

NGHIÊN CỨU ỨNG DỤNG CÔNG NGHỆ AI VÀO QUÁ TRÌNH DỰ BÁO LỖI VÀ BẢO TRÌ MÁY IN 3D KIM LOẠI SLM

RESEARCH ON APPLYING AI TECHNOLOGY IN THE PROCESS OF ERROR PREDICTION AND MAINTENANCE OF SLM METAL 3D PRINTER

ThS. Bùi Quang Toàn

Khoa Cơ khí, Trường Đại học Công nghệ Đông Á

Email: toanbq@eaut.edu.vn

TÓM TẮT

Bài báo trình bày ứng dụng trí tuệ nhân tạo (AI) trong dự đoán lỗi và bảo trì cho máy in 3D kim loại dùng công nghệ Selective Laser Melting (SLM). Mô hình học máy được phát triển để phát hiện sớm lỗi từ dữ liệu cảm biến như nhiệt độ, độ rung, tốc độ laser... Kết quả thử nghiệm cho thấy mô hình cảnh báo lỗi hiệu quả, hỗ trợ bảo trì chính xác. So sánh với phương pháp truyền thống, hệ thống AI thể hiện tiềm năng lớn trong nâng cao hiệu suất và giảm chi phí vận hành.

Từ khóa: AI; Bảo trì; Máy in 3D; SLM; Học máy; Cảm biến.

ABSTRACT

The paper presents the application of artificial intelligence (AI) in fault prediction and maintenance for metal 3D printers using Selective Laser Melting (SLM) technology. The machine learning model is developed to detect faults early from sensor data such as temperature, vibration, laser speed, etc. The experimental results show that the fault warning model is effective, supporting accurate maintenance. Compared with the traditional method, the AI system shows great potential in improving performance and reducing operating costs.

Từ khóa: AI; Maintenance; 3D printers; SLM; Machine learning; Sensors.

1. ĐẶT VẤN ĐỀ

Máy in 3D kim loại sử dụng công nghệ SLM đã mở ra những khả năng sản xuất mới, đặc biệt trong việc chế tạo các chi tiết có hình dạng phức tạp, tính chất cơ học cao và khối lượng sản xuất linh hoạt. Tuy nhiên, quá trình vận hành máy in 3D kim loại đòi hỏi độ chính xác rất cao, do sự nhạy cảm của các thông số quá trình như năng lượng laser, tốc độ quét, độ dày lớp in và môi trường khí trơ [8, 9].

Các lỗi trong quá trình in như rỗ xốp (porosity), biến dạng nhiệt (warping), hoặc hư hỏng đầu phun (nozzle) nếu không được phát hiện kịp thời sẽ dẫn đến sản phẩm lỗi và hư hỏng thiết bị. Bảo trì truyền thống, vốn dựa trên lịch trình cố định hoặc sửa chữa khi có hỏng hóc, không đủ nhanh nhạy để xử lý các lỗi này. Vì thế, ứng dụng AI để xây dựng hệ thống bảo trì dự đoán (Predictive Maintenance - PdM) trở nên cần thiết [1, 6, 13].



2. GIẢI QUYẾT VẤN ĐỀ

2.1. Cơ sở lý thuyết [2-5]

- Selective Laser Melting (SLM): Là công nghệ in 3D kim loại sử dụng laser để nung chảy từng lớp bột kim loại. Chất lượng in phụ thuộc vào các yếu tố như công suất laser, độ dày lớp bột, tốc độ quét và điều kiện môi trường khí trơ.

- Bảo trì dự đoán (PdM): Sử dụng dữ liệu cảm biến thời gian thực để phân tích và dự báo lỗi trước khi xảy ra, giúp giảm thời gian dừng máy và tối ưu chi phí bảo trì.

- Học máy trong bảo trì: Gồm các thuật toán như Random Forest, SVM, LSTM và CNN. LSTM phù hợp với dữ liệu chuỗi thời gian, còn CNN xử lý hình ảnh lớp in. Những mô hình này giúp tự động phát hiện và phân loại lỗi chính xác hơn so với các phương pháp thủ công.

Việc kết hợp các mô hình này trong một hệ thống phân tích đa tầng cho phép phát hiện sớm, chính xác và toàn diện các lỗi tiềm ẩn trong quy trình sản xuất bằng máy in 3D kim loại.

2.2. Phương pháp nghiên cứu [7, 10, 11]

2.2.1. Thiết lập hệ thống thu thập dữ liệu

- Máy in: EOS M290 (SLM);
- Cảm biến: Nhiệt độ, rung động, áp suất, camera quan sát lớp in;
- Số lượng mẫu: 1.200 phiên in, dữ liệu đa nguồn.

2.2.2. Tiền xử lý dữ liệu

- Làm sạch, chuẩn hóa, gán nhãn lỗi theo nhật ký vận hành;
- Trích chọn đặc trưng bằng PCA, FFT và phân tích hình ảnh.

2.2.3. Xây dựng mô hình AI

- LSTM: Phát hiện bất thường trên chuỗi dữ liệu cảm biến;
- CNN: Phát hiện lỗi trên hình ảnh lớp in;
- Random Forest: Phân loại trạng thái thiết bị từ dữ liệu tổng hợp.

2.3. Nội dung nghiên cứu

2.3.1. Nguồn dữ liệu

Nguồn dữ liệu được thu thập từ xưởng in công nghiệp với máy EOS M290 trong thời gian 3 tháng. Dữ liệu gồm:

- 300 triệu điểm dữ liệu từ cảm biến (tần suất 10 Hz).
- 45.000 ảnh lớp in.
- Nhật ký vận hành: Thời gian chạy máy, lỗi hệ thống, lịch bảo trì.



Hình 1. Máy in 3D kim loại EOS M290

2.3.2. Quy trình tiền xử lý


- Loại bỏ dữ liệu ngoại lệ, xử lý mất mát gói tin.
- Áp dụng PCA để giảm chiều dữ liệu về 20 thành phần chính.
- Gắn nhãn lỗi thủ công từ ảnh in mẫu và nhật ký lỗi đã xác nhận.

2.3.3. Thực nghiệm và đánh giá mô hình AI

Mỗi mô hình được thực nghiệm trên 80% dữ liệu, 10% dùng để xác thực và 10% để kiểm thử. Kết quả mô hình như sau:

Bảng 1. Kết quả thực nghiệm

Mô hình	Độ chính xác	Precision	Recall	F1 - score	AUC - ROC	Training Time
LSTM	91.2%	90.5%	89.8%	0.901	0.943	6 giờ
CNN	87.3%	88.0%	91.2%	0.896	0.912	3.5 giờ
Random Forest	93.4%	94.1%	92.7%	0.934	0.961	1.2 giờ




Biểu đồ 1. Đường cong ROC của các mô hình (LSTM, CNN, RF)

2.3.4. So sánh phương pháp AI-PdM với bảo trì định kỳ truyền thống

Bảng 2. So sánh hiệu suất AI-PdM với bảo trì truyền thống

Tiêu chí đánh giá	Bảo trì định kỳ truyền thống	AI-PdM
Thời gian dừng máy trung bình	12 giờ/tháng	4.3 giờ/tháng
Tỷ lệ phát hiện lỗi sớm	43%	89%
Chi phí bảo trì (quy đổi %)	100%	63%
Năng suất máy tăng (ước lượng)	-	+21%
Tỷ lệ lỗi lặp lại sau bảo trì	22%	5%





Biểu đồ 2. So sánh hiệu suất vận hành giữa hai phương pháp

2.3.5. Phân tích ảnh lớp in và lỗi bằng CNN


Hệ thống camera chụp ảnh lớp in theo từng lớp (layer). Mỗi ảnh được xử lý bằng CNN để phân loại ba nhóm lỗi chính [14, 15]:

- Rỗ xốp (Porosity): Thiếu nhiệt hoặc phân bố bột không đều;
- Biến dạng (Warping): Do sai lệch nhiệt độ hoặc tốc độ quét;
- Thiếu vật liệu (Lack of Fusion): Do hư hỏng đầu in hoặc tốc độ quá nhanh.

Bảng 3. Phân tích lỗi bằng CNN

Loại lỗi	Mô tả lỗi và nguyên nhân	Giải pháp khắc phục
Rỗ xốp	Các vùng không được nung chảy hoàn toàn dẫn đến lỗ khí. Thường do thiếu năng lượng hoặc phân bố bột không đều.	Tăng công suất laser, cải thiện hệ thống phân phối bột, kiểm tra độ dày lớp phủ.
Biến dạng	Vật thể bị cong vênh do làm nguội không đồng đều hoặc quá nhiệt. Do tốc độ quét không ổn định.	Tối ưu tốc độ quét, điều chỉnh nhiệt độ nền, dùng vật liệu hỗ trợ.
Thiếu vật liệu	Một số vùng không có đủ vật liệu để nung chảy. Nguyên nhân do tắc đầu in hoặc bột bị kẹt.	Vệ sinh và kiểm tra đầu in định kỳ, đảm bảo cấp bột ổn định.

Mô hình CNN được thực nghiệm trên tập dữ liệu ảnh thực tế thu thập từ các ca in khác nhau. Quá trình thực nghiệm sử dụng kỹ thuật tăng cường dữ liệu để cải thiện khả năng tổng quát hóa. Sau khi phân loại, hệ thống đưa ra cảnh báo sớm giúp điều chỉnh quá trình in kịp thời.




Biểu đồ 3. Tỷ lệ từng loại lỗi xuất hiện trên tổng số ảnh kiểm tra ($n = 2000$)

2.3.6. Đánh giá thực nghiệm tại xưởng sản xuất

Trong 30 ngày triển khai thử nghiệm tại xưởng:

- 96 cảnh báo được AI đưa ra → 89 cảnh báo chính xác (True Positive).
- 7 cảnh báo sai → không gây dừng máy, nhưng cần tối ưu mô hình.
- Giảm thiểu 27% số lỗi cần can thiệp khẩn cấp.
- Thời gian vận hành liên tục trung bình tăng từ 13.2 giờ lên 15.3 giờ.



Hình 2. Dashboard hiển thị thời gian thực về cảnh báo và hiệu suất máy

Những kết quả này cho thấy mô hình có tính ứng dụng cao trong môi trường công nghiệp thực tế, góp phần cải thiện tính chủ động trong bảo trì và nâng cao hiệu suất dây chuyền sản xuất.

3. KẾT QUẢ VÀ THẢO LUẬN

Dựa trên kết quả thực nghiệm, mô hình AI đã chứng minh hiệu quả rõ rệt trong việc phát hiện và cảnh báo lỗi trên máy in 3D kim loại. Các mô hình học máy như LSTM, CNN và Random Forest hoạt động ổn định và cho kết

quả khả quan [9, 12]:

- Mô hình LSTM có khả năng phát hiện lỗi theo chuỗi thời gian với độ chính xác cao (91,2%), đặc biệt hiệu quả trong việc nhận diện sự thay đổi bất thường từ cảm biến rung và nhiệt độ.

- CNN cho thấy khả năng nhận diện chính xác các lỗi hình ảnh từ ảnh lớp in, đặc biệt là các lỗi như rỗ xốp và thiếu vật liệu, vốn rất khó phát hiện bằng mắt thường trong quá trình sản xuất liên tục.

- Kết hợp Random Forest đã cải thiện độ chính xác tổng thể khi đánh giá trạng thái máy dựa trên dữ liệu tích hợp.

Việc áp dụng AI không chỉ giúp phát hiện lỗi sớm mà còn giảm đáng kể thời gian dừng máy (trung bình từ 12 giờ xuống còn 4.3 giờ), đồng thời giảm chi phí bảo trì đến 37%. Ngoài ra, nhờ các cảnh báo kịp thời, đội ngũ kỹ thuật có thể chủ động xử lý vấn đề trước khi sự cố lớn xảy ra, góp phần kéo dài tuổi thọ máy móc và nâng cao năng suất vận hành. Bên cạnh đó, hệ thống còn đóng vai trò như một công cụ đào tạo thực tiễn, giúp kỹ thuật viên hiểu rõ nguyên nhân và diễn biến lỗi. Việc lưu trữ và phân tích dữ liệu dài hạn cũng mở ra khả năng tối ưu quy trình sản xuất trong các giai đoạn tiếp theo.

Tuy nhiên, một số thách thức vẫn tồn tại:

- Mô hình phụ thuộc vào chất lượng và độ tin cậy của dữ liệu đầu vào. Nếu cảm biến bị sai lệch, kết quả dự đoán sẽ thiếu chính xác.

- Việc tích hợp hệ thống AI vào quy trình sản xuất hiện tại đòi hỏi đào tạo nhân sự, 

điều chỉnh quy trình và đầu tư cơ sở hạ tầng CNTT.

- Một số cảnh báo sai (false positive) có thể gây gián đoạn nhẹ và cần tinh chỉnh thêm mô hình.

4. KẾT LUẬN

Việc ứng dụng trí tuệ nhân tạo trong bảo trì dự đoán cho máy in 3D kim loại, đặc biệt là công nghệ SLM, mang lại hiệu quả thiết thực cả về mặt kỹ thuật lẫn kinh tế. Thông qua mô hình học máy và hệ thống cảm biến tích hợp, doanh nghiệp có thể:

- Tăng độ chính xác trong phát hiện lỗi sớm;

- Giảm chi phí và thời gian dừng máy không cần thiết;

- Nâng cao hiệu suất và tuổi thọ thiết bị.

Trong tương lai, cần tiếp tục mở rộng nghiên cứu theo hướng học máy thích ứng (adaptive learning), kết hợp thêm dữ liệu âm thanh và dòng điện, đồng thời phát triển giao diện giám sát trực quan thân thiện hơn. Việc hình thành hệ thống AI giám sát tập trung trong các dây chuyền sản xuất thông minh sẽ là xu thế tất yếu trong công nghiệp 4.0.

Ngày nhận bài: **18/3/2025**

Ngày phản biện: **08/4/2025**

Tài liệu tham khảo:

[1]. Nguyen, D. H., Tran, Q. T. (2023), “*Ứng dụng mạng nơ-ron tích chập để phát hiện lỗi trong in 3D kim loại*”. Tạp chí Công nghệ Cơ khí Việt Nam.

- [2]. Lê Minh Hùng (2022), “*Tối ưu hóa quy trình bảo trì máy in 3D trong công nghiệp sản xuất*”. Tạp chí Tự động hóa.
- [3]. Trần Văn Thảo (2020), “*Cảm biến và giám sát trong sản xuất thông minh*”. NXB. Khoa học và Kỹ thuật.
- [4]. Nguyễn Quốc Huy, Phạm Văn Bình (2021), “*Dự đoán sự cố thiết bị bằng mô hình học sâu*”. Tạp chí CNTT & Truyền thông.
- [5]. Phạm Thị Hồng Vân (2023), “*Ứng dụng AI trong phát hiện lỗi sản phẩm công nghiệp*”. Tạp chí Điện tử Việt Nam.
- [6]. Nguyễn Hữu Trí (2022), “*Giám sát rung động trong bảo trì thiết bị công nghiệp*”. Đại học Bách khoa Hà Nội.
- [7]. Trương Thị Ngọc Duyên (2022), “*Tổng quan về công nghệ in 3D kim loại*”. Tạp chí Cơ khí Chế tạo.
- [8]. ISO/ASTM 52900:2021, “*Additive manufacturing*”, General principles.
- [9]. Zhang, Y. et al. (2021), “*Predictive Maintenance for Additive Manufacturing using AI*”. Journal of Manufacturing Systems.
- [10]. Hochreiter, S., & Schmidhuber, J. (1997), “*Long Short-Term Memory*”. Neural Computation.
- [11]. Krizhevsky, A., Sutskever, I., & Hinton, G. (2012), “*ImageNet Classification with Deep Convolutional Neural Networks*”. NIPS.
- [12]. EOS GmbH. (2022), “*EOS M 290 – Industrial 3D Printing of Metals*”, eos.info.
- [13]. Li, Y. et al. (2020), “*Machine Learning in Additive Manufacturing: State-of-the-art and perspectives*”. Additive Manufacturing Journal.
- [14]. Aboulkhair, N. T. et al. (2015), “*Reducing porosity in AlSi10Mg parts processed by selective laser melting*”. Additive Manufacturing.
- [15]. Chen, L. et al. (2021), “*Real-Time Monitoring in Metal Additive Manufacturing using Convolutional Neural Networks*”. IEEE Access.