hình được phát triển đều có khả năng dự báo nồng độ bụi mịn PM_{2.5} sinh ra do nổ mìn với mức độ chính xác tương đối cao. Trong đó, mô hình APSO–MLP cung cấp mức độ chính xác cao hơn so với mô hình GA–MLP (RMSE = 5,102; R² = 0,900 và MAPE = 0,063). Trong khi đó, mô hình GA–MLP chỉ cung cấp mức độ chính xác với RMSE = 5,331, R² = 0,890 và MAPE = 0,073.

Từ khóa: Mỏ lộ thiên; Nổ mìn; PM_{2.5}; Mạng nơ-ron nhân tạo; Giải thuật tối ưu; Phát triển bền vững.

1. Đặt vấn đề

Khai thác lộ thiên là một trong những phương pháp khai thác phổ biến nhất nhằm thu hồi tài nguyên khoáng sản có ích trong lòng đất. Tuy nhiên, các tác động tiêu cực của các hoạt động khai thác lộ thiên tới môi trường xung quanh là không hề nhỏ (bụi, khí độc, chiếm dụng diện tích đất đai, nhiễm bẩn nguồn nước, chấn động nổ mìn,...). Trong số các tác động đó, vấn đề ô nhiễm bụi trên các mỏ lộ thiên đang là mối quan tâm chính của các mỏ, đặc biệt là bụi mịn [1–2].

Một trong các hoạt động chính trên các mỏ lộ thiên gây phát sinh một lượng lớn bụi đó là hoạt động nổ mìn. Những đám mây bụi rất lớn xuất hiện sau mỗi vụ nổ mang theo nhiều bụi mịn [3–4]. Dưới tác động của các điều kiện khí tượng, đặc biệt là hướng gió và tốc độ

gió, bụi mịn sẽ gây tác động không nhỏ tới môi trường xung quanh và vùng ảnh hưởng có thể rất rộng [5–6]. Để giảm thiểu bụi trong quá trình nổ mìn, các giải pháp như: tưới nước bề mặt bãi nổ trước và sau khi nổ mìn, sử dụng phương pháp nổ mìn phân đoạn sử dụng búa nước,... Những giải pháp này tuy có hiệu quả trong việc giảm bụi phát sinh sau khi nổ mìn, nhưng chưa có khả năng dự báo và kiểm soát được nồng độ bụi mịn phát tán do các hoạt động nổ mìn. Nói cách khác, các giải pháp kỹ thuật trên mới chỉ là các giải pháp giảm bụi tức thời mà chưa có khả năng dự báo trước khi các vụ nổ xảy ra để đánh giá mức độ ô nhiễm bụi do các hoạt động nổ mìn gây ra và các giải pháp tiềm năng có thể áp dụng để xử lý hiệu quả nồng độ bụi phát tán.

Để dự báo nồng độ bụi mịn phát sinh khi nổ mìn trên các mỏ lộ thiên, các phương pháp truyền thống thường sử dụng các mô hình mô phỏng nồng độ bụi phát tán theo hướng gió và tốc độ gió như mô hình Sutton, Pasquill, Berliand,... [7]. Tuy nhiên, các mô hình trên còn tồn tại nhiều hạn chế với mức độ chính xác còn khiêm tốn do các đặc thù riêng và các yếu tố hình học của mỏ.

Trong những năm gần đây, khoa học máy tính với sự phát triển của công nghệ thông tin và sự ra đời của trí tuệ nhân tạo đã làm thay đổi cả thế giới, không ngoại trừ khai thác mỏ. Để dự báo nồng độ bụi phát sinh trên mỏ nói chung và do các hoạt động nổ mìn nói riêng, nhiều mô hình trí tuệ nhân tạo (*Artificial Intelligence*) và học máy (*Machine learning*) đã được phát triển cho mục đích này với mức độ chính xác được cải thiện đáng kể so với các phương pháp truyền thống. [8] đã phát triển một mô hình trí tuệ nhân tạo lai (*Hybrid model*) dựa trên mạng nơ-ron nhân tạo (*Artificial Neural Network – ANN*) và giải thuật di truyền (*Genetic Algorithm – GA*), gọi tắt là GA-ANN để dự báo nồng độ bụi PM₁₀ phát sinh do các hoạt động khoan trên mỏ với mức độ chính xác sai số bình quân phương gốc RMSE = 0,028, hệ số xác định R² = 0,979, sai số tuyệt đối bình quân MAE = 0,023 và tỉ lệ phần trăm lỗi tuyệt đối trung bình MAPE = 0,055. Trong một nghiên cứu khác, [9] đã sử dụng hệ thống mờ (*fuzzy system*) dựa trên các mô phỏng Monte Carlo kết hợp với lý thuyết xác suất và lập trình biểu hiện gen (*Genetic Expression Programming – GEP*) để dự báo nồng độ bụi phát sinh khi nổ mìn trên mỏ. Các kết quả cho thấy mô hình này đạt tới mức độ chính xác R² = 0,8754 và RMSE = 7,0181 trong quá trình thử nghiệm. Các mô phỏng Monte Carlo của nghiên cứu này cũng cho thấy khoảng cách phát tán bụi không vượt quá 199–212 m. [10] cũng đã đề xuất một mô hình lai để dự báo nồng độ bụi khi nổ mìn tại mỏ đá vôi sử dụng các phân tích hồi quy (*regression analysis*) và thứ nguyên (*dimensional analysis*). Các kết quả cung cấp mức độ chính xác rất cao với R² = 0,9357. Một mô hình trí tuệ nhân tạo lai khác cũng đã được phát triển bởi [11] nhằm dự báo bụi phát tán theo phương thẳng đứng trong quá trình nổ mìn trên các mỏ lộ thiên sử dụng mạng nơ-ron nhân tạo và bản đồ nhận thức mờ (*fuzzy cognitive map*). Các kết quả cung cấp mức độ chính xác rất cao với R² = 0,9933 và RMSE = 0,009. [12] trong một nghiên cứu khác cũng đã đề xuất một mô hình trí tuệ nhân tạo dựa trên phân tích thứ nguyên và mạng nơ-ron nhân tạo cho mục đích tương tự và các kết quả là rất khả quan với độ nhạy và độ chính xác cao.

Xem xét các khía cạnh và tổng quan các công trình cho thấy trí tuệ nhân tạo là một công cụ mạnh mẽ cung cấp mức độ chính xác cao trong việc dự báo nồng độ bụi phát sinh trong quá trình nổ mìn. Tuy nhiên, các mô hình trí tuệ nhân tạo chưa được xem xét phát triển để dự báo nồng độ bụi phát sinh hoặc phát tán trong quá trình nổ mìn tại các mỏ lộ thiên Việt Nam. Do đó, bài báo này nhằm trình bày các kết quả nghiên cứu phát triển mô hình trí tuệ nhân tạo lai dựa trên mạng nơ-ron truyền thẳng nhiều lớp MLP và các giải thuật tối ưu hóa bầy đàn được cải tiến APSO, giải thuật GA, gọi tắt là APSO-MLP và GA-MLP, để dự báo nồng độ bụi PM_{2.5} phát tán trong quá trình nổ mìn.

2. Phương pháp nghiên cứu

Trong nghiên cứu này, mạng nơ-ron nhân tạo truyền thẳng nhiều lớp – MLP đã được xem xét để dự báo nồng độ bụi PM_{2.5} phát tán trong quá trình nổ mìn trên mỏ lộ thiên. MLP

được xem là một trong những loại mạng nơ-ron nhân tạo phổ biến và được áp dụng rộng rãi trong những năm gần đây [13–15].

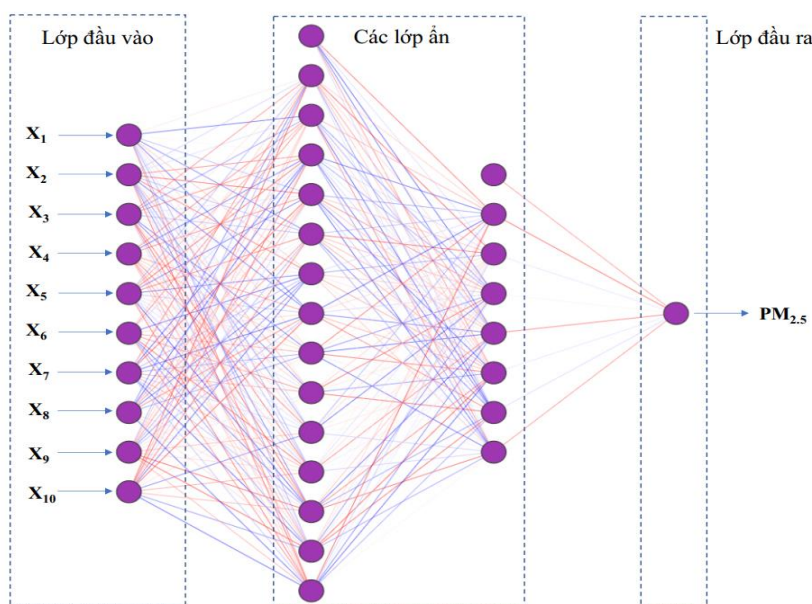
Cấu trúc của mạng MLP bao gồm lớp thông số đầu vào (*inputs*), một hoặc nhiều lớp ẩn, và lớp đầu ra (*output*). Các lớp này chứa các nơ-ron nhân tạo và chúng được liên kết với nhau để truyền tải và xử lý thông tin. Các nơ-ron được kết nối với nhau và được mã hóa dưới dạng các trọng số và độ lệch giữa các lớp. Chúng phản ánh mối liên hệ giữa các nơ-ron liên kết với nhau và được xử lý, tính toán thông qua các hàm kích hoạt giữa các tầng (lớp).

Ngoài ra, các hàm kích hoạt (*activation function*) được sử dụng để mô phỏng tỷ lệ truyền xung qua axon của một nơ-ron thần kinh và chúng thường đóng vai trò là thành phần phi tuyến tại các nút đầu ra của mạng nơ-ron [16]. Các hàm kích hoạt này có ảnh hưởng lớn tới mức độ chính xác của mạng nơ-ron trong quá trình huấn luyện.

Bên cạnh đó, một thành phần quan trọng không thể thiếu cho các mạng nơ-ron nhân tạo nói chung và mạng MLP nói riêng là giải thuật huấn luyện. Các giải thuật huấn luyện thường quyết định nhiều đến mức độ chính xác của mạng nơ-ron nhân tạo. Trong thực tế, có nhiều giải thuật có thể áp dụng để huấn luyện mạng nơ-ron nhân tạo như: giải thuật lan truyền ngược (*backpropagation algorithm*), giải thuật Levenberg–Marquardt, Adam,... [17–18].

Để đánh giá “mức độ tốt” của mạng nơ-ron nhân tạo, hàm mất mát (*Loss function*) được sử dụng nhằm tìm ra tập hợp trọng số và độ lệch tốt nhất giúp giảm thiểu hàm mất mát. Có rất nhiều hàm mất mát có sẵn có thể sử dụng để đánh giá hiệu suất huấn luyện của mạng MLP như MSE (sai số bình quân trung bình), RMSE, R^2 , MAPE,...

Do đó, việc thiết kế và lựa chọn cấu trúc mạng, giải thuật huấn luyện cũng như hàm kích hoạt hợp lý cho mạng nơ-ron nhân tạo MLP được xem là một công việc quan trọng và chúng quyết định tới mức độ chính xác của mô hình dự báo. Cấu trúc cơ bản của mạng MLP dự báo nồng độ bụi $PM_{2.5}$ phát tán do các hoạt động nổ mìn trên mỏ lộ thiên được minh họa trong hình 1.

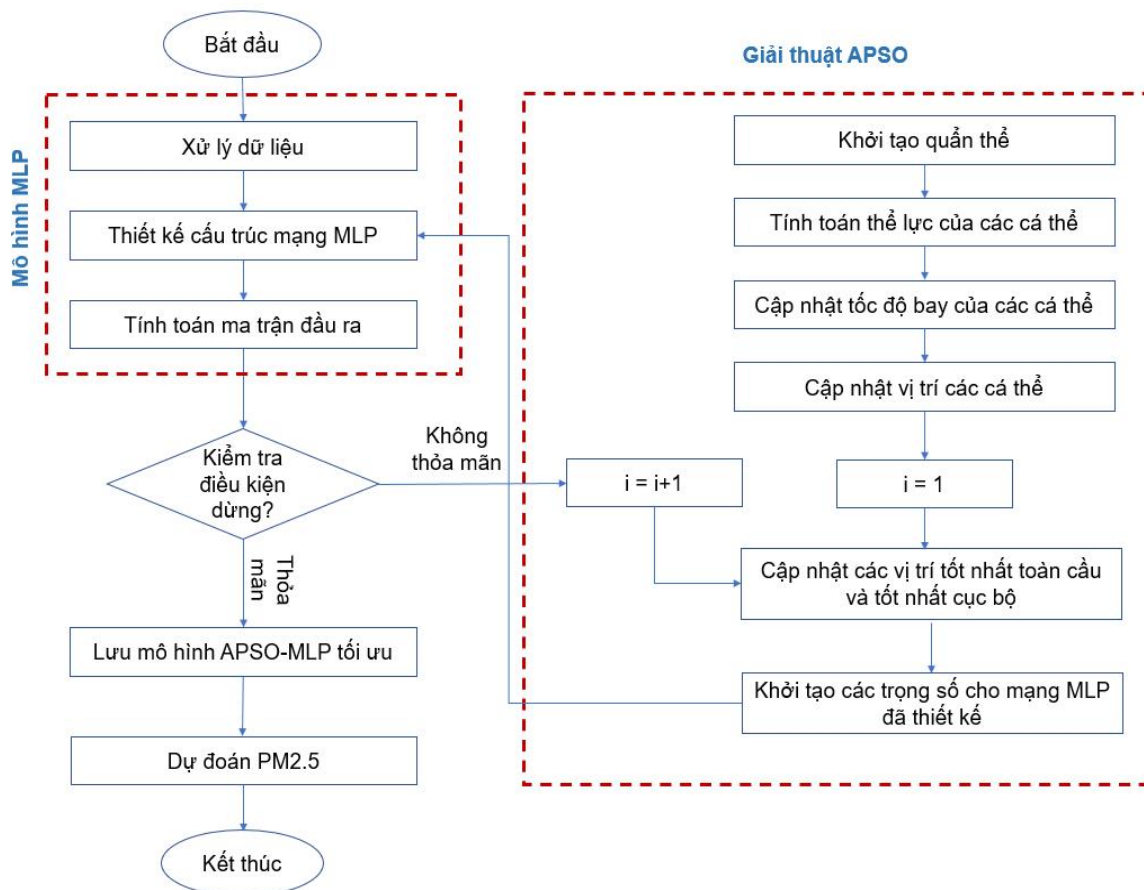


Hình 1. Mạng nơ-ron truyền thẳng nhiều lớp MLP dự báo $PM_{2.5}$ phát tán do các hoạt động nổ mìn trên mỏ lộ thiên.

Trong những năm gần đây, các giải thuật tối ưu cũng đã được nghiên cứu, phát triển mạnh mẽ và chúng có xu thế được sử dụng thay cho các giải thuật truyền thống để huấn luyện mạng nơ-ron nhân tạo với hiệu suất được cải thiện đáng kể [19–21]. Trong số đó, các giải thuật tối ưu hóa bầy đàn (*Particle Swarm Optimization – PSO*) và giải thuật di truyền (*Genetic Algorithm – GA*) là những giải thuật tối ưu được sử dụng rộng rãi trong nhiều lĩnh vực khác nhau.

[22] là những người đầu tiên giới thiệu giải thuật tối ưu hóa PSO từ năm 1995 dựa trên cơ chế săn mồi của các đàn động vật trong thực tế (đàn chim, đàn cá,...). Mặc dù có nhiều ưu điểm trong quá trình tối ưu hóa các bài toán thực tế, tuy nhiên giải thuật PSO gốc vẫn gặp phải một số nhược điểm như dễ bị rơi vào tối ưu cục bộ đối với dữ liệu nhiều chiều (khoảng không gian tìm kiếm lớn) và tốc độ hội tụ chậm [23]. Do đó, đến năm 1999, [24] đã thực hiện một cải tiến nhỏ nhằm khắc phục các nhược điểm trên bằng cách thêm vào các trọng số w_{min} và w_{max} (trọng lượng tối thiểu và tối đa của cá thể) và nó được gọi là giải thuật tối ưu hóa bầy đàn thúc đẩy Accelerated Particle Swarm Optimization – APSO). Chi tiết về giải thuật PSO và APSO có thể tham khảo trong các tài liệu tham khảo [24–27]. Dựa trên các ưu điểm của những cải tiến đó, nghiên cứu này đã xem xét sử dụng giải thuật APSO để tối ưu hóa mô hình mạng nơ-ron nhân tạo MLP dự báo nồng độ bụi $PM_{2.5}$ phát tán trong quá trình nổ mìn trên mỏ lộ thiên, được gọi là mô hình APSO–MLP. Sơ đồ làm việc của mô hình APSO–MLP được minh họa trong hình 2.

Trong nghiên cứu này, giải thuật GA cũng được xem xét sử dụng để tối ưu hóa mô hình MLP cho mục đích tương tự, gọi tắt là mô hình GA–MLP. Chi tiết về giải thuật GA có thể tham khảo trong các tài liệu [28–30]. Đồng thời, nó được sử dụng để so sánh với mô hình APSO–MLP trong quá trình dự báo nồng độ bụi $PM_{2.5}$ phát tán do các hoạt động nổ mìn trên mỏ lộ thiên. Cơ chế tối ưu hóa mô hình MLP của giải thuật GA tương tự như giải thuật APSO trong hình 2.



Hình 2. Sơ đồ làm việc của mô hình APSO–MLP.

3. Dữ liệu sử dụng

Trong nghiên cứu này, các dữ liệu được thu thập tại mỏ than Cọc Sáu tại Quảng Ninh. Đây là mỏ than lộ thiên sâu nhất Việt Nam đến thời điểm hiện tại (–300 m so với mực nước biển). Ngoài ra, mỏ than Cọc Sáu nằm liền kề với các mỏ than Đèo Nai và Cao Sơn và cách khu vực dân cư khoảng hơn 600m về phía Nam. Do đó, ảnh hưởng của bụi mỏ là rất lớn.

Trong nghiên cứu này, 10 biến đầu vào đã được xem xét bao gồm: khối lượng thuốc nổ sử dụng (Q), chỉ tiêu thuốc nổ (q), chiều dài cột bua (L_b), khoảng cách giữa các hàng lỗ khoan (b), độ ẩm không khí (AH), độ ẩm thành phần của đất đá (MC), áp suất không khí (AP), tốc độ gió (WS), hướng gió (WD), và khoảng cách quan trắc bụi tính từ vị trí nổ mìn (D).

Để quan trắc nồng độ bụi $PM_{2.5}$ phát tán trên mỏ do các hoạt động nổ mìn, các trạm quan trắc cố định (được thiết kế và chế tạo bởi nhóm nghiên cứu ISRM–Trường Đại học Mở – Địa chất) được đặt tại một số vị trí cần giám sát trên mỏ. Trong thực tế, các trạm quan trắc được đặt ở hướng Nam là hướng mà bụi mỏ có thể ảnh hưởng tới khu vực dân cư lân cận. Các vị trí đặt các trạm quan trắc có thể thay đổi tùy thuộc vào mỗi vụ nổ như được minh họa trong hình 3. Các giá trị nồng độ bụi được quan trắc theo thời gian thực với chu kỳ 1 giây. Tuy nhiên, chỉ giá trị nồng độ bụi lớn nhất được lựa chọn và sử dụng trong bộ dữ liệu như những biến đầu ra của mô hình (*output*). Thời gian quan trắc được tiến hành từ 04/2018 đến 12/2021 tùy thuộc vào điều kiện thực tại mỏ khi nổ mìn. Dữ liệu sử dụng trong nghiên cứu này được tóm tắt và mô phỏng trong bảng 1 và hình 4.

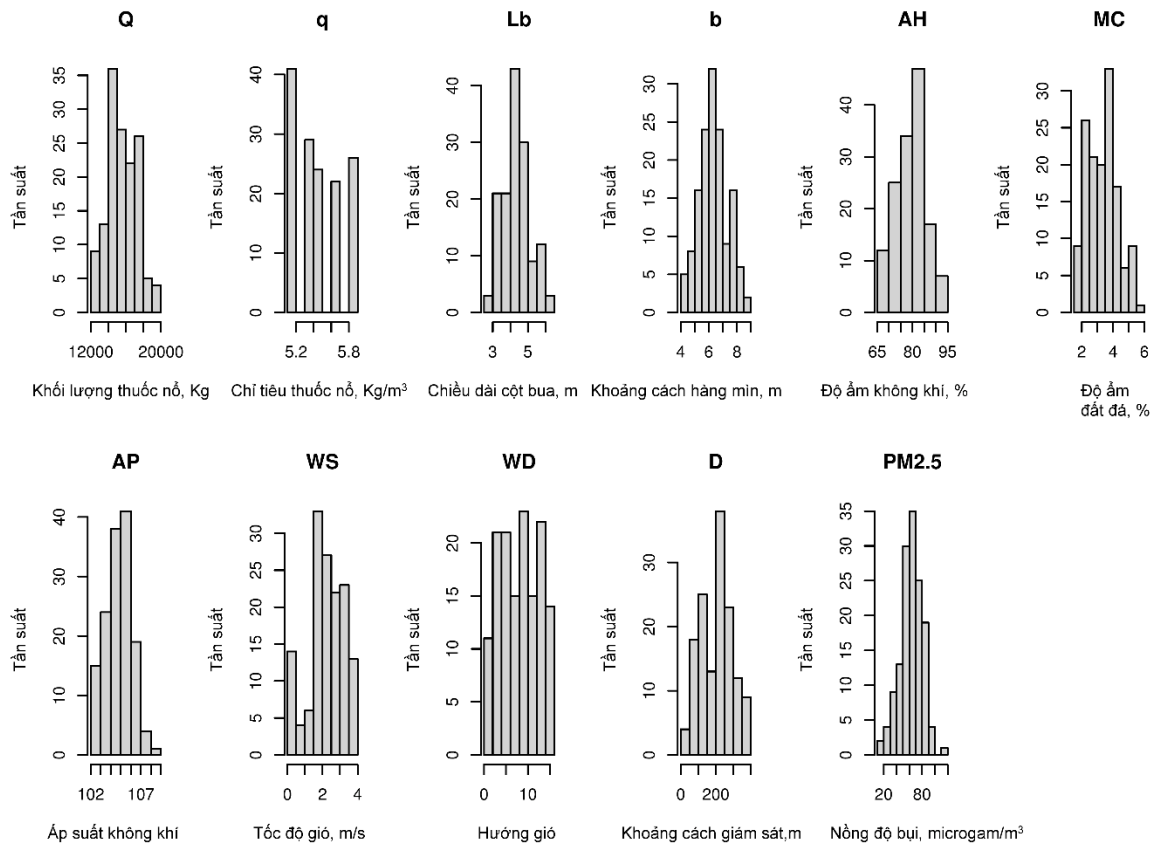


Hình 3. Mỏ than Cọc Sáu và các trạm quan trắc bụi trên mỏ.

Bảng 1. Tóm tắt dữ liệu sử dụng để dự báo $PM_{2.5}$ phát tán do nổ mìn.

Phân loại	Q	q	L_b	b	AH	MC	AP	WS	WD	D	$PM_{2.5}$
Nhỏ nhất	12248	5,1	2,8	4	69	1,74	102	0,02	1	29,9	17
25% dữ liệu	14598	5,2	3,8	5,8	75	2,513	104	1,725	5	116,4	52
Trung vị	15404	5,5	4,3	6,4	80,5	3,455	105	2,3	9	215,1	65
Trung bình	15625	5,484	4,369	6,365	79,86	3,327	105,3	2,245	8,563	203,8	63,38
75% dữ liệu	16941	5,7	4,8	7	84	3,98	106	3,013	12,75	263,1	75
Lớn nhất	19688	5,9	6,3	8,7	95	5,54	109	3,97	15	386,2	114

Lưu ý, hướng gió đã được mã hóa dưới dạng số để phục vụ bài toán hồi quy một cách hiệu quả.



Hình 4. Mật độ phân bố của dữ liệu.

4. Kết quả và thảo luận

Trước khi phát triển mô hình APSO–MLP và GA–MLP để dự báo PM_{2.5}, bộ dữ liệu đã được xem xét, phân tích và tiền xử lý để loại bỏ các yếu tố có thể gây nhiễu hoặc giảm mức độ chính xác của mô hình. Sau đó, 142 dữ liệu được phân chia ngẫu nhiên thành 2 phần: 70% sử dụng để huấn luyện mô hình và 30% còn lại để kiểm tra mức độ chính xác của các mô hình đã huấn luyện.


Để thiết kế cấu trúc mạng MLP, kỹ thuật thử và sai (*trial-and-error*) đã được áp dụng. Một cấu trúc MLP với một lớp ẩn và 25 nơ-ron ẩn đã được thiết lập trong mạng MLP. Một hàm mục tiêu (*loss function*) phức tạp MSE đã được sử dụng làm trong quá trình huấn luyện mạng MLP này. Quá trình huấn luyện, hàm kích hoạt ReLU đã được sử dụng. Bên cạnh đó, số lượng quần thể ban đầu được khởi tạo được thiết lập với 200 cá thể và quá trình huấn luyện được thực hiện với 1000 epoches và batch size là 16.

Đối với các tham số của giải thuật, 10 bộ tham số khác nhau của mỗi giải thuật được xem xét áp dụng để tham gia vào quá trình huấn luyện mô hình MLP. Để đánh giá và lựa chọn được bộ tham số tốt nhất của giải thuật, một hàm mục tiêu phức tạp dựa trên nhiều chỉ số hiệu suất (RMSE và MAPE) đã được sử dụng để đánh giá hiệu suất của các mô hình một cách toàn diện hơn như được trình bày trong phương trình (1).

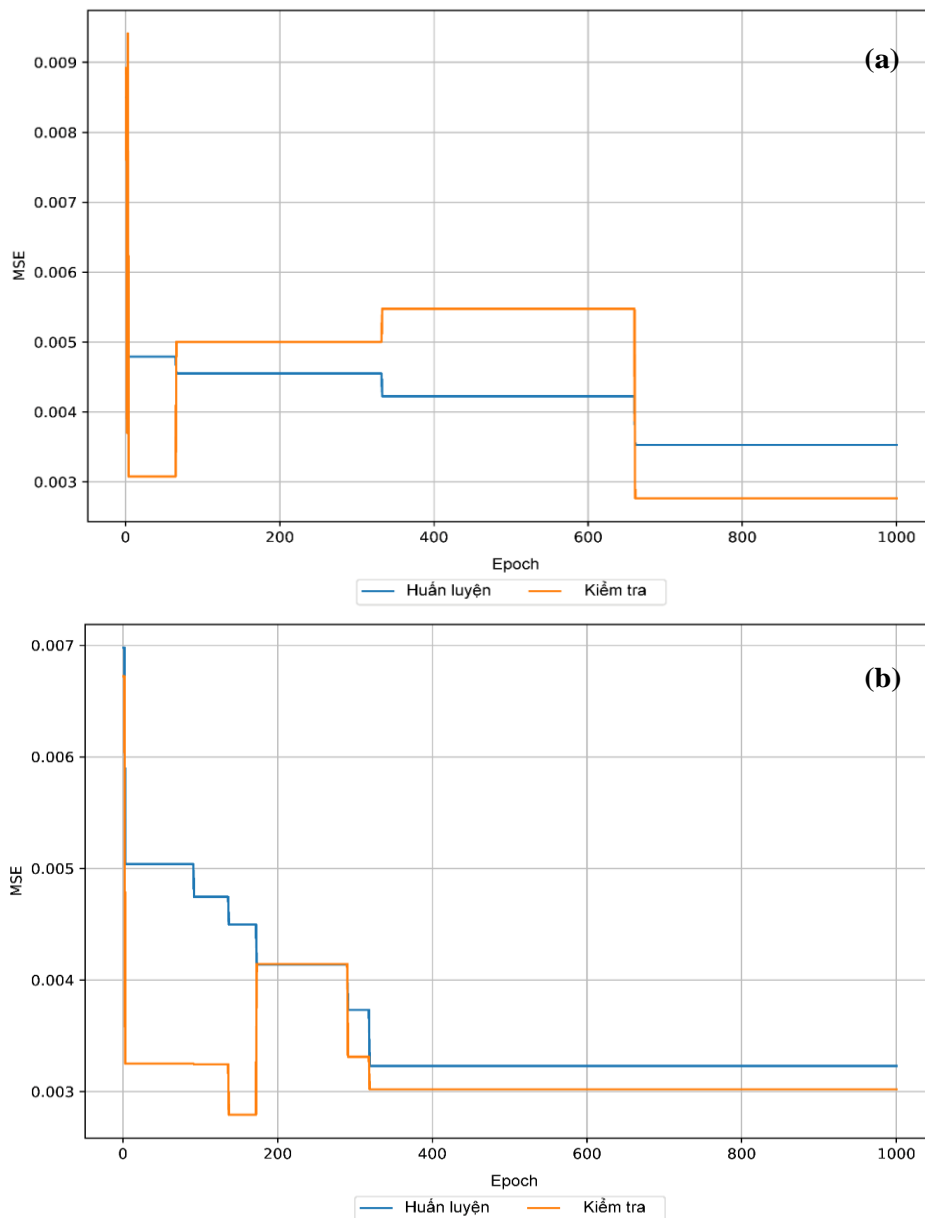
$$\text{fitness} = 0.5\text{RMSE} + 0.5\text{MAPE} \tag{1}$$

Trong quá trình huấn luyện mô hình, kỹ thuật kiểm tra chéo k–nếp gấp (*k-folds cross-validation*) đã được áp dụng để đánh giá hiệu suất của mô hình một cách khách quan, không thiên vị. Trong nghiên cứu này, 5 folds đã được sử dụng và lặp lại 3 lần trong quá trình huấn luyện mô hình. Theo đó, 70% dữ liệu huấn luyện được chia thành 5 folds và chúng lần lượt được huấn luyện và kiểm tra để xác định mức độ chính xác trung bình trong quá trình huấn luyện mô hình như được minh họa trong hình 5. Quá trình huấn luyện và chọn bộ tham số tốt

nhất cho các mô hình APSO-MLP và GA-MLP để dự báo nồng độ PM_{2.5} phát tán do các hoạt động nổ mìn trên mỏ lộ thiên được minh họa trong hình 6.



Hình 5. Kỹ thuật kiểm tra chéo với 5 folds.



Hình 6. Hiệu suất huấn luyện và kiểm tra của các mô hình APSO-MLP và GA-MLP với các bộ tham số tốt nhất: (a) Mô hình APSO-MLP; (b) Mô hình GA-MLP.

Các kết quả huấn luyện mô hình MLP bằng các giải thuật tối ưu APSO và GA để dự báo PM_{2.5} trong hình 6 cho thấy sai số của các mô hình rất nhỏ (MSE trên dưới 0,003) và không có sự khác biệt nhiều giữa hai mô hình. Các kết quả tương tự cũng được ghi nhận trên tập dữ liệu kiểm tra. Tuy nhiên, đối với mô hình GA-MLP, vùng hội tụ lại không phải vùng cung cấp mức độ chính xác cao nhất, như thể hiện trong hình 6. Trong khi đó, mô hình APSO-MLP cung cấp mức độ chính xác cao nhất tại vùng hội tụ nhất.

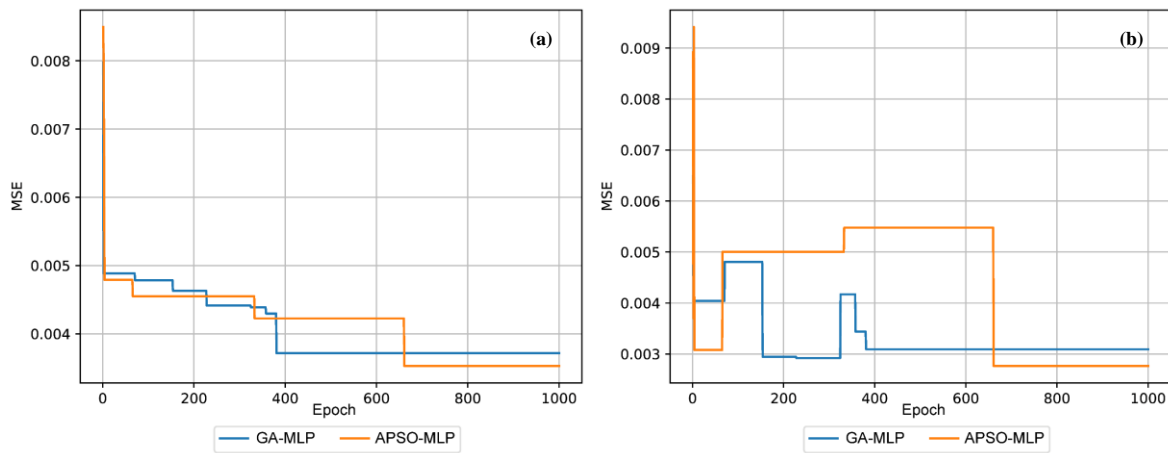
Lưu ý, các kết quả huấn luyện và kiểm tra trên được thực hiện trong quá trình tìm kiếm các bộ tham số tốt nhất cho các mô hình. Sau khi các bộ tham số tốt nhất của các mô hình APSO-MLP và GA-MLP đã được tìm thấy, quá trình huấn luyện lại các mô hình này với bộ tham số tốt nhất đã được tiến hành như sau:

- Mô hình APSO-MLP: $C_1 = C_2 = 1,2$; $W_{\min} = 0,5$; $W_{\max} = 0,9$;

- Mô hình GA-MLP: $P_c = 0,8$; $P_m = 0,1$;

- Cả 2 mô hình này đều được huấn luyện dựa trên 200 cá thể khởi tạo ngẫu nhiên ban đầu và được thực hiện với 1000 epoch.

Hiệu suất huấn luyện lại và mức độ hội tụ của mạng nơ-ron nhân tạo MLP dựa trên các tham số tối ưu của các giải thuật tối ưu được minh họa trong hình 7.



Hình 7. Mức độ hội tụ của các mô hình APSO-MLP và GA-MLP trong dự báo PM_{2.5}: (a) Quá trình huấn luyện; (b) Quá trình kiểm tra.

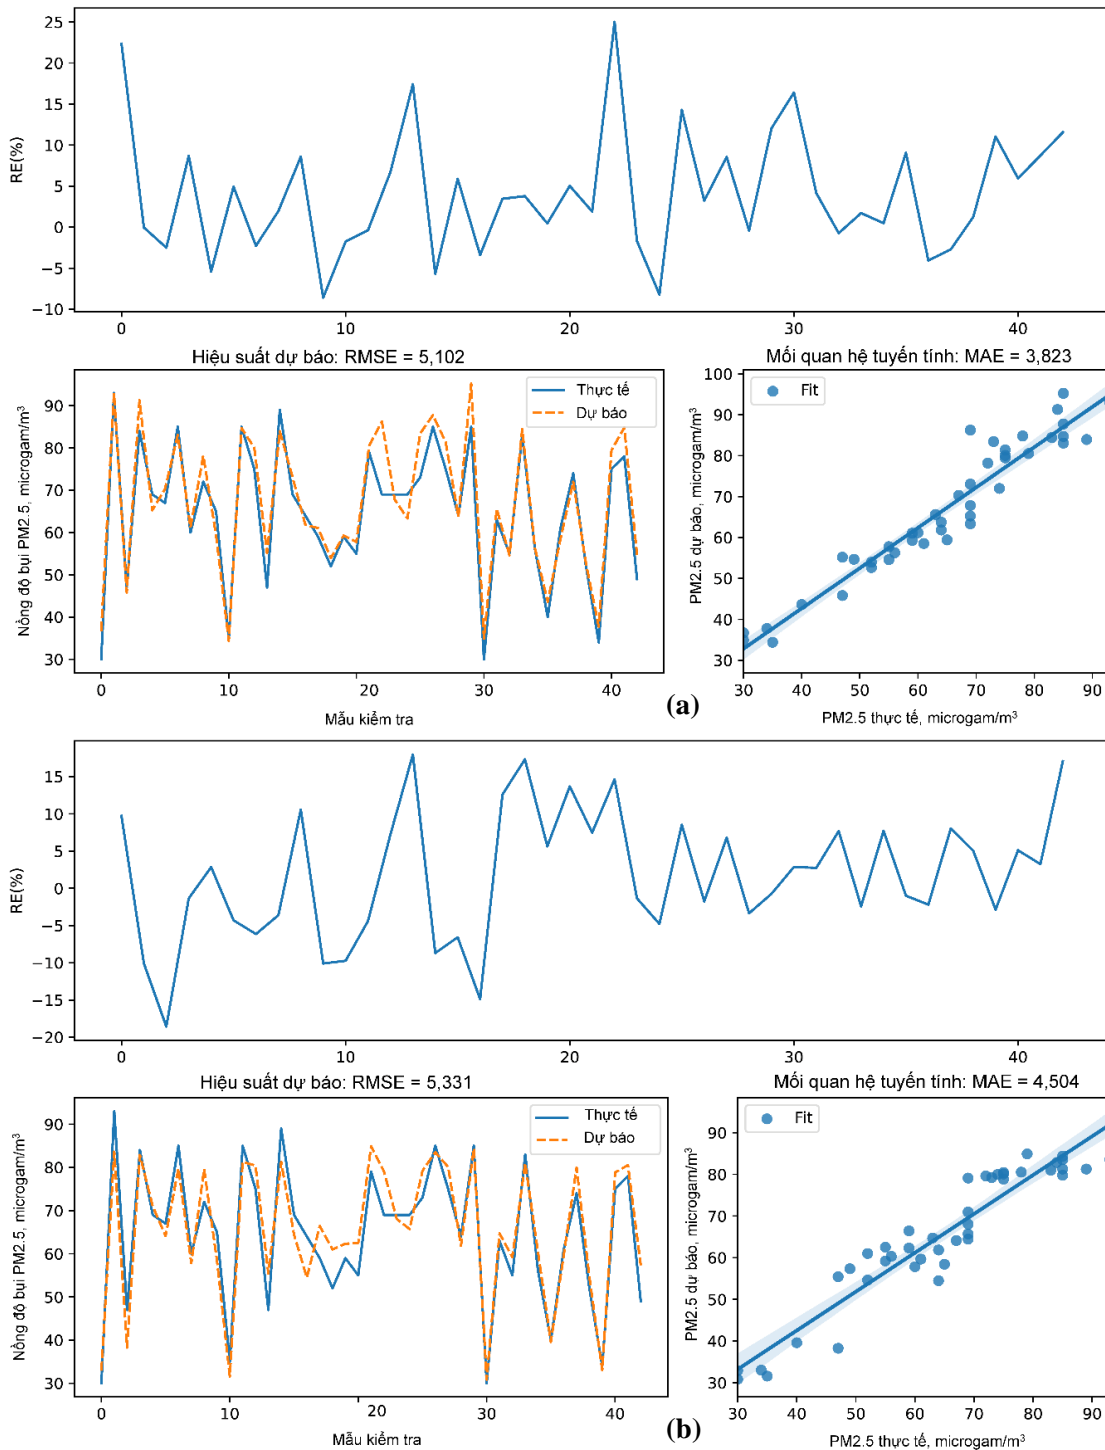
Nhìn vào hình 7, có thể thấy mô hình APSO-MLP dường như cung cấp mức độ chính xác cao hơn trên cả bộ dữ liệu huấn luyện và dữ liệu kiểm tra khi dự báo nồng độ PM_{2.5} phát tán do nổ mìn trên mỏ. Mức độ hội tụ trên tập dữ liệu huấn luyện dường như rất tốt khi sai số MSE giảm dần theo biên độ mạnh và hội tụ dần ở mức dưới 0,004. Trên tập dữ liệu kiểm tra, mức độ sai số có thể khác nhau ở các vị trí epoch khác nhau, tuy nhiên, sai số thấp nhất vẫn được ghi nhận ở mô hình APSO-MLP ở mức dưới 0,003. Để đánh giá hiệu suất dự báo PM_{2.5} của các mô hình đã phát triển, các chỉ số hiệu suất bao gồm: MAE, RMSE, R² và MAPE đã được sử dụng và tính toán dựa trên các giá trị thực tế và dự báo trong bảng 2.

Bảng 2. Hiệu suất của các mô hình dự báo PM_{2.5} phát tán do các hoạt động nổ mìn.

Mô hình	Số lượng quần thể	Dữ liệu huấn luyện				Dữ liệu kiểm tra			
		MAE	RMSE	R ²	MAPE	MAE	RMSE	R ²	MAPE
APSO-MLP	200	4,494	5,763	0,890	0,087	3,823	5,102	0,900	0,063
GA-MLP	250	4,259	5,513	0,899	0,080	4,504	5,331	0,890	0,073

Từ các kết quả trong bảng 2, có thể thấy hiệu suất của cả hai mô hình APSO-MLP và GA-MLP tương đối cao và không có sự chênh lệch lớn. Tuy nhiên, mô hình APSO-MLP cung cấp mức độ chính xác cao hơn một chút so với mô hình GA-MLP với MAE = 3,823;

RMSE = 5,102; $R^2 = 0,900$ và MAPE = 0,063 trên tập dữ liệu kiểm tra. Để đánh giá thêm và trực quan hơn về mức độ chính xác của các mô hình trên, sai số tương đối (relative error – RE) và tương quan giữa các giá trị dự báo và thực tế đã được minh họa trong hình 8.



Hình 8. Sai số tương đối RE, tuyệt đối và tương quan của các mô hình dự báo PM_{2.5}: (a) Mô hình APSO–MLP; (b) Mô hình GA–MLP.

Dựa trên các chỉ số sai số tương đối RE, tuyệt đối và tương quan của các mô hình dự báo PM_{2.5} trên hình 8, có thể thấy rõ hơn sự khác biệt giữa hai mô hình APSO–MLP và GA–MLP trong dự báo nồng độ PM_{2.5} phát tán khi nổ mìn. Trong khi biên độ dao động của RE trên mô hình APSO–MLP là từ –9 đến 25, mô hình GA–MLP cung cấp biên độ RE lớn hơn rất nhiều (từ –20 đến 20). Ngoài ra, các so sánh trên tập dữ liệu kiểm tra ở hình 8 cũng cho thấy mức độ chính xác của các dự đoán trên mô hình APSO–MLP là tốt hơn so với các dự đoán trên

mô hình GA–MLP. Do đó, mô hình APSO–MLP đã được lựa chọn làm mô hình chính thức để dự báo nồng độ bụi PM_{2.5} phát tán trong quá trình nổ mìn tại mỏ này.

5. Kết luận và kiến nghị

Dự báo nồng độ bụi phát tán trong quá trình nổ mìn trên các mỏ lộ thiên là một bài toán tương đối khó do ảnh hưởng của các yếu tố hình học mỏ, các thông số nổ mìn và điều kiện khí tượng. Trong khi các thông số hình học của mỏ không (hoặc ít) thay đổi, các thông số nổ mìn có thể thay đổi được thì các thông số về điều kiện khí tượng là những thông số không thể kiểm soát/thay đổi được. Do đó, việc dự báo nồng độ bụi nói chung và PM_{2.5} nói riêng là không đơn giản. Nghiên cứu này đã xem xét tổng thể các yếu tố về thông số nổ mìn trong các điều kiện khí tượng khác nhau với khoảng cách giám sát khác nhau để xây dựng hai mô hình trí tuệ nhân tạo có khả năng dự báo nồng độ bụi PM_{2.5} phát tán do nổ mìn (APSO–MLP và GA–MLP). Các kết quả bước đầu cho thấy mức độ khả thi và độ chính xác có thể chấp nhận được cho các mô hình trí tuệ nhân tạo trong việc dự báo nồng độ PM_{2.5} phát tán do nổ mìn. Trong đó, mô hình APSO được đánh giá là tốt hơn một chút so với mô hình GA–MLP trong nghiên cứu này với độ chính xác dao động ở mức 90%.

Mặc dù nghiên cứu này đã chỉ ra mức độ khả thi của các mô hình trí tuệ nhân tạo trong dự báo nồng độ bụi phát tán khi nổ mìn trên các mỏ lộ thiên, tuy nhiên, chúng cần được tiếp tục nghiên cứu mở rộng trong tương lai với việc xem xét dự báo nồng độ bụi trong không gian, tối ưu hóa số lượng biến đầu vào hoặc xem xét các mô hình trí tuệ nhân tạo khác với mục đích cải thiện mức độ chính xác trong quá trình dự báo. Các kết quả nghiên cứu là tiền đề để tối ưu hóa các thông số nổ mìn nhằm giảm thiểu hoặc kiểm soát bụi phát tán ra môi trường xung quanh, hướng tới khai thác bền vững và có trách nhiệm với môi trường.

Đóng góp của các tác giả: Lên ý tưởng, Điều tra, khảo sát, Viết và chỉnh sửa bản thảo: N.H., B.X.N.; Phân tích sơ bộ, xử lý dữ liệu, trực quan hóa các kết quả, viết bản thảo gốc: T.Q.H., T.K.H., N.T.T.

Lời cảm ơn: Nhóm tác giả xin gửi lời cảm ơn tới Trung tâm Nghiên cứu Cơ Điện Mỏ và các thành viên trong nhóm nghiên cứu mạnh “Những tiến bộ trong khai thác mỏ bền vững và có trách nhiệm” – ISRM của Trường Đại học Mỏ địa chất đã hỗ trợ nhóm nghiên cứu thu thập dữ liệu phục vụ nghiên cứu này.

Tài liệu tham khảo

1. Silvester, S.; Lowndes, I.; Hargreaves, D. A computational study of particulate emissions from an open pit quarry under neutral atmospheric conditions. *Atmos. Environ.* **2009**, *43*(40), 6415–6424.
2. 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.
3. Bhandari, S.; Bhandari, A.; Arya, S. Dust resulting from blasting in surface mines and its control. Proceedings of explosive conference. 2004.
4. Bhandari, S. Fines and dust generation and control in rock fragmentation by blasting. in *Rock Fragmentation by Blasting: The 10th International Symposium on Rock Fragmentation by Blasting, 2012 (Fragblast 10)*. Taylor & Francis Books Ltd, 2013.
5. Heo, S.; Kim, D.Y.; Kwoun, Y.; Lee, T.J.; Jo, Y.M. Characterization and source identification of fine dust in Seoul elementary school classrooms. *J. Hazard. Mater* **2021**, *414*, 125531.
6. Vanicela, B.D.; Nebel, M.; Stephan, M.; Riethmüller, C.; Gresser, G. Quantitative analysis of fine dust particles on moss surfaces under laboratory conditions using the example of *Brachythecium rutabulum*. *Environ. Sci. and Pollut. Res.* **2021**, *28*(37), 51763–51771.

7. Nam, C.t.k.t.đ.v.Y.V. Báo cáo đánh giá tác động môi trường "Dự án đầu tư cải tạo mở rộng nâng công suất mỏ đá hoa trắng Châu Cường, xã Châu Cường, huyện Quỳnh Hợp, Nghệ An. 2014.
8. Bui, X.N. et al. Utilizing a Novel Artificial Neural Network–Based Meta–heuristic Algorithm to Predict the Dust Concentration in Deo Nai Open–Pit Coal Mine (Vietnam). Cham: Springer International Publishing, 2021.
9. Bakhtavar, E. et al. Air Pollution Risk Assessment Using a Hybrid Fuzzy Intelligent Probability–Based Approach: Mine Blasting Dust Impacts. *Nat. Resour. Res.* **2021**, *30(3)*, 2607–2627.
10. Hosseini, S.; Mousavi, A.; Monjezi, M. Prediction of blast–induced dust emissions in surface mines using integration of dimensional analysis and multivariate regression analysis. *Arabian J. Geosci.* **2022**, *15(2)*, 163.
11. Bakhtavar, E. et al. Green blasting policy: Simultaneous forecast of vertical and horizontal distribution of dust emissions using artificial causality–weighted neural network. *J. Cleaner Prod.* **2021**, *283*, 124562.
12. Hosseini, S. et al. Prediction of Dust Emission Due to Open Pit Mine Blasting Using a Hybrid Artificial Neural Network. *Nat. Resour. Res.* **2021**, *30(6)*, 4773–4788.
13. Hyder, Z.; Siau, K.; Nah, F. Artificial intelligence, machine learning, and autonomous technologies in mining industry. *J. Database Manage.* **2019**, *30(2)*, 67–79.
14. Ali, D.; Frimpong, S. Artificial intelligence, machine learning and process automation: existing knowledge frontier and way forward for mining sector. *Artif. Intell. Rev.* **2020**, *53(8)*, 6025–6042.
15. Soofastaei, A. The application of artificial intelligence to reduce greenhouse gas emissions in the mining industry, in Green Technologies to Improve the Environment on Earth. IntechOpen London, UK, 2018.
16. Sharma, S.; Sharma, S.; Athaiya, A. Activation functions in neural networks. *Towards Data Sci.* **2017**, *6(12)*, 310–316.
17. Ghaffari, A. et al. Performance comparison of neural network training algorithms in modeling of bimodal drug delivery. *Int. J. Pharm.* **2006**, *327(1–2)*, 126–138.
18. Can, A. et al. Landslide susceptibility mapping at Ovacık–Karabük (Turkey) using different artificial neural network models: comparison of training algorithms. *Bull. Eng. Geol. Environ.* **2019**, *78(1)*, 89–102.
19. Abedinia, O.; Amjady, N.; Ghadimi, N. Solar energy forecasting based on hybrid neural network and improved metaheuristic algorithm. *Comput. Intell.* **2018**, *34(1)*, 241–260.
20. Chong, H.Y. et al. Advances of metaheuristic algorithms in training neural networks for industrial applications. *Soft Comput.* **2021**, *25(16)*, 11209–11233.
21. Khan, A. et al. An alternative approach to neural network training based on hybrid bio meta–heuristic algorithm. *J. Ambient Intell. Hum. Comput.* **2019**, *10(10)*, 3821–3830.
22. Kennedy, J.; Eberhart, R. Particle swarm optimization (PSO). Proc. IEEE International Conference on Neural Networks, Perth, Australia. 1995.
23. Li, M.; Du, W.; Nian, F. An adaptive particle swarm optimization algorithm based on directed weighted complex network. *Math. Probl. Eng.* **2014**, ID 434972.
24. Shi, Y.; Eberhart, R.C. Empirical study of particle swarm optimization. Proceedings of the 1999 congress on evolutionary computation–CEC99 (Cat. No. 99TH8406). IEEE, 1999.
25. Bui, X.N. et al. A novel Hybrid Model for predicting Blast–induced Ground Vibration Based on k–nearest neighbors and particle Swarm optimization. *Sci. Rep.* **2019**, *9(1)*, 1–14.

26. Ding, Z. et al. Computational Intelligence Model for Estimating Intensity of Blast-Induced Ground Vibration in a Mine Based on Imperialist Competitive and Extreme Gradient Boosting Algorithms. *Nat. Resour. Res.* **2020**, 29(2), 751–769.
27. Zhang, X. et al. Novel Soft Computing Model for Predicting Blast-Induced Ground Vibration in Open-Pit Mines Based on Particle Swarm Optimization and XGBoost. *Nat. Resour. Res.* **2020**, 29(2), 711–721.
28. Ahmadi, M.R.; Shahabi, R.S. Cutoff grade optimization in open pit mines using genetic algorithm. *Resour. Policy* **2018**, 55, 184–191.
29. Armaghani, D.J. et al. Airblast prediction through a hybrid genetic algorithm-ANN model. *Neural Comput. Appl.* **2018**, 29(9), 619–629.
30. El-Mihoub, T.A. et al. Hybrid Genetic Algorithms: A Review. *Eng. Lett.* **2006**, 13(2), 124–137.

Forecasting PM_{2.5} dust concentration induced by blasting in open pit mines using artificial neural network and improved swarm optimization algorithm (APSO-MLP)

Nguyen Hoang^{1,2*}, Bui Xuan Nam^{1,2}, Tran Quang Hieu^{1,2}, Tran Khac Hung³, Nguyen Tuan Thanh⁴

¹ Department of Open-pit Mining, Faculty of Mining, University of Mining – Geology, No. 18 Pho Vien, Duc Thang ward, Bac Tu Liem district, Hanoi; nguyenhoang@humg.edu.vn; buixuannam@humg.edu.vn; tranquanghieu@humg.edu.vn

² Research Group of Innovations in Sustainable and Responsible Mining (ISRM), Hanoi University of Mining and Geology, No. 18 Pho Vien, Duc Thang Ward, Bac Tu Liem District, Hanoi

³ Vietnam National Institute of Occupational Safety and Health (VNNIOSH); khachung722007@gmail.com

⁴ Department of Training, Hanoi University of Mining and Geology, No. 18 Pho Vien, Duc Thang Ward, Bac Tu Liem District, Hanoi. nguyentuantthanh@humg.edu.vn

Abstract: In this paper, PM_{2.5} induced by blasting operations in open-pit mines has been predicted by hybrid artificial intelligence models based on multi-layer perceptron neural network (MLP), accelerated particle swarm optimization (APSO), and genetic algorithm (GA), named as APSO-MLP and GA-MLP. Blasting parameters and meteorology conditions were considered for this aim. Subsequently, a MLP model was then designed for predicting PM_{2.5} based on the inputs (blasting parameters and meteorology conditions). The optimization algorithms APSO and GA then were applied to optimize the weights of the designed MLP model, aiming to improve the accuracy of the MLP model for predicting PM_{2.5}. The results showed that both hybrid models (APSO-MLP and GA-MLP) provided pretty high accuracies in predicting PM_{2.5} (over 90%). Of those, the APSO-MLP model provided a slightly higher performance with RMSE = 5.102; R² = 0.900 and MAPE = 0.063. Meanwhile, the GA-MLP model provided lower performance with an RMSE = 5.331, R² = 0.890 and MAPE = 0.073.

Keywords: Open pit mine; Mine blasting; PM_{2.5}; Artificial Neural Networks; Optimal Algorithm; Sustainable Development.