



DOI:10.22144/ctujos.2023.231

ỨNG DỤNG MẠNG HỌC SÂU VÀ XỬ LÝ ẢNH TRONG XÁC ĐỊNH CÁC CẤP ĐỘ NHÁM BỀ MẶT GIA CÔNG KIM LOẠI

Trần Hữu Phát¹ và Nguyễn Chí Ngôn^{2*}

¹Học viên Cao học Khóa 28, Ngành Kỹ thuật điều khiển & Tự động hoá, Trường Bách Khoa, Đại học Cần Thơ

²Khoa Tự động hoá, Trường Bách Khoa, Đại học Cần Thơ

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

Thông tin chung (Article Information)

Nhận bài (Received): 09/08/2023

Sửa bài (Revised): 05/09/2023

Duyệt đăng (Accepted): 20/09/2023

Title: Application of deep learning and image processing in determining metal surface roughness levels

Author(s): Tran Huu Phat and Nguyen Chi Ngon*

Affiliation(s): Can Tho University

TÓM TẮT

Trong ngành cơ khí chế tạo, độ nhám bề mặt sau gia công là một trong những yêu cầu kỹ thuật quan trọng. Việc đánh giá phải được thực hiện trên hệ thống thiết bị đầu dò phức tạp bởi các kỹ thuật viên, thực tế đó dẫn đến một số khó khăn trong quy trình đánh giá. Trong nghiên cứu này, mạng nơ ron tích chập AlexNet được đề xuất sử dụng để tự động hóa việc nhận dạng và phân tích độ nhám bề mặt. Đầu tiên, dữ liệu hình ảnh bề mặt kim loại được thu thập với độ nhám đã được đánh giá và gán sẵn giá trị Ra trong khoảng 0,4-3,2 μm . Tiếp theo, AlexNet sẽ được huấn luyện trên bộ dữ liệu này để học cách nhận biết các cấp độ nhám khác nhau. Kết quả thực nghiệm với độ chính xác 89,2% đã cho thấy mô hình AlexNet đạt được hiệu suất nhận dạng độ nhám đáng kể. Nghiên cứu đã chứng minh tính khả thi và hiệu quả của việc ứng dụng mạng nơ ron tích chập vào tự động hóa quy trình đánh giá chất lượng bề mặt gia công.

Từ khóa: AlexNet, cấu trúc bề mặt, độ nhám, mạng nơ ron tích chập, xử lý ảnh

ABSTRACT

In the mechanical manufacturing industry, surface roughness after machining is one of the crucial technical requirements. The evaluation has traditionally been carried out on complex probing systems by technicians, which has led to some difficulties in the assessment process. In this study, we propose the use of the convolutional neural network AlexNet to automate the identification and analysis of surface roughness. First, we collected images of metal surfaces with pre-evaluated roughness values Ra ranging from 0.4 to 3.2 μm . Next, AlexNet was trained on this dataset to learn to recognize different levels of roughness. Experimental results with an accuracy of 89.2% have demonstrated that the AlexNet model achieved significant roughness identification performance. The research has proven the feasibility and effectiveness of applying convolutional neural networks to automate the surface quality assessment process.

Keywords: AlexNet, convolutional neural networks, image processing, roughness, texture

1. GIỚI THIỆU

1.1. Cơ sở phân chia và sự khác nhau giữa các cấp độ nhám của hệ thống

Độ nhám bề mặt là một yếu tố kỹ thuật quan trọng trong các thiết kế cơ khí. Những chi tiết nằm trong các mối ghép động như ổ trượt, sống dẫn, con trượt, trục máy, xy lanh-piston có bề mặt trượt liên tục. Độ nhám càng lớn, việc tạo màng dầu bôi trơn giữa các bề mặt càng khó khăn. Dưới tác động của tải trọng, các đỉnh nhám tiếp xúc với nhau gây ra ma sát nửa ướt hoặc khô, làm giảm hiệu suất và tăng nhiệt độ làm việc của mối ghép. Ứng suất lớn tại các điểm tiếp xúc dẫn đến mòn và biến dạng chảy phá hỏng bề mặt. Ngược lại, độ nhám nhỏ (độ bóng cao) giúp bề mặt mịn hơn và chống mòn tốt hơn.

Phương pháp đánh giá độ nhám đơn giản nhất là so sánh với các căn mẫu, nhưng không đem lại độ chính xác cao, do phụ thuộc vào kinh nghiệm của người thực hiện. Phương pháp phổ biến hiện nay là sử dụng các loại máy đầu dò tiếp xúc trực tiếp với bề mặt để đo độ gồ ghề, sau đó chuyển đổi thành giá trị độ nhám (thường là Ra hoặc Rz) như Hình 1. Hệ thống máy phân tích độ nhám chính xác có giá thành cao, đòi hỏi môi trường bảo quản, vận hành trong điều kiện phòng thí nghiệm, việc thiết đặt và hiệu chỉnh định kỳ cũng đầy thử thách. Ngoài ra, đầu dò chống mòn sau thời gian sử dụng với tần suất liên tục cũng là vấn đề cần được chú ý.



Hình 1. Giá trị độ nhám được trích xuất từ profile bề mặt của chi tiết máy

Trong phạm vi nghiên cứu này, việc lựa chọn và phân chia cấp độ nhám dựa trên các tiêu chuẩn đánh giá cũng như các yêu cầu tiêu chuẩn kỹ thuật về bề mặt được thống nhất áp dụng phổ biến trong thực tế. Các cấp độ nhám cụ thể được chọn trong khoảng Ra 0,4-3,2 μm , gồm có: Ra 0,4 μm , Ra 0,8 μm , Ra 1,6 μm và Ra 3,2 μm . Sự khác biệt giữa các cấp độ nhám được chọn làm mốc được trình bày rõ ở nội dung tiếp theo.

Độ nhám Ra 3,2 μm : Đây là bề mặt chuẩn của máy thương mại. Nó phù hợp cho hầu hết các bộ phận tiêu dùng và đủ mịn, nhưng chứa các vết cắt rõ ràng. Đây là bề mặt mặc định được áp dụng trừ khi có chỉ định khác. Độ nhám Ra 3,2 μm là chỉ số đề xuất về độ nhám bề mặt tối đa cho các bộ phận chịu tải, lực và rung động. Nó cũng có thể được sử dụng cho các bề mặt chuyển động đối xứng khi tải nhẹ và chuyển động chậm. Để đạt được độ nhám này, việc gia công sử dụng tốc độ cao, đồng thời cắt mỏng và cắt nhẹ.

Độ nhám Ra 1,6 μm : Thông thường với tùy chọn này, chỉ có các vết cắt khá rõ ràng. Độ nhám Ra 1,6 μm được đề xuất cho các bộ phận kẹp chặt và chịu lực, đủ cho các bề mặt di chuyển chậm và chịu tải nhẹ. Tuy nhiên, nó không phù hợp cho các bộ phận quay nhanh và chịu rung mạnh. Để đạt được độ nhám bề mặt này, việc gia công sử dụng tốc độ cao, đồng thời cắt mỏng và cắt nhẹ dưới điều kiện kiểm soát.

Độ nhám Ra 0,8 μm được xem như là một lựa chọn bề mặt cấp cao, độ nhám này yêu cầu kiểm soát rất chặt chẽ để đạt được và giá thành gia công sẽ cao hơn. Nó được yêu cầu cho các bộ phận chịu tập trung lực. Khi chuyển động xảy ra thỉnh thoảng và tải nhẹ, nó có thể được sử dụng cho các vòng bi.

Độ nhám Ra 0,4 μm : Đây là độ nhám có chất lượng bề mặt rất cao. Nó phù hợp cho các bộ phận chịu áp lực hoặc tải lực cao. Nó cũng được yêu cầu cho các bộ phận quay nhanh như vòng bi và trục. Độ nhám bề mặt này đòi hỏi sự cố gắng nhất định trong gia công và chỉ nên được chỉ định khi độ mịn bề mặt là quan trọng hàng đầu.

1.2. Tổng quan tình hình nghiên cứu

Các nghiên cứu ứng dụng mạng nơ ron tích chập (CNN – Convolutional Neural Networks) vào việc nhận dạng và phân loại đối tượng trong hình ảnh 2D, đặc biệt là các cấu trúc bề mặt (texture) tự nhiên hoặc nhân tạo, đã tạo tiền đề cho một phương pháp đánh giá không tiếp xúc đối với độ nhám bề mặt kim loại gia công.

Roberti et al. (2013) đã sử dụng ma trận GLCM (Gray Level Co-occurrence Matrices) và bộ lọc Gauss để tạo tầng kim tự tháp, áp dụng bộ mô tả đa thang và đạt độ chính xác trung bình là 81,7% trên tập UIUC và 87,2% trên tập dữ liệu Brodatz với giải thuật phân lớp KNN (K-Nearest Neighbors). Trong khi đó, Zhang et al. (2013) sử dụng phương pháp thống kê cục bộ và mã hoá N-Ray để tạo vector đặc trưng từ ảnh. Kết quả: 81,9% độ chính xác trên tập

Outex Tc10 và 81,8% trên tập dữ liệu UIUC (University of Illinois Urbana Champaign).

Cimpoli et al. (2015) đã kết hợp FV (Fisher Vector) với mô hình CNN dùng kiến trúc Alex-Net để nhận dạng texture, thực nghiệm trên tập dữ liệu CURET đạt độ chính xác trung bình là 98,4% và 99,1% đối với tập dữ liệu UIUC.

Du et al. (2016) đề xuất phương pháp Local Sensitive Pooling (LSP) với mạng nơ ron 2 chiều để phân loại hình ảnh kết cấu trong các điều kiện khác nhau. Độ chính xác trung bình đạt 86,12% trên tập Outex TC 10. Trong khi Nguyen et al. (2016) đề xuất phương pháp Statistical Binary Patterns (SBP), một phương pháp thống kê mẫu nhị phân cục bộ. Kết quả thực nghiệm trên tập dữ liệu CURET và UIUC đạt độ chính xác trung bình lần lượt là 90,8% và 93,74%.

Nghiên cứu của Al-Kadi (2017) theo phương pháp xử lý tín hiệu, tác giả sử dụng bộ lọc Gabor để phân loại kết cấu ảnh chụp trong các ảnh X - quang y tế để phát hiện bệnh ung thư và các bệnh liên quan khác. Kết quả đạt độ chính xác trung bình là 89,38%. Bên cạnh đó, Nguyen et al. (2017) sử dụng phương pháp kết hợp đặc trưng trích chọn từ Completed Local Binary Pattern (CLBP) và ScatNet để phân lớp ảnh bề mặt vật liệu, thực nghiệm trên nhiều tập dữ liệu khác nhau và thu được độ chính xác trung bình là 99,5% trên tập dữ liệu CURET và 99,4% trên tập dữ liệu OUTEX.

Ứng dụng CNN đánh giá chất lượng bề mặt gia công kim loại vẫn còn khá mới, bước đầu chỉ nhận được sự quan tâm từ một số nhà khoa học, chuyên gia trong ngành công nghệ vật liệu và chế tạo. Các nghiên cứu mới này tập trung vào sử dụng các mô hình học máy và mạng nơ ron tích chập để tự động phân loại và đánh giá cấu trúc, độ nhám bề mặt kim loại, thay vì sử dụng phương pháp tiếp xúc vật lý truyền thống. Việc sử dụng mạng nơ ron tích chập và các thuật toán học máy tiên tiến giúp tiết kiệm thời gian, công sức trong quá trình đánh giá so với phương pháp truyền thống.


Một vài công trình có thể kể đến, Zhang and Li (2018) đã đề xuất một phương pháp đánh giá độ nhám bề mặt kim loại dựa trên mạng học sâu, Nguyen et al. (2020) đã thành công trong việc dự đoán cấp độ nhám bề mặt tiện và phay bằng cách sử dụng CNN. Các kết quả nghiên cứu đầu tiên này đã góp phần cho thấy tiềm năng của mạng học sâu trong việc phân loại và đánh giá độ nhám bề mặt kim loại, giúp tối ưu hóa quy trình sản xuất, đánh giá chất lượng bề mặt kim loại sau gia công.

Nghiên cứu này thực hiện phân tích độ nhám bề mặt gia công cơ khí từ ảnh bề mặt phôi sử dụng mạng nơ ron tích chập AlexNet. Các bước thực hiện của hệ thống bao gồm: Bước 1, Xây dựng tập dữ liệu huấn luyện: Thu thập ảnh texture đặc trưng theo độ nhám và phương pháp gia công; Bước 2, thiết kế hệ thống huấn luyện và kiểm tra dựa trên mạng nơ ron tích chập AlexNet, để dự đoán độ nhám từ ảnh chụp bề mặt gia công với độ chính xác chấp nhận được (xấp xỉ 90%) so với tập dữ liệu đối chứng; Nghiên cứu này được giới hạn trong khoảng độ nhám Ra 0,4-3,2 μm của các phương pháp gia công: đúc, tiện và phay mặt.

2. NỘI DUNG NGHIÊN CỨU

2.1. Mối liên hệ giữa đặc trưng giữa texture và profile bề mặt gia công

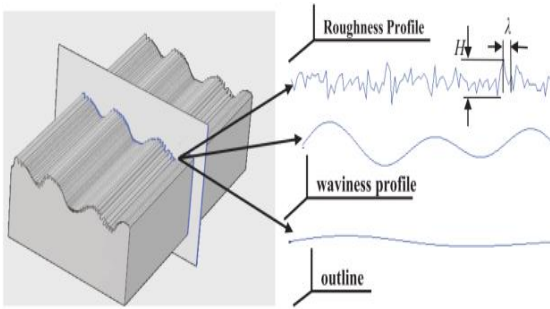
Trong gia công kim loại, mỗi phương pháp chế tạo sẽ để lại một dạng kết cấu đặc trưng trên bề mặt phôi (texture). Sự hình thành kết cấu bề mặt được quy định bởi các yếu tố như vật liệu, dao cụ, tốc độ cắt và chiều sâu cắt. Các texture trong Hình 2 (Gadelmawla et al., 2008), thể hiện sự khác nhau về kết cấu bề mặt kim loại khi được gia công bằng phương pháp phay trong các chế độ cắt được tinh chỉnh tốc độ tiến dao khác nhau.



Hình 2. Cấu trúc bề mặt gia công với tốc độ tiến dao khác nhau (mm/phút)


Ghi chú: Vận tốc trục chính 157 vòng/phút, chiều sâu cắt 0,2 mm

Bên cạnh texture, profile cũng là một thuộc tính quan trọng của bề mặt, nó đề cập đến hình dạng và đặc tính không gian bề mặt. Profile thường được xác định dưới dạng các giá trị đo lường theo một đường chạy dọc trên bề mặt hoặc thông qua lát cắt hình dạng 3D của bề mặt, cách thức thu thập profile như mô tả ở Hình 3 (Li et al., 2019).



Hình 3. Profile trích suất thông qua mặt cắt

Nếu texture thể hiện sự không đồng đều hoặc có những biến đổi mạnh về độ tương phản, điều đó cho thấy có nhiều đỉnh và lõm trên profile bề mặt. Nếu texture mịn và đồng đều, thì profile bề mặt có thể ít gồ ghề hơn. Hình 4 (Sinanoğlu et al., 2005) cho thấy profile mặt cắt và texture bề mặt tương ứng của một bề mặt được gia công bằng phương pháp tiện:



Hình 4. Mặt cắt và texture nhìn từ trên xuống

Như vậy, giữa hai thuộc tính texture và profile bề mặt có mối liên hệ chặt chẽ với nhau, cùng trực tiếp ảnh hưởng, quy định độ nhám bề mặt phi sau gia công.

2.2. Đánh giá độ nhám bề mặt gia công dựa trên ảnh texture

Trong một số trường hợp nhất định, mắt thường có thể nhận thấy được sự khác nhau rõ ràng giữa các cấp độ nhám bề mặt. Điều đó đồng nghĩa, cấp độ nhám bề mặt thông qua ảnh texture hoàn toàn có khả năng được xác định, bên cạnh phương pháp thăm dò trực tiếp profile bề mặt.

Bài toán dự đoán cấp độ nhám bề mặt gia công thông qua ảnh 2D, về bản chất, có phần tương tự như ứng dụng mạng CNN vào phân lớp texture (Văn, 2020). Khi huấn luyện mô hình trên tập dữ liệu texture, mô hình học cách phân loại và nhận dạng các đặc trưng của texture để phân loại chúng vào các nhóm khác nhau. Trong bài toán dự đoán độ nhám bề mặt kim loại, mô hình CNN cũng học cách phát hiện và ánh xạ các đặc điểm của ảnh texture 2D vào các giá trị độ nhám tương ứng.

2.3. Xây dựng tập dữ liệu huấn luyện và kiểm tra

2.3.1. Nguyên tắc và phạm vi thu thập dữ liệu

Quá trình thu thập dữ liệu độ nhám bề mặt kim loại cần tuân thủ nguyên tắc đa dạng và đại diện cho từng kiểu dữ liệu. Điều này đảm bảo mô hình CNN có thể học được các đặc trưng bề mặt của từng phương pháp gia công cũng như đặc trưng cho từng độ nhám khác nhau trong cùng một phương pháp gia công.

Tiền xử lý ảnh: Dữ liệu hình ảnh cần được đảm bảo tính đồng nhất về kích thước 227×227×3 (ảnh màu 3 kênh RGB có kích thước 227×227 pixels), khoảng cách chụp, độ phóng đại và định dạng. Ảnh bị lỗi do rung hoặc chói sáng được loại bỏ khỏi tập huấn luyện nhằm đảm bảo quá trình huấn luyện được ổn định và chính xác.

Dữ liệu được thu thập từ các phương pháp gia công khác nhau và khoảng độ nhám khác nhau tạo ra một tập dữ liệu phong phú đáng tin cậy. Trong phạm vi của nghiên cứu này, các mẫu được thu thập có giá trị độ nhám từ Ra 0,4 μm đến Ra 3,2 μm của ba phương pháp gia công: đúc, tiện trục và phay mặt.

2.3.2. Cách thức thu thập, phân lớp và chia tập dữ liệu ảnh huấn luyện

Bất cứ thay đổi nào về vị trí của ống kính camera trên mặt phẳng 2D song song với bề mặt của mẫu kim loại sẽ tạo ra một ảnh mới. Về lý thuyết, có thể tạo ra vô số ảnh bề mặt khác nhau bằng cách kết hợp giữa việc chụp ảnh liên tục và đồng thời di chuyển ống kính (khung nhìn tức thời của camera). Để thực

hiện được điều này, một chương trình hỗ trợ chụp ảnh liên tục là cần thiết phải được áp dụng.

Mỗi lớp trong tập dữ liệu huấn luyện là một tập hợp với cơ số mẫu ảnh bề mặt được chụp từ cùng một mẫu với cùng phương pháp gia công, cùng khoảng giá trị độ nhám đã xác định và gắn nhãn cấp độ nhám dựa trên kết quả đo đạc từ thiết bị phân tích độ nhám SJ210 (tham khảo Hình 5). Tập dữ liệu huấn luyện gồm 12 lớp (tham khảo Hình 1), được xây dựng trên cơ sở 4 cấp độ nhám của mỗi phương pháp gia công (đúc, phay và tiện).



Hình 5. Bộ thiết bị kiểm tra độ nhám SJ210

Bảng 1. Phân chia lớp huấn luyện

Ra (μm)	Ra 0,4	Ra 0,8	Ra 1,6	Ra 3,2	Ra 6,3
Đúc		L01	L02	L03	L04
Phay	L05	L06	L07	L08	
Tiện	L09	L10	L11	L12	

Bảng 2 thể hiện mẫu dữ liệu trích ngang từ tập dữ liệu huấn luyện:

Bảng 2. Trích ngang tập dữ liệu huấn luyện

Ra(μm)	Ra 0,4	Ra 0,8	Ra 1,6	Ra 3,2	Ra 6,3
Đúc	N/a				
Phay					N/a
Tiện					N/a

Bảng 3. Số mẫu có trong mỗi lớp

Texture	Ra (μm)	Lớp	Số mẫu
Đúc	0,8	01	963
	1,6	02	984
	3,2	03	979
	6,3	04	997
Phay	0,4	05	967
	0,8	06	989
	1,6	07	955
	3,2	08	983
Tiện	0,4	09	986
	0,8	10	993
	1,6	11	987
	3,2	12	960

Mỗi lớp dữ liệu ảnh được chia thành hai phần trong chương trình huấn luyện AlexNet. Tập huấn luyện (trainDataset) với tỉ lệ được phân bổ là 90%, còn lại được phân bổ cho tập đối chứng (validationDataset). Số lượng mẫu có trong mỗi lớp được trình bày cụ thể trong Bảng 3.

2.4. Thiết kế hệ thống

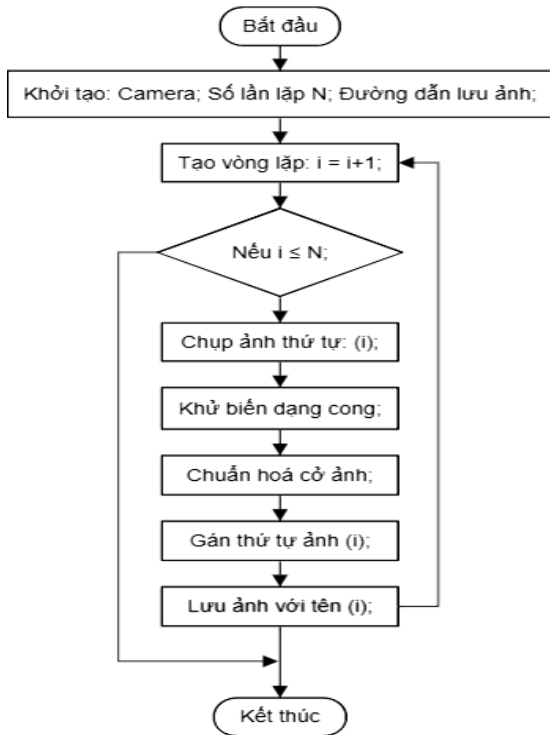
2.4.1. Lưu đồ thu thập, chuẩn hoá ảnh đầu vào

Chương trình hỗ trợ thu thập dữ liệu ảnh được tích hợp chức năng chuẩn hoá đầu vào và khử biến dạng cong. Vấn đề khử độ cong của hình ảnh do biến dạng xuyên tâm thấu kính trong mô hình pinhole camera, được xử lý bằng kỹ thuật hiệu chỉnh méo xuyên tâm dựa trên ảnh chụp bàn cờ phẳng (Hartley et al., 2007; Seok-Han et al., 2009).

Lưu đồ của quá trình chuẩn hoá ảnh đầu vào được thể hiện cụ thể trong Hình 6.

Trong mỗi lớp dữ liệu, số lượng ảnh thu thập cho việc huấn luyện (số vòng lặp) được chọn là $N=1000$. Khi một vòng lặp bắt đầu, hệ thống gọi camera chụp ảnh và gán cho biến `img` bằng hàm `snapshot(cam)`.

Việc khử biến dạng ảnh cong được thực hiện bởi hàm: `undistortImage (img, cameraParameters)`, trong đó, bộ tham số hiệu chỉnh `cameraParameter`, đã trích xuất và lưu lại sau khi hiệu chỉnh camera được gọi ra sử dụng cho bước này.



Hình 6. Lưu đồ chương trình thu thập và chuẩn hoá dữ liệu ảnh đầu vào

Bảng 4. Tham số huấn luyện AlexNet

trainingOption	Diễn giải	Chế độ, giá trị được áp dụng khi huấn luyện
Sgdm	Thuật toán tối ưu hoá	Stochastic Gradient Descent with Momentum
MiniBatchSize	Kích thước mini-batch	10
MaxEpochs	Số epoch tối đa	10
InitialLearnRate	Tốc độ học ban đầu	3.00E-04
Shuffle	Tần suất xáo trộn dữ liệu	Xáo trộn dữ liệu sau mỗi epoch
ValidationData	Dữ liệu validation	Sử dụng augimdsValidation
ValidationFrequency	Tần suất kiểm tra validation	valFrequency
Verbose	Chế độ hiển thị Verbose	Không hiển thị trong quá trình huấn luyện
Plots	Chế độ hiển thị tiến trình	Hiển thị biểu đồ tiến trình huấn luyện

Cấu hình mạng AlexNet thu được sau quá trình huấn luyện với các tham số đã thiết lập như trên, được lưu lại và áp dụng vào hệ thống nhận dạng cấp độ nhám của bề mặt kim loại sau gia công đúc, phay và tiện.

3. KẾT QUẢ THỰC HIỆN

Tiến trình huấn luyện mạng AlexNet được thực hiện trên 11743 mẫu thuộc 12 lớp dữ liệu:

Các đường biểu diễn accuracy và training smoothed trong Hình 7 cho thấy một xu hướng chung là giá trị validation accuracy tăng và dao động giảm sau mỗi chu kỳ epoch.

Tiền xử lý ảnh: Chuẩn hoá kích thước ảnh đầu vào vào 227×227 pixels. Quá trình này thực chất là “Resize” một ảnh chụp (có kích thước bất kỳ), tạo thành một ảnh nhỏ hơn, có kích thước 227×227 pixel. Kích thước này phù hợp với kích thước ảnh đầu vào mà một AlexNet cho phép 227×227 pixels.

Hình ảnh đã qua các bước xử lý và tiền xử lý sẽ được gán tên theo số thứ tự tăng dần và lưu vào đường dẫn đã khai báo ở đầu chương trình. Cho đến khi số thứ tự (tên ảnh) vượt quá số vòng lặp đã định trước N=1000 thì quá trình thu thập ảnh cho một cấp độ nhám sẽ kết thúc.

Quá trình thu thập ảnh có thể gặp phải một số ảnh hỏng (do ảnh bị rung hoặc bị chói sáng) nên số lượng ảnh cần đạt được (N=1000) có thể ít hơn mà không ảnh hưởng đáng kể đến chất lượng huấn luyện của hệ thống.

2.4.2. Thiết kế tham số huấn luyện AlexNet


Cấu hình AlexNet sau huấn luyện được thiết lập thông qua các tùy chọn tham số huấn luyện (trainingOptions). Trong phạm vi của nghiên cứu này, AlexNet được thiết kế với các tham số được ấn định cụ thể trong Bảng 4 như sau:

Epoch 1-2: Đường cong học tập (training) dao động mạnh, hiệu suất mô hình (thể hiện bởi validation) ở ngưỡng thấp và biến động 40-90%.

Epoch 3-4: Đường cong học tập còn dao động mạnh, hiệu suất trung bình của mô hình đạt mức khá và biến động trong khoảng 80-100%.

Epoch 5-7: Đường cong học tập dao động với biên độ nhỏ hơn các chu kỳ trước, hiệu suất mô hình đạt mức cao và biến động trong 90-100%.

Epoch 8-10: Đường cong học tập dao động với biên độ nhỏ và ổn định. Hiệu suất mô hình tiến dần đến tối đa và ổn định ngưỡng 95-100%.



Hình 7. Quá trình, kết quả huấn luyện AlexNet

Kết thúc huấn luyện, validation accuracy trung bình đạt 95,41%, điều này cho thấy mô hình đã đạt đến một mức độ chính xác tương đối cao khi phân loại dữ liệu trên tập dữ liệu validation (tập đối chứng của AlexNet). Đây là một kết quả tốt và cho thấy mô hình có khả năng tổng quát hóa tốt trên dữ liệu mới mà nó chưa từng được thấy (được học) trong quá trình huấn luyện.

Với validation accuracy ở mức cao như vậy (95,41%), mô hình đã học được các đặc trưng quan trọng từ dữ liệu huấn luyện và có thể áp dụng những

thông tin đã học được để phân loại dữ liệu mới một cách chính xác. Kết quả này có ý nghĩa quan trọng đối với việc áp dụng mô hình vào các tác vụ phân loại thực tế, vì mô hình AlexNet đã chứng minh khả năng tổng quát hóa tốt và có thể cung cấp các dự đoán đáng tin cậy cho các hình ảnh (texture) mới.


Bảng 5 tổng hợp các kết quả kiểm thử hệ thống, với tập ảnh không tồn tại hoặc trùng với ảnh trong tập huấn luyện nhằm đảm bảo tính khách quan khi đánh giá hiệu suất của mô hình.

Bảng 5. Tỷ lệ nhận dạng đúng của mô hình AlexNet đã được huấn luyện

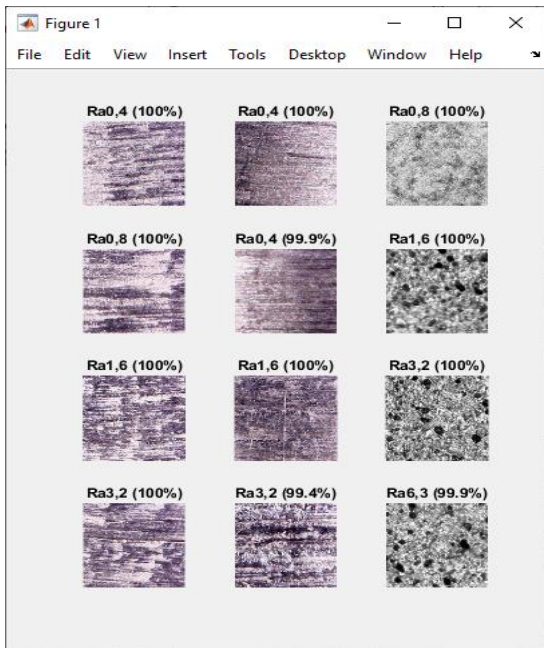
Lớp	Số mẫu	Cấp độ nhám	Cỡ mẫu	Đoán đúng	Tỷ lệ đúng
09 - Tiện	10	Ra 0,4 μm	20	19	95,0%
05 - Phay	10				
01 - Đúc	10				
10 - Tiện	10	Ra 0,8 μm	30	26	86,7%
06 - Phay	10				
02 - Đúc	10				
11 - Tiện	10	Ra 1,6 μm	30	25	83,3%
07 - Phay	10				
03 - Đúc	10				
12 - Tiện	10	Ra 3,2 μm	30	27	90,0%
08 - Phay	10				
04 - Đúc	10	Ra 6,3 μm	10	10	100%

Tỷ lệ dự đoán đúng với ảnh chụp texture ngoài tập huấn luyện (tính trung bình chung với trọng số là cỡ mẫu kiểm thử ở mỗi cấp độ): **89,2%**

Trong đa số thử nghiệm sau huấn luyện, các so sánh giữa ảnh mẫu ban đầu (đã biết trước cấp độ nhám) với ảnh do hệ thống nhận dạng và kết quả dự đoán cấp độ nhám là trùng khớp, như trường hợp so sánh cụ thể các texture giữa Hình 8 và Hình 9. Điều này chứng tỏ hệ thống có khả năng xử lý và nhận dạng tốt các đặc điểm của ảnh texture.



Hình 8. Một số ảnh được sử dụng để kiểm tra hiệu quả của mô hình đã huấn luyện



Hình 9. Kết quả dự đoán cấp độ nhám của mô hình AlexNet

Trong một so sánh khác, Bảng 6 cho thấy các kết quả đo đạc cụ thể bằng phương pháp đầu dò trên thiết bị phân tích độ nhám SJ210, cũng hoàn toàn nằm trong khoảng (hoặc xấp xỉ) cấp độ nhám mà hệ thống dự đoán đã đưa ra.

Bảng 6. Đối chiếu kết quả nhận dạng với giá trị đo trên thiết bị phân tích độ nhám SJ210

Ảnh texture	Giá trị đo trên thiết bị SJ210	Cấp độ nhám theo dự đoán
	Ra 0,507 μm	Ra 0,4 μm
	Ra 0,593 μm	
	Ra 1,080 μm	Ra 0,8 μm
	Ra 0,848 μm	
	Ra 0,674 μm	
	Ra 2,065 μm	Ra 1,6 μm
	Ra 1,911 μm	
	Ra 1,785 μm	
	Ra 3,702 μm	Ra 3,2 μm
	Ra 2,769 μm	
	Ra 2,950 μm	
	Ra 5,331 μm	Ra 6,3 μm

4. KẾT LUẬN VÀ KIẾN NGHỊ

Trong điều kiện thực hiện của nghiên cứu này, tỉ lệ dự đoán đúng trung bình đạt 89,2% qua các thử nghiệm cho thấy mô hình mạng học sâu hoàn toàn

có khả năng dự đoán được cấp độ nhám thông qua ảnh chụp từ bề mặt kim loại đã gia công.

Kết quả của nghiên cứu đã cho thấy tính khả thi trong việc ứng dụng mạng học sâu vào việc dự đoán độ nhám bề mặt gia công với những ưu điểm: nhanh chóng, linh hoạt, ổn định, giảm chi phí với độ chính xác đáng tin cậy.

TÀI LIỆU THAM KHẢO

- Al-Kadi, O. S. (2017). A Gabor Filter Texture Analysis Approach for Histopathological Braim Tumor Subtype Discrimination. *JSZSCO 7. Sci.Technol.*
- Cimpoli, M., Maji, S., & Vedaldi, A. (2015). Deep filter banks for texture recognition and segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. doi:10.1109/cvpr.2015.7299007
- Du, S., Yan, Y., & Ma, Y. (2016). Local energy pattern for texture classification using self-adaptive quantization thresholds. *Optik, 127*(16), 6583-6589.
- Gadelmawla, E. S., Eladawi, A. E., Abouelatta, O. B., & Elewa, I. M. (2008). Investigation of the cutting conditions in milling operations using image texture features. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 222*(11), 1395-1404. doi:10.1243/09544054jem1173.
- Hartley, R., & Kang, S. B. (2007). Parameter-Free Radial Distortion Correction with Center of Distortion Estimation. *IEEE Trans. Pattern. Anal. Mach. Intell., 29*(8), 1309-1321.
- Li, B., Zhou, D., Xu, W., & Zhang, Y. (2019). Effect of random roundness error on the stability of a hydrodynamic journal bearing system part I: Theoretical study. *Advances in Mechanical Engineering, 11*(4), 168781401984625. doi:10.1177/1687814019846250
- Nguyen, H. T., Rifai, A. P., Aoyama, N., Zawiah Md Dawal, S., & Aini Masruroh, N. (2020). Evaluation of turned and milled surfaces roughness using convolutional neural network. *Measurement, 107*860. doi:10.1016/j.measurement.2020.10.
- Nguyen, T. P., Vu, N. S., & Manzanera, A. (2016). Statistical binary patterns for rotational invariant texture classification. *Neurocomputing, 173*, 1565-1577. doi:10.1016/j.neucom.2015.09.029
- Nguyen, V. L., Vu, N. S., Phan, H. H., & Gosselin, P. H. (2017). LBP-and-ScatNet-based combined features for efficient texture classification. *Multimedia Tools and Applications, 76*(21), 22425-22444. doi:10.1007/s11042-017-4824-5
- Roberti, S., F., Robson, S. W., & Pedrini, H. (2013). Multi-scale gray level co-occurrence matrices for texture description. *Neurocomputing, 120*, 336-345. doi:10.1016/j.neucom.2012.09.042
- Seok-Han, L., Tae-Eun, K., & Jong-Soo, C. (2009). Correction of radial distortion using a planar checkerboard pattern and its image. (2009). *Digest of Technical Papers International Conference on Consumer Electronics*. doi:10.1109/icce.2009.5012236
- Sinanoğlu, C., Nair, F., & Karamış, M. B. (2005). Effects of shaft surface texture on journal bearing pressure distribution. *Journal of Materials Processing Technology, 168*(2), 344-353. doi:10.1016/j.jmatprotec.2005.02.
- Văn, D. L. (2020). Kết hợp ScatNet và CNN ứng dụng vào phân lớp Texture, (luận văn thạc sĩ). Trường Đại học Cần Thơ.
- Zhang, C., & Li, Z. (2018). A novel method for evaluating surface roughness of metallic materials based on convolutional neural network. *Materials, 11*(11), 2234.
- Zhang, J., Liang, J., & Zhao, H. (2013). Local Energy Pattern for Texture Classification Using Self-Adaptive Quantization Thresholds. *IEEE Transactions on Image Processing, 22*(1), 31-42. doi:10.1109/tip.2012.2214045