



DOI:10.22144/ctujos.2026.090

NHẬN DẠNG VÀ ĐỊNH VỊ VỊ TRÍ BẤT THƯỜNG CỦA MỐI HÀN DƯA TRÊN MÔ HÌNH FASTFLOW VÀ PATCHCORE-LITE

Nguyễn Đức Tài¹, Lê Việt Phương², Tô Thanh Tuấn³ và Nguyễn Hoàng Dũng^{1*}

¹Trường Bách Khoa, Đại học Cần Thơ, Việt Nam

²Trường Cao đẳng nghề An Giang, Việt Nam

³Trường Cao đẳng Công nghệ Quốc tế Lilama 2, Việt Nam

*Tác giả liên hệ (Corresponding author): hoangdung@ctu.edu.vn

Thông tin chung (Article Information)

Nhận bài (Received): 10/03/2026

Sửa bài (Revised): 02/04/2026

Duyệt đăng (Accepted): 08/05/2026

Title: Detection and localization of weld anomalies based on FastFlow and Patchcore-Lite models

Author(s): Nguyen Duc Tai¹, Le Viet Phuong², To Thanh Tuan³ and Nguyen Hoang Dung^{1*}

Affiliation(s): ¹College of Engineering, Can Tho University, Viet Nam; ²An Giang Vocational College, Viet Nam; ³Lilama 2 International Technology College, Viet Nam

TÓM TẮT

Mối hàn là vị trí dễ phát sinh hư hỏng trong kết cấu cơ khí, đặc biệt khi bề mặt mối hàn tiếp xúc trực tiếp với môi trường. Việc kiểm tra thủ công với số lượng lớn dễ dẫn đến sai sót. Nghiên cứu này đề xuất phương pháp nhận dạng và định vị bất thường trên ảnh bề mặt mối hàn trong vùng quan tâm (ROI) dựa trên hai mô hình học sâu FastFlow và PatchCore-Lite. Bộ dữ liệu gồm 5.451 ảnh được chuẩn hóa về kích thước 512×512 pixels. Mỗi ảnh có mặt nạ mối hàn (weld mask), trong khi các ảnh bất thường có thêm mặt nạ lỗi (defect mask) làm dữ liệu chuẩn (ground truth). Kết quả thực nghiệm cho thấy PatchCore-Lite đạt hiệu quả tốt hơn ở mức nhận dạng bất thường với AUROC = 0,8978, trong khi FastFlow cho kết quả tốt hơn ở định vị trong ROI với FPR = 0,01875, Dice = 0,04175 và IoU = 0,02161. Nghiên cứu là cơ sở cho việc phát triển các phương pháp kiểm tra tự động lỗi bề mặt mối hàn trong điều kiện dữ liệu lỗi hạn chế.

Từ khóa: Định vị lỗi mối hàn, FastFlow, PatchCore-lite, vùng quan tâm (ROI)

ABSTRACT

Welded joints are among the most failure-prone regions in mechanical structures, particularly as the weld surface is directly exposed to environmental conditions. Manual inspection of large volumes of welds is prone to human error. This study proposes an approach for anomaly detection and localization on weld surface images within regions of interest (ROI) using two deep learning models: FastFlow and PatchCore-Lite. A total of 5,451 images were standardized to a resolution of 512×512 pixels. Each image includes a weld mask, while anomalous samples are additionally annotated with defect masks serving as ground truth. Experimental results indicate that PatchCore-Lite achieves superior performance in anomaly detection at the image level, with an AUROC of 0.8978. In contrast, FastFlow demonstrates better localization performance within the ROI, achieving an FPR of 0.01875, a Dice score of 0.04175, and an IoU of 0.02161. These findings provide a foundation for developing automated weld surface defect inspection systems under conditions of limited defect data, which is a common constraint in industrial applications.

Keywords: FastFlow, PatchCore-lite, Region of Interest (ROI), weld defect localization

1. GIỚI THIỆU

Kiểm tra chất lượng mối hàn là yêu cầu quan trọng trong chế tạo cơ khí và kết cấu hàn, vì các khuyết tật như rỗ khí, nứt, thiếu ngấu hay lẫn xỉ có thể làm giảm độ bền và độ tin cậy của chi tiết. Trong thực tế, các kỹ thuật kiểm tra không phá hủy (NDT: Non-Destructive Testing) vẫn giữ vai trò chủ đạo nhưng thường đòi hỏi thiết bị chuyên dụng, quy trình nghiêm ngặt và chi phí cao. Vì vậy, các giải pháp kiểm tra dựa trên thị giác máy đang được quan tâm nhiều hơn. Một số nghiên cứu gần đây cũng cho thấy thị giác máy tính và học sâu có tiềm năng hỗ trợ phát hiện khuyết tật mối hàn nhanh và ổn định hơn so với kiểm tra thủ công (Dai et al., 2021; Shaloo et al., 2022; Zhang et al., 2025).

Tuy nhiên, kiểm tra ảnh bề mặt mối hàn vẫn gặp nhiều khó khăn. Dữ liệu lỗi thường ít hơn rõ rệt so với dữ liệu bình thường, trong khi hình thái lỗi rất đa dạng. Ảnh mối hàn còn chịu ảnh hưởng của phản xạ kim loại, biến thiên chiếu sáng, nhiễu nền và điều kiện thu nhận ảnh. Ngoài ra, các hướng tiếp cận có giám sát theo kiểu phát hiện hoặc phân đoạn đầy đủ thường cần lượng dữ liệu gán nhãn lớn và đồng đều, điều khó đáp ứng trong môi trường sản xuất. Các khó khăn này đã được phản ánh trong các nghiên cứu về kiểm tra mối hàn bằng ảnh bề mặt và ảnh bức xạ (Hassaballah & Awad, 2020; Wang et al., 2022; Xu et al., 2022; Nguyen et al., 2025;)

Trong bối cảnh đó, phát hiện bất thường theo thiết kế một lớp hoặc không giám sát là hướng tiếp cận phù hợp hơn cho nhiều bài toán lỗi mối hàn, vì mô hình chủ yếu được huấn luyện trên dữ liệu bình thường và nhận biết sai khác ở giai đoạn suy luận. Hướng này đã được nghiên cứu rộng rãi trong thị giác công nghiệp và hỗ trợ đánh giá đồng thời ở mức ảnh và mức pixel (Liu et al., 2017; Bergmann et al., 2021).

Trong số các phương pháp liên quan, FastFlow là đại diện của nhóm mô hình dựa trên luồng, trong khi PatchCore là phương pháp tiêu biểu của hướng khai thác đặc trưng dựa trên phân mảnh ảnh (patch) kết hợp bộ nhớ đại diện cho phát hiện và định vị bất thường trên dữ liệu thị giác công nghiệp (Li et al., 2021; Yu et al., 2021; Zavrtnik et al., 2021; Gudovskiy et al., 2022; Roth et al., 2022; Say & Zidi, 2023).

Mặc dù vậy, phần lớn các công trình trên được xây dựng cho bài toán phát hiện bất thường công nghiệp tổng quát, chưa xử lý đầy đủ đặc thù của

ảnh bề mặt mối hàn trong bối cảnh dữ liệu nội bộ. Với ảnh mối hàn, vùng ngoài đường hàn có thể chứa nền, phản xạ hoặc họa tiết vật liệu không liên quan trực tiếp đến lỗi nhưng vẫn làm lệch bản đồ bất thường (Bergmann et al., 2021). Vì vậy, nghiên cứu này áp dụng quy ước vùng quan tâm ROI (Region of Interest), trong đó các chỉ số đánh giá định vị chỉ được tính trên các pixel thuộc vùng mối hàn trên ảnh, còn các pixel ngoài vùng ROI được loại khỏi quá trình tính toán.

Từ góc nhìn đó, nghiên cứu này không tiếp cận bài toán như một bài phân đoạn có giám sát đầy đủ trên toàn ảnh, mà xem đây là bài toán phát hiện và định vị bất thường trong vùng ROI mối hàn với thiết kế train chỉ trên ảnh đạt yêu cầu (OK), còn val/test có cả ảnh OK và ảnh mối hàn bị lỗi (NG: Not good). Trên cơ sở đó, hai mô hình có tính thực dụng được tập trung đánh giá là FastFlow và PatchCore-Lite. FastFlow phù hợp với nhu cầu tạo bản đồ bất thường liên tục và hỗ trợ định vị, còn PatchCore-Lite là biến thể triển khai nhẹ dựa trên việc phát hiện lỗi mà không cần dữ liệu lỗi khi train (PatchCore), phù hợp với mục tiêu so sánh gọn và có khả năng tái lập (Li et al., 2021; Yu et al., 2021; Roth et al., 2022).

Ngoài lựa chọn mô hình, một vấn đề quan trọng khác là hiệu chỉnh ngưỡng để chuyển bản đồ bất thường liên tục sang mặt nạ nhị phân phục vụ tính các chỉ số như tỉ lệ bỏ sót/dự đoán sai, Pixel-F1 và mức độ trùng lặp giữa dự đoán và ground truth, IoU (Liu et al., 2024; Li et al., 2025). Các nghiên cứu trước cho thấy ngưỡng (threshold) có thể ảnh hưởng đáng kể đến kết luận thực nghiệm, đồng thời việc dùng dữ liệu bất thường ở giai đoạn đánh giá tập huấn luyện (validation) để chọn ngưỡng có thể dẫn đến thiên lệch đánh giá (Bergmann et al., 2021). Vì vậy, bước hiệu chỉnh ngưỡng được xem xét riêng thông qua hai phương án hiệu chỉnh: V0 (chỉ chọn ngưỡng từ ảnh mối hàn đạt yêu cầu) và V1 (chọn ngưỡng có tham chiếu thêm từ ảnh mối hàn bị lỗi).

Từ các phân tích trên, mục tiêu của nghiên cứu là xây dựng và đánh giá việc phát hiện và định vị bất thường trên ảnh bề mặt mối hàn trong vùng ROI của mối hàn. Hai mô hình FastFlow và PatchCore-Lite được lựa chọn để đánh giá khả năng phát hiện lỗi mối hàn. Cụ thể, nghiên cứu hướng tới ba đóng góp chính: (i) chuẩn hóa bài toán theo kịch bản là chỉ huấn luyện dựa trên ảnh OK, trong khi val/test có cả ảnh OK và ảnh NG, kèm vùng ROI mối hàn và mặt nạ lỗi chuẩn cho các ảnh NG; (ii) áp dụng phương thức chỉ đánh giá

vùng ROI nhằm phân ánh chính xác hơn khả năng định vị bất thường trên vùng mỗi hàn và (iii) hiệu chỉnh ngưỡng để có được mức ánh và định vị mức pixel tốt hơn.

2. PHƯƠNG PHÁP NGHIÊN CỨU

2.1. Bộ dữ liệu nghiên cứu

Bộ dữ liệu gồm 5.451 ánh, được chia thành năm tập: tập ánh mẫu mỗi hàn tốt được sử dụng huấn luyện (train_OK, gồm 4.387 ánh), tập ánh mẫu mỗi hàn tốt dùng để kiểm định mô hình (val_OK, gồm 487 ánh), tập ánh mẫu mỗi hàn lỗi dùng để kiểm định/đánh giá mô hình (val_NG, gồm 51 ánh), tập ánh mẫu mỗi hàn tốt dùng để kiểm tra mô hình (test_OK, gồm 320 ánh) và tập ánh mẫu mỗi hàn lỗi dùng để kiểm tra mô hình

(test_NG, gồm 206 ánh). Hình 1(a) minh họa mẫu ánh mỗi hàn tốt/đạt yêu cầu (OK) trong khi Hình 1(b) mô tả mẫu mỗi hàn bị lỗi/khuyết tật bề mặt (NG).

Toàn bộ ánh có kích thước 512×512 pixel và được lưu dưới định dạng PNG. Mỗi ánh đều được gán mặt nạ mỗi hàn (weld mask) để xác định vùng ROI, trong khi các ánh mỗi hàn lỗi/bất thường trong val_NG và test_NG được gán thêm mặt nạ lỗi (defect mask) làm dữ liệu chuẩn (ground truth). Các mặt nạ này được xây dựng thông qua quá trình gán nhãn thủ công bởi hai chuyên gia trong lĩnh vực hàn nhằm bảo đảm độ tin cậy của dữ liệu. Cấu trúc chi tiết của bộ dữ liệu được trình bày trong Bảng 1.

Bảng 1. Bộ dữ liệu sử dụng trong nghiên cứu

Tập dữ liệu	Số ánh	Mặt nạ mỗi hàn	Mặt nạ lỗi	Vai trò
Train_OK	4387	Có	Không	Huấn luyện mô hình trên dữ liệu bình thường Hiệu chỉnh ngưỡng và kiểm soát báo động giả
val_OK	487	Có	Không	
val_NG	51	Có	Có	Hỗ trợ hiệu chỉnh ngưỡng trên dữ liệu có bất thường
test_OK	320	Có	Không	Đánh giá báo động giả trên tập kiểm thử Đánh giá khả năng phát hiện và định vị bất thường
test_NG	206	Có	Có	



a) OK b) NG

Hình 1. Ảnh mỗi hàn tốt/đạt (OK) và mỗi hàn bị lỗi/bất thường (NG)

Cách tổ chức tập dữ liệu này cho phép tách biệt rõ ba vai trò chính: học phân bố bình thường từ train_OK, hiệu chỉnh ngưỡng trên tập xác nhận (validation) và đánh giá cuối trên tập đánh giá (test). Thiết kế đó phù hợp với bản chất của bài toán phát hiện bất thường trong công nghiệp, nơi dữ liệu lỗi thường ít hơn đáng kể so với dữ liệu bình thường.

2.2. Đánh giá dựa trên vùng ROI

Mục tiêu của nghiên cứu này là phát hiện và định vị bất thường của mỗi hàn theo hướng phát hiện bất thường 1 lớp. Cụ thể, mô hình chỉ được huấn luyện trên tập train_OK gồm các ánh bình thường. Ở giai đoạn suy luận, với mỗi ánh đầu vào

X , mô hình sinh ra một điểm bất thường mức ánh $s(X)$ và một bản đồ bất thường mức pixel $A(x, y)$, trong đó giá trị lớn hơn biểu thị mức độ bất thường cao hơn.

Khác với các bài toán phân đoạn có giám sát trên toàn ánh, nghiên cứu này chỉ đánh giá kết quả trong vùng ROI mỗi hàn. Vùng ROI được xác định bởi mặt nạ vùng mỗi hàn $R(x, y)$, còn vùng lỗi thực tế trên các ánh NG được xác định bởi mặt nạ lỗi $G(x, y)$. Do mục tiêu của bài toán là đánh giá khả năng phát hiện lỗi trên chính vùng mỗi hàn, bản đồ bất thường trước hết được giới hạn trong vùng ROI, sau đó mới được nhị phân hóa để tạo mặt nạ dự đoán.

$$A_{ROI}(x, y) = A(x, y) \cdot R(x, y) \quad (1)$$

Trong đó, mặt nạ vùng mỗi hàn ROI được định nghĩa như sau:

$$R(x, y) = \begin{cases} 1, & (x, y) \in \text{ROI} \\ 0, & (x, y) \notin \text{ROI} \end{cases} \quad (2)$$

Sau khi giới hạn bản đồ bất thường trong vùng ROI, mặt nạ dự đoán nhị phân được tạo dựa trên ngưỡng hóa (với ngưỡng τ).

$$P(x, y) = I(A_{ROI}(x, y) \geq \tau) \quad (3)$$

Trong đó, hàm chỉ thị được viết như sau:

$$I(z) = \begin{cases} 1, & z \\ 0, & -z \end{cases} \quad (4)$$

Đối với các ảnh bất thường, ground truth mức pixel cũng được giới hạn trong ROI để bảo đảm tính nhất quán giữa vùng dự đoán và vùng đánh giá.

$$G_{ROI}(x, y) = G(x, y) \cdot R(x, y) \quad (5)$$

Và ảnh đầu vào X được xem là bất thường nếu điểm bất thường mức ảnh vượt ngưỡng quyết định τ_{img} :

$$\hat{y}(X) = I(s(X) \geq \tau_{img}) \quad (6)$$

Với biện luận này, nghiên cứu hiện tại không xem bài toán là phân đoạn có giám sát trên toàn ảnh, mà là phát hiện và định vị bất thường trong vùng ROI mỗi hàn: mô hình được huấn luyện chỉ trên dữ liệu OK và được đánh giá trên cả mức ảnh lẫn mức pixel. Các pixel ngoài vùng ROI không tham gia vào quá trình tính toán chỉ số, nhờ đó kết quả phản ánh khả năng phát hiện lỗi trên vùng mỗi hàn thay vì bị ảnh hưởng bởi nền ngoài vùng hàn.

2.3. Cấu hình huấn luyện và thiết lập thực nghiệm

Hai mô hình FastFlow và PatchCore-Lite được sử dụng trong cùng một thiết lập thực nghiệm nhằm bảo đảm tính nhất quán khi so sánh. Ảnh đầu vào được giữ ở kích thước 512×512 pixel. Cả hai mô hình chỉ được huấn luyện trên tập train_OK; tập xác nhận được dùng để hiệu chỉnh ngưỡng, còn tập đánh giá được dùng để đánh giá cuối cùng. Toàn bộ thí nghiệm được thực hiện trên Google Colab với GPU NVIDIA L4, RAM 230 GB và bộ nhớ GPU 79,6 GB.

2.4. Quy trình và các bước thực hiện thí nghiệm

Quy trình thực nghiệm được thiết kế thống nhất cho cả hai mô hình FastFlow và PatchCore-Lite nhằm bảo đảm tính công bằng trong so sánh. Trước hết, dữ liệu được kiểm tra về tính đầy đủ và tính nhất quán giữa ảnh đầu vào, mặt nạ vùng mỗi hàn và mặt nạ lỗi theo từng tập dữ liệu. Sau đó, mô hình được huấn luyện chỉ trên tập train_OK để học biểu diễn dữ liệu bình thường. Ở giai đoạn đánh giá, mô hình được áp dụng trên val_OK và nếu cần, val_NG cũng được áp dụng để hiệu chỉnh ngưỡng theo phương án đã chọn. Cuối cùng, mô hình và ngưỡng tương ứng được sử dụng để suy luận trên test_OK và test_NG nhằm tạo điểm bất

thường mức ảnh, mặt nạ dự đoán trong vùng ROI và các chỉ số đánh giá tương ứng.

Quy trình thực hiện thí nghiệm gồm năm bước chính. Bước thứ nhất là chuẩn bị và kiểm tra dữ liệu, bao gồm kiểm tra cấu trúc dữ liệu, số lượng ảnh, sự tương ứng giữa ảnh và các mặt nạ, cũng như tính hợp lệ của các tập huấn luyện, xác nhận (validation) và đánh giá (test). Bước thứ hai là huấn luyện mô hình trên tập huấn luyện train_OK. Bước thứ ba là hiệu chỉnh ngưỡng trên tập xác nhận để chuyển bản đồ bất thường liên tục thành mặt nạ dự đoán nhị phân trong vùng ROI. Bước thứ tư là đánh giá trên tập đánh giá, trong đó mô hình sinh điểm bất thường, bản đồ bất thường và mặt nạ dự đoán cho các tập ảnh test_OK và test_NG. Bước cuối cùng là tổng hợp kết quả, bao gồm tính toán các chỉ số vùng ROI mỗi hàn và xây dựng các kết quả trực quan phục vụ so sánh giữa các mô hình.

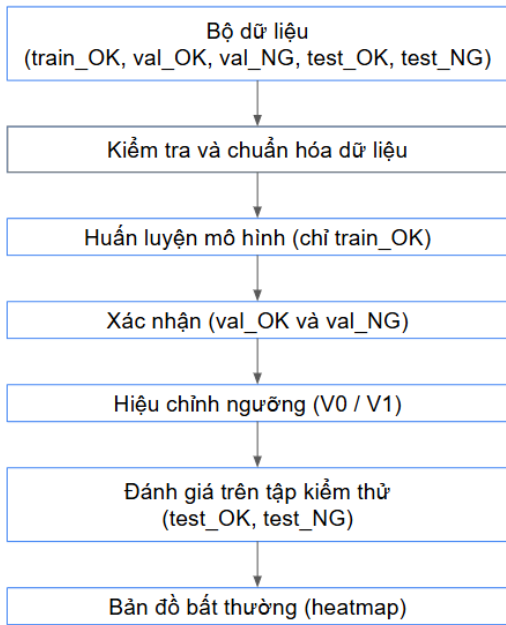
Quy trình thực nghiệm (xem Hình 2) gồm: (1) kiểm tra và chuẩn hóa dữ liệu đầu vào; (2) huấn luyện mô hình trên tập ảnh train_OK; (3) hiệu chỉnh ngưỡng trên tập xác nhận; (4) đánh giá trên tập đánh giá test_OK và test_NG và (5) tổng hợp kết quả định lượng và trực quan.

2.5. Mô hình huấn luyện

2.5.1. Mô hình FastFlow

FastFlow là một phương pháp phát hiện bất thường dựa trên chuẩn hóa luồng, trong đó đặc trưng ảnh được ánh xạ qua các phép biến đổi khả nghịch để ước lượng phân bố của dữ liệu bình thường. Trên cơ sở đó, mô hình có thể sinh bản đồ bất thường ở mức pixel, đồng thời hỗ trợ cả phát hiện bất thường ở mức ảnh và định vị bất thường theo không gian. Hướng tiếp cận này thuộc nhóm mô hình ước lượng phân bố đặc trưng, vốn là một nhánh quan trọng trong phát hiện bất thường công nghiệp hiện nay.

Trong nghiên cứu này, FastFlow được lựa chọn vì phù hợp với mục tiêu định vị bất thường trong vùng ROI mỗi hàn. So với các hướng chỉ nhấn mạnh phát hiện ở mức ảnh, các mô hình dựa trên luồng thường thuận lợi hơn khi cần xây dựng bản đồ bất thường liên tục để phục vụ định vị. Các nghiên cứu liên quan cho thấy nhóm phương pháp này có hiệu quả tốt trong bối cảnh phát hiện bất thường không giám sát, đặc biệt khi dữ liệu lỗi không xuất hiện ở pha huấn luyện (Yu et al., 2021).



Hình 2. Lưu đồ quy trình thực thi mô hình học sâu FastFlow và PatchCore-Lite

Trong phạm vi nghiên cứu này, FastFlow được sử dụng như một mô hình đối sánh cơ sở đại diện cho hướng dựa trên luồng. Mô hình được triển khai trên cùng tập train_OK, cùng kích thước đầu vào và cùng quy trình hiệu chỉnh ngưỡng như mô hình đối sánh còn lại để bảo đảm tính nhất quán trong thực nghiệm.

2.5.2. Mô hình PatchCore-Lite

PatchCore là một phương pháp tiêu biểu của hướng phát hiện bất thường dựa trên đặc trưng cục bộ theo mảnh và bộ nhớ đại diện. Ý tưởng chính của phương pháp là trích xuất đặc trưng từ ảnh bình thường, lưu một tập đại diện của các mảnh đặc trưng vào bộ nhớ, rồi ở pha suy luận đo mức bất thường thông qua khoảng cách từ đặc trưng của ảnh kiểm tra đến bộ nhớ này. Theo nghiên cứu gốc, PatchCore cho kết quả mạnh ở cả phát hiện mức ảnh và định vị mức pixel trên các điểm chuẩn công nghiệp (Roth et al., 2022).

Trong nghiên cứu này, PatchCore-Lite được sử dụng như một biến thể triển khai nhẹ dựa trên tinh thần của PatchCore. Việc rút gọn bộ nhớ đại diện và điều chỉnh cách triển khai giúp mô hình phù hợp hơn với điều kiện tính toán của thí nghiệm, đồng thời vẫn giữ được nguyên lý phát hiện bất thường dựa trên độ sai khác cục bộ. Cách lựa chọn này cũng phù hợp với xu hướng chung của lĩnh vực nghiên cứu (Roth et al., 2022).

Trong bài toán này, PatchCore-Lite được chọn để đối sánh trực tiếp với FastFlow nhằm làm rõ khác biệt giữa hai hướng tiếp cận: một bên là ước lượng phân bố đặc trưng bằng mô hình dựa trên luồng, bên còn lại là đo sai khác cục bộ bằng truy hồi đặc trưng theo mảnh. Sự đối sánh này phù hợp với ảnh bề mặt mới hàn trong vùng ROI, nơi cần xem xét đồng thời khả năng phát hiện mức ảnh và khả năng định vị mức pixel.

Trên cơ sở hai mô hình nêu trên, nghiên cứu tiếp tục xem xét phương án hiệu chỉnh ngưỡng để chuyển bản đồ bất thường liên tục thành mặt nạ dự đoán nhị phân trong vùng ROI. Đây là bước ảnh hưởng trực tiếp đến các chỉ số định lượng mức pixel và cần được tách riêng trong thiết kế thực nghiệm.

2.6. Điều chỉnh ngưỡng

Hiệu chỉnh ngưỡng là bước chuyển bản đồ bất thường liên tục thành mặt nạ dự báo (predicted mask) nhị phân trong vùng ROI mỗi hàn. Trong nghiên cứu này, ngưỡng mức pixel τ được dùng để tạo mặt nạ dự báo từ bản đồ bất thường đã giới hạn trong vùng ROI. Bước này có ảnh hưởng trực tiếp đến các chỉ số định vị như tỉ lệ bỏ sót/dự đoán sai ở mức pixel (Pixel-F1), mức độ chồng lấp giữa vùng dự đoán và ground truth (IoU) và tỉ lệ dự đoán sai trên tổng số mẫu mỗi hàn bị lỗi (FP-rate), nên được tách riêng như một thành phần của thiết kế thực nghiệm.

Nghiên cứu này xem xét hai phương án hiệu chỉnh ngưỡng là V0 và V1. Với V0, ngưỡng τ chỉ được chọn từ tập val_OK. Cách làm này phù hợp với tinh thần phát hiện bất thường 1 lớp, vì bước cân chỉnh (calibration) không sử dụng thông tin từ ảnh mỗi hàn lỗi. Do đó, V0 phản ánh chặt chẽ hơn kịch bản triển khai khi dữ liệu NG không sẵn có hoặc rất hạn chế.

$$\tau_{V0} = \text{Threshold}(A_{ROI}(x, y) | X \in \text{val_OK}) \quad (7)$$

Với V1, ngưỡng τ được hiệu chỉnh với sự tham chiếu của cả 2 tập val_OK và val_NG. Cách tiếp cận này thực dụng hơn khi hệ thống có sẵn một lượng nhỏ dữ liệu NG để tinh chỉnh sau huấn luyện. Khi đó, ngưỡng có thể được chọn theo hướng cân bằng tốt hơn giữa khả năng bắt lỗi trong vùng ROI và mức báo động giả trên ảnh OK.

$$\tau_{V1} = \text{Threshold}(\text{val_OK}, \text{val_NG}) \quad (8)$$

Trong nghiên cứu này, V0 và V1 không được xem là hai cấu hình thay thế lẫn nhau và được sử dụng để phân tích sự đánh đổi giữa tính chặt chẽ

của phương pháp và tính thực dụng trong thiết lập thực nghiệm. Cụ thể, V0 sử dụng tập val_OK để hiệu chỉnh ngưỡng, trong khi V1 sử dụng val_OK kết hợp với val_NG.

2.7. Đánh giá hiệu quả mô hình

Để đánh giá mô hình một cách nhất quán dựa trên quy ước vùng ROI mỗi hàn, các chỉ số ở mức pixel được sử dụng như mặt nạ dự đoán được so sánh với mặt nạ lỗi chuẩn (ground truth) trong vùng ROI để xác định các đại lượng cơ bản gồm: TP (True Positive) là số pixel lỗi được dự đoán đúng là lỗi; FP (False Positive) là số pixel bình thường nhưng bị dự đoán nhầm là lỗi; và FN (False Negative) là số pixel lỗi nhưng không được mô hình phát hiện. Các đại lượng này là cơ sở để tính các chỉ số đánh giá chất lượng mô hình như Precision (Tỉ lệ mô hình dự đoán đúng so với kết quả dự đoán), Recall (Tỉ lệ mô hình dự đoán đúng so với kết quả thực tế), Dice (Mức độ trùng khớp giữa dự đoán và ground truth) và IoU. Trên cơ sở đó, hai chỉ số chính được sử dụng là Pixel-F1 và IoU trong vùng ROI. Trong đó, Pixel-F1 phản ánh sự cân bằng giữa Precision và Recall, còn IoU đo mức chồng lấp giữa vùng lỗi dự đoán và vùng lỗi thực tế. Đối với các ảnh bình thường, FP-rate trong vùng ROI được tính toán để phản ánh tỉ lệ báo động giả (FPR: False positive rate) trên vùng mỗi hàn.

Trước hết, các đại lượng TP, FP và FN trong vùng ROI được xác định như sau:

$$TP = \sum_{x,y} P(x,y).G_{ROI}(x,y) \quad (9)$$

$$FP = \sum_{x,y} P(x,y).(1 - G_{ROI}(x,y)R(x,y)) \quad (10)$$

$$FN = \sum_{x,y} (1 - P(x,y)).G_{ROI}(x,y) \quad (11)$$

Từ đó, giá trị Precision và Recall được tính như sau:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (12)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (13)$$

Chỉ số Pixel-F1 trong vùng ROI được xác định như sau:

$$F1_{ROI} = \frac{2.Precision.Recall}{Precision+Recall} \quad (14)$$

Trong khi đó, IoU trong vùng ROI được tính theo công thức:

$$IoU_{ROI} = \frac{TP}{TP + FP + FN} \quad (15)$$

Đối với các ảnh của mỗi hàn tốt/đạt OK, tỷ lệ báo động giả trong vùng ROI được tính như sau:

$$FP_{ROI\text{rate}} = \frac{\sum_{x,y} P(x,y).R(x,y)}{\sum_{x,y} R(x,y)} \quad (16)$$

Bên cạnh các chỉ số định lượng, kết quả thực nghiệm còn được tổ chức theo cách cho phép đối chiếu nhất quán giữa các mô hình. Các đầu ra chính của mỗi thí nghiệm bao gồm cấu hình thực nghiệm, các chỉ số tổng hợp, bản đồ nhiệt và các ảnh chồng lấp được minh họa. Đồng thời, một tập mẫu cố định được sử dụng trong toàn bộ quá trình so sánh trực quan nhằm bảo đảm rằng các mô hình được đối chiếu trên cùng một cơ sở. Ngoài ra, các bảng minh họa ground truth cũng được xây dựng để kiểm tra sự tương ứng giữa ảnh đầu vào, vùng ROI mỗi hàn và mặt nạ lỗi. Cách tổ chức này giúp việc so sánh giữa FastFlow và PatchCore-Lite không chỉ dựa trên số liệu định lượng mà còn được hỗ trợ bởi đối chiếu trực quan nhất quán.


3. KẾT QUẢ VÀ THẢO LUẬN

3.1. Đánh giá chất lượng mô hình

Kết quả thực nghiệm được tổng hợp theo bốn chỉ số chính gồm: (1) khả năng mô hình phân biệt được giữa ảnh bình thường và bất thường AUROC (Area under receiver operating characteristic), (2) Dice, (3) IoU và (4) FPR. Trong đó, AUROC phản ánh khả năng nhận dạng bất thường ở mức ảnh; Dice và IoU phản ánh chất lượng định vị bất thường ở mức pixel; còn FPR phản ánh tỉ lệ báo động giả trên các mẫu bình thường. Cách tổng hợp này phù hợp với thiết kế đánh giá đã trình bày ở Mục 2.7.

Bảng 2. Kết quả định lượng của FastFlow và PatchCore-Lite

Mô hình	AUROC	Dice	IoU	FPR
PatchCore-lite	0,8978	0,00109	0,00057	0,0875
FastFlow	0,6612	0,04175	0,02161	0,01875



a) *FastFlow* b) *PatchCore-Lite*
Hình 3. So sánh trực quan kết quả định vị của FastFlow và PatchCore-Lite trên các mẫu kiểm thử

Quan sát trực quan trong Hình 3 cho thấy sự khác biệt rõ rệt giữa hai cách biểu diễn bản đồ bất thường của hai mô hình. PatchCore-Lite tạo ra các vùng bất thường có cường độ màu cao (màu cam-đỏ) tập trung tại khu vực khuyết tật trên bề mặt mỗi hàn, giúp người quan sát dễ nhận biết vị trí lỗi. Trong khi đó, bản đồ bất thường của FastFlow có xu hướng xuất hiện dưới dạng các điểm sáng nhỏ phân bố rải rác trong vùng ROI, tạo nên cấu trúc dạng nhiễu điểm (speckle) thay vì các vùng bất thường liên tục.

Kết quả định lượng trong Bảng 2 cho thấy hai mô hình có xu hướng tối ưu khác nhau theo từng mục tiêu đánh giá. Cụ thể, PatchCore-Lite đạt giá trị AUROC cao hơn rõ rệt. Ngược lại, FastFlow cho kết quả tốt hơn ở các chỉ số định vị trong vùng ROI mỗi hàn. Nói tóm lại, hai mô hình thể hiện hai đặc trưng khác nhau trong cùng bài toán. PatchCore-lite có xu hướng tạo ra các vùng bất thường rõ ràng hơn ở mức ảnh, phù hợp cho nhận dạng bất thường tổng thể, trong khi FastFlow cho khả năng định vị ổn định hơn trong vùng ROI và hạn chế tốt hơn các dự đoán sai trên các vùng không có lỗi.

3.2. So sánh mô hình FastFlow và PatchCore-lite

Kết quả được trình bày ở Bảng 2 so sánh chất lượng của hai mô hình FastFlow và PatchCore-Lite. Ở mức phát hiện bất thường trên toàn ảnh, PatchCore-Lite có chỉ số AUROC = 0,8978 cao hơn

đáng kể so với 0,6612 của FastFlow. Kết quả này cho thấy PatchCore-Lite có khả năng phân tách giữa ảnh bình thường và ảnh bất thường tốt hơn FastFlow. Ngược lại, ở mức định vị bất thường trong vùng ROI mỗi hàn, FastFlow đạt kết quả tốt hơn theo các chỉ số đánh giá (chỉ số Dice của FastFlow đạt 0,04175 so với 0,00109 của PatchCore-Lite; IoU của FastFlow là 0,02161 cao hơn so với PatchCore-Lite là 0,00057). Hơn nữa, mô hình FastFlow có tỷ lệ báo động giả FPR = 0,01875 thấp hơn so với 0,0875 của PatchCore-Lite. Điều này chứng tỏ FastFlow khả năng kiểm soát các dự đoán sai trên vùng không lỗi tốt hơn PatchCore-Lite. Mặc dù mô hình FastFlow có thể định vị lỗi bất thường nhưng các giá trị Dice và IoU thì khá thấp. Điều này chứng tỏ việc định vị bất thường trên ảnh mỗi hàn là khó và các vùng lỗi dự đoán còn chưa trùng khớp tốt với vùng lỗi thực tế. Nguyên nhân các chỉ số này thấp là do sự đa dạng hình thái lỗi (ví dụ như nứt, lẫn xỉ, cháy xém, lệch biên dạng, rỗ khí,...), kích thước các lỗi nhỏ và ảnh hưởng của nhiễu nền trong vùng ROI.

4. KẾT LUẬN

Một giải pháp nhận dạng và định vị sự bất thường trên ảnh bề mặt mỗi hàn trong vùng ROI sử dụng mô hình học sâu FastFlow và PatchCore-Lite được trình bày trong nghiên cứu. Kết quả thực nghiệm cho thấy PatchCore-Lite đạt hiệu quả tốt hơn trong phát hiện bất thường ở mức ảnh với AUROC đạt 0,8978, trong khi FastFlow cho kết quả tốt hơn ở định vị trong vùng ROI và kiểm soát báo động giả, với Dice = 0,04175, IoU = 0,02161 và FPR = 0,01875.

Kết quả trên cho thấy hai mô hình này có thể được sử dụng để hỗ trợ cho nhau trong hệ thống kiểm tra mỗi hàn tự động: PatchCore-Lite phù hợp cho bước sàng lọc ban đầu ở mức ảnh, trong khi FastFlow hỗ trợ xác định vị trí lỗi trong vùng ROI của mỗi hàn. Điều này góp phần giảm khối lượng kiểm tra thủ công và nâng cao độ tin cậy của quá trình kiểm tra.

Trong nghiên cứu tiếp theo, hai mô hình trên được tích hợp trong một pipeline. Đồng thời, giải pháp này được đánh giá trên nhiều loại dữ liệu mỗi hàn khác nhau. Từ đó tìm ra được các tham số tối ưu của các mô hình để hướng đến tích hợp chúng trong hệ thống nhận dạng và định vị lỗi mỗi hàn một cách tự động trong công nghiệp.

TÀI LIỆU THAM KHẢO

- Bergmann, P., Batzner, K., Fauser, M., Sattlegger, D., & Steger, C. (2021). The MVTEC Anomaly Detection Dataset: A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection. *International Journal of Computer Vision*, 129(4), 1038–1059. <https://doi.org/10.1007/s11263-020-01400-4>
- Dai, W., Li, D., Tang, D., Jiang, Q., Wang, D., Wang, H., & Peng, Y. (2021). Deep learning assisted vision inspection of resistance spot welds. *Journal of Manufacturing Processes*, 62, 262–274. <https://doi.org/10.1016/j.jmapro.2020.12.015>
- Gudovskiy, D., Ishizaka, S., & Kozuka, K. (2022). CFLOW-AD: Real-Time Unsupervised Anomaly Detection with Localization via Conditional Normalizing Flows. *2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)* (pp. 1819–1828). <https://doi.org/10.1109/WACV51458.2022.00188>
- Hassaballah, M., & Awad, A. I. (2020). *Deep Learning in Computer Vision: Principles and Applications* (M. Hassaballah & A. I. Awad, B.t.v; 1st a.b). CRC Press. <https://doi.org/10.1201/9781351003827>
- Li, C.-L., Sohn, K., Yoon, J., & Pfister, T. (2021). CutPaste: Self-Supervised Learning for Anomaly Detection and Localization. *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 9659–9669). <https://doi.org/10.1109/CVPR46437.2021.00954>
- Li, Z., Yan, Y., Wang, X., Ge, Y., & Meng, L. (2025). A survey of deep learning for industrial visual anomaly detection. *Artificial Intelligence Review*, 58(9), 279. <https://doi.org/10.1007/s10462-025-11287-7>
- Liu, J., Fan, Z., Olsen, S. I., Christensen, K. H., & Kristensen, J. K. (2017). Boosting Active Contours for Weld Pool Visual Tracking in Automatic Arc Welding. *IEEE Transactions on Automation Science and Engineering*, 14(2), 1096–1108. <https://doi.org/10.1109/TASE.2015.2498929>
- Liu, J., Xie, G., Wang, J., Li, S., Wang, C., Zheng, F., & Jin, Y. (2024). Deep Industrial Image Anomaly Detection: A Survey. *Machine Intelligence Research*, 21(1), 104–135. <https://doi.org/10.1007/s11633-023-1459-z>
- Nguyen, D. T., Le, V. P., To, T. T., & Nguyen, H. D. (2025). Weld detection and segmentation using improved deep learning approach. Trong N. T. Hai, N. H. Q. Thinh, N. H. Loc, & L. C. Hiep (B.t.v), *2nd EAI International Conference on Renewable Energy and Sustainable Manufacturing* (pp. 623–635). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-90629-9_39
- Roth, K., Pemula, L., Zepeda, J., Scholkopf, B., Brox, T., & Gehler, P. (2022). Towards Total Recall in Industrial Anomaly Detection. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 14298–14308). <https://doi.org/10.1109/CVPR52688.2022.01392>
- Say, D., & Zidi, S. (2023). Application of a new multi-binary classification strategy in the Weld Defects Images. *2023 IEEE International Workshop on Mechatronic Systems Supervision (IW_MSS)* (pp. 1–6). https://doi.org/10.1109/IW_MSS59200.2023.10368597
- Shaloo, M., Schnall, M., Klein, T., Huber, N., & Reitingner, B. (2022). A Review of Non-Destructive Testing (NDT) Techniques for Defect Detection: Application to Fusion Welding and Future Wire Arc Additive Manufacturing Processes. *Materials*, 15(10), 3697. <https://doi.org/10.3390/ma15103697>
- Wang, X., Zhang, Y., Liu, J., Luo, Z., Zielinska, T., & Ge, W. (2022). Online detection of weld surface defects based on improved incremental learning approach. *Expert Systems with Applications*, 195, 116407. <https://doi.org/10.1016/j.eswa.2021.116407>
- Xu, H., Yan, Z. H., Ji, B. W., Huang, P. F., Cheng, J. P., & Wu, X. D. (2022). Defect detection in welding radiographic images based on semantic segmentation methods. *Measurement*, 188, 110569. <https://doi.org/10.1016/j.measurement.2021.110569>
- Yu, J., Zheng, Y., Wang, X., Li, W., Wu, Y., Zhao, R., & Wu, L. (2021). *FastFlow: Unsupervised Anomaly Detection and Localization via 2D Normalizing Flows* (Version 2). arXiv. <https://doi.org/10.48550/ARXIV.2111.07677>
- Zavrtanik, V., Kristan, M., & Skocaj, D. (2021). DRÆM – A discriminatively trained reconstruction embedding for surface anomaly detection. *2021 IEEE/CVF International Conference on Computer Vision (ICCV)* (pp. 8310–8319). <https://doi.org/10.1109/ICCV48922.2021.00822>
- Zhang, M., Feng, M., Chen, C., Yu, X., & Lian, G. (2025). Weld Defect Detection: Deep Learning-Based Image Processing and the Mechanisms of Defect Formation. *Archives of Computational Methods in Engineering*, 33, 3525–3563. <https://doi.org/10.1007/s11831-025-10407-4>