

Nhận diện một số bệnh phổ biến dựa trên lá sầu riêng sử dụng kỹ thuật học sâu

Identifying common diseases on durian leaves using deep learning techniques

ThS. Đặng Thị Xuân Tiên^{1*}, ThS. Lê Minh Trung², ThS. Nguyễn Quan Khánh³

¹Khoa Công Nghệ, Trường Đại học Xây dựng Miền Tây

²Trường tiểu học Lộc Hòa B, Vĩnh Long

³Trường Cao đẳng Kiên Giang

*Tác giả liên hệ: dangthixuantien@gmail.com

■Nhận bài: 22/01/2025 ■Sửa bài: 23/02/2025 ■Duyệt đăng: 13/05/2025

TÓM TẮT

Sầu riêng, một loại trái cây nhiệt đới có giá trị kinh tế cao, được mệnh danh là “Vua của các loại trái cây” và được trồng rộng rãi ở Việt Nam. Tuy nhiên, cây sầu riêng dễ bị mắc các bệnh trên lá, gây ảnh hưởng nghiêm trọng đến sức khỏe và năng suất của cây trồng. Việc phát hiện sớm và chính xác các bệnh này thông qua hình ảnh lá đóng vai trò vô cùng quan trọng trong việc xử lý kịp thời, từ đó giúp cải thiện năng suất và chất lượng cây trồng. Trong nghiên cứu này, chúng tôi đề xuất một kỹ thuật nhận diện và phân loại hình ảnh lá sầu riêng bằng cách sử dụng các mô hình học sâu dựa trên các kiến trúc mạng nổi bật như MobileNetV3, InceptionV3 và VGG19. Các mô hình này đã được huấn luyện trên một tập dữ liệu gồm 8682 hình ảnh của 4 loại lá sầu riêng: lá mắc bệnh cháy lá, bệnh đốm rong, bệnh đốm lá và lá không bị bệnh. Kết quả thử nghiệm cho thấy mô hình đạt được độ chính xác lên tới 95,87%, cho thấy khả năng phân loại bệnh trên lá sầu riêng một cách nhanh chóng và chính xác. Kết quả nghiên cứu này có thể đóng góp đáng kể vào việc giúp nông dân phát hiện bệnh kịp thời và áp dụng các biện pháp điều trị phù hợp, từ đó nâng cao năng suất và lợi nhuận từ cây sầu riêng.

Từ khóa: Sầu riêng, bệnh trên lá, MobileNetV3, InceptionV3, VGG19

ABSTRACT

Durian, a tropical fruit with high economic value, is widely cultivated in Vietnam and is often referred to as the “King of Fruits.” However, the durian tree is susceptible to various leaf diseases that can significantly affect its health and yield. Early and accurate detection of these diseases through leaf images plays a crucial role in timely intervention, which can improve both the productivity and quality of the crops. In this study, we propose a technique for leaf image classification and disease identification using deep learning models based on prominent architectures such as MobileNetV3, InceptionV3, and VGG19. The models were trained on a dataset comprising 8,682 images of four types of durian leaves: healthy leaves, leaves with Leaf Scorch, Cercospora Leaf Spot, and Phytophthora Blight. The results show that the proposed model achieved an accuracy of 95.87%, demonstrating its effectiveness in quickly and accurately classifying leaf diseases. The findings of this study could significantly assist farmers in early disease detection and timely treatment, thereby enhancing the yield and profitability of durian cultivation.

Keywords: Durian, leaf diseases, MobileNetV3, InceptionV3, VGG19.

1. MỞ ĐẦU

1.1. Giới thiệu bài toán

Sầu riêng là loại trái cây nhiệt đới được yêu thích tại Đông Nam Á, đặc biệt là Việt

Nam. Với hương vị thơm ngon, giá trị dinh dưỡng cao, sầu riêng được mệnh danh là “Vua của các loại trái cây” và đóng góp quan trọng cho nền kinh tế nước ta. Nhu cầu tiêu thụ sầu

riêng ngày càng tăng, thúc đẩy diện tích trồng và sản lượng sầu riêng gia tăng. Ở Việt Nam, trong năm 2023, theo Tổng cục thống kê diện tích sầu riêng chiếm 76.6 nghìn ha với sản lượng đạt 1185.5 nghìn tấn và có kim ngạch xuất khẩu là 2.1 tỷ USD theo thông tin từ Tổng cục Hải quan. Tuy nhiên, sầu riêng dễ bị các bệnh trên lá, ảnh hưởng đến năng suất và chất lượng quả. Các loại bệnh phổ biến như đốm lá, đốm rong, cháy lá, chết ngọn, thán thư... gây thiệt hại lớn cho người nông dân. Phát hiện sớm và chính xác bệnh dựa trên hình ảnh lá là yếu tố then chốt để kiểm soát và phòng trừ bệnh hiệu quả. Việc này giúp người nông dân áp dụng các biện pháp xử lý kịp thời, ngăn chặn sự lây lan và giảm thiểu thiệt hại. Hiện nay, việc nhận diện bệnh trên lá sầu riêng chủ yếu dựa vào kinh nghiệm thực tế, chưa có sự hỗ trợ của công nghệ gây mất thời gian, có thể thiếu chính xác và không kịp thời. Để giải quyết được hạn chế này, nghiên cứu ứng dụng mạng học sâu trong nhận diện một số bệnh phổ biến dựa trên hình ảnh lá sầu riêng là hướng đi mới đầy tiềm năng và thiết thực cho nông dân trồng sầu riêng.

1.2. Đặc điểm của sầu riêng

Sầu riêng, loại cây ăn quả nhiệt đới lâu năm, mang lại giá trị kinh tế cao và thu nhập bền vững cho người nông dân. Cây được trồng rộng rãi ở khu vực Đông Nam Á, trong đó có Việt Nam. Nổi tiếng với hương vị độc đáo và mùi thơm nồng nàn, sầu riêng dần trở thành một loại trái cây được ưa chuộng. Tuy nhiên, việc trồng sầu riêng cũng gặp nhiều thách thức do các loại sâu bệnh gây hại. Nổi bật là hơn 10 loại sâu hại như sâu đục cành, đục trái, nhện đỏ, bọ trĩ, tuyến trùng,... Về các loại bệnh, ngoài bệnh xì mũ có khả năng hủy hoại cả vườn cây, sầu riêng còn dễ bị tấn công bởi các bệnh như cháy lá do nấm *Rhizoctonia solani*, đốm lá do nấm *Phomopsis durionis*, và đốm rong do tảo *Cephaleuros virescens*,... Với đặc điểm thực vật học là ra trái trên cành, bộ lá đóng vai trò vô cùng quan trọng đối với sầu riêng nên chất lượng và năng suất của vườn cây đều phụ thuộc vào sức khỏe của bộ lá. Do đó, việc phát hiện sớm các loại bệnh trên lá dựa trên sức khỏe và hình ảnh của lá là yếu tố then chốt để kiểm soát hiệu quả và giảm thiểu thiệt hại kinh tế cho người trồng.



Hình 1. Hình ảnh lá sầu riêng

1.3. Vai trò của học sâu trong nhận diện bệnh trên lá sầu riêng

Kỹ thuật học sâu và máy học đã đóng một vai trò quan trọng trong lĩnh vực nông nghiệp để nhận diện, phân loại và phát hiện bệnh thông qua hình ảnh lá trên cây trồng, trong đó có cây sầu riêng, đồng thời cung cấp các phương tiện phát hiện bệnh trên cây trồng với chi phí thấp, nhanh chóng và đáng tin cậy. Học sâu cho phép hệ thống tự động phân tích hình ảnh lá sầu riêng, trích xuất các đặc trưng liên

quan đến bệnh. Các mạng CNN có thể học các đặc trưng như màu sắc, kết cấu, hình dạng của các loại bệnh. Nhờ khả năng học các đặc trưng phức tạp và mối quan hệ giữa các đặc trưng, hệ thống nhận dạng bệnh dựa trên học sâu có thể phân biệt các loại bệnh khác nhau trên lá sầu riêng một cách chính xác hơn. Từ đó, giúp người nông dân phát hiện bệnh sớm, có biện pháp phòng trừ kịp thời, hạn chế thiệt hại, nâng cao năng suất và chất lượng quả sầu riêng, tăng thu nhập.

2. NHỮNG NGHIÊN CỨU LIÊN QUAN

Đề tài nghiên cứu của Jay Al Gallenero và cộng sự [2] đã sử dụng mạng thần kinh chuyển đổi MobileNet, một mô hình được huấn luyện trước đủ khả năng xử lý trực quan và sẽ giúp giảm đáng kể thiệt hại kinh tế liên quan đến các bệnh như đốm táo, cháy lá, đốm lá, lá khỏe. Tổng cộng có bảy mươi lăm (75) mẫu được phân tích và sử dụng ma trận nhầm lẫn để tính toán độ chính xác của hệ thống, là 93.333%. Nhờ đó, kỹ thuật xác định hiệu quả các loại bệnh trên lá sầu riêng nói trên.

Nghiên cứu của tác giả N. A. H. A. Halim, S. Suhaila, N. S. A. M. Taujuddin1, R. Hazli [4] đã đề xuất và nghiên cứu về nhận dạng loại cây sầu riêng dựa trên lá sầu riêng trên thiết bị di động thực hiện bằng TensorFlow Lite cung cấp quy trình phát triển cho mô hình CNN với kết quả mô hình có độ chính xác là 86.00% khi huấn luyện, 77.78% khi xác thực và 66.67% khi kiểm tra. AL. Sabarre và cộng sự [5] đã phát triển tính năng phát hiện bệnh trên lá sầu riêng trên thiết bị Android và xây dựng một ứng dụng di động độc lập có thể phân loại các bệnh trên lá sầu riêng bằng phương pháp học chuyển giao ứng dụng và mô hình CNN MobileNets được huấn luyện lại. Bộ phân loại có thể phát hiện chính xác 36 trong số 40 mẫu với độ chính xác tổng thể là 90%.

Shivani Machha và cộng sự [6] đã sử dụng mạng lưới CNN với mô hình đã được huấn luyện để xác định bệnh trên lá cây. Phát hiện nhiều loại bệnh trên lá cây như bông, mía, lúa mì, nho. Dữ liệu được xử lý và huấn luyện trên kiến trúc CNN. Thuật toán MobileNet được sử dụng để huấn luyện dữ liệu. Lập trình Python cùng với thư viện Tensor flow/Keras được sử dụng để thao tác phân loại bệnh lá. Mô hình được xây dựng trên Colab với độ chính xác 97.33%.

2.1. Các mạng nơ-ron trích xuất đặc trưng

2.1.1. MobileNetV3

MobileNetV3 [7] là một trong những mạng CNN được thiết kế đặc biệt để đạt được cân bằng giữa hiệu suất và tài nguyên tích hợp. Được phát triển bởi nhóm nghiên cứu

tại Google AI; MobileNetV3 là phiên bản tiếp theo của chuỗi mạng MobileNet, nhằm tối ưu hóa hiệu năng và hiệu quả trong việc triển khai trên các thiết bị di động và đạt được hiệu suất vượt trội so với các mô hình di động hiện đại khác trên nhiều nhiệm vụ nhận dạng hình ảnh, bao gồm phân loại hình ảnh, phát hiện đối tượng và phân đoạn ảnh.

2.1.2. InceptionV3

InceptionV3 [8] là một trong những mạng nơ-ron nổi tiếng, một trong những phiên bản của Inception (mô hình mạng CNN đặc biệt được nghiên cứu bởi Google năm 2014 tham dự cuộc thi ImageNet) có gần 24 triệu tham số, độ sâu 48 lớp có khả năng giảm đáng kể kích thước đầu vào của lớp tiếp theo và được huấn luyện bởi 1000 lớp dữ liệu từ ImageNet. InceptionV3 sử dụng các khối Inception để cải thiện hiệu quả và tốc độ của mạng nơ-ron. Các khối Inception bao gồm các bộ lọc có kích thước khác nhau để trích xuất các đặc trưng hình ảnh ở nhiều thang độ khác nhau giúp thúc đẩy sự phát triển của nhận diện hình ảnh và thị giác máy tính.

2.1.3. VGG19

VGG19 [9] là một mô hình mạng CNN hiệu quả cho nhận dạng hình ảnh quy mô lớn do hai nhà khoa học Simonyan và Zisserman của trường đại học Oxford xây dựng và huấn luyện gồm 19 lớp (16 lớp tích chập và 3 lớp kết nối đầy đủ). Trong cuộc thi ILSVRC năm 2014, VGG19 đã đạt được thứ hạng đáng kinh ngạc như: hạng nhất ở hạng mục định vị tọa độ vật thể và hạng nhì ở hạng mục phân loại hình ảnh. Kiến trúc mạng này có khoảng 143 triệu tham số, trong đó các tham số được học từ bộ dữ liệu ImageNet chứa 1.2 triệu đối tượng chung của 1000 loại đối tượng khác nhau để huấn luyện. Ước tính chập được cố định 1 pixel cho đệm không gian (spatial padding) của đầu vào lớp tích chập sao cho độ phân giải không gian được bảo toàn sau khi tích chập. Đệm không gian được thực hiện bởi năm lớp tổng hợp tối đa (max pooling) theo sau một số lớp tích chập. Max-pooling được thực hiện trên cửa sổ 2x2 pixel với bước trượt (stride)

là 2. Tiếp theo là đơn vị tuyến tính chỉnh lưu (Rectified linear unit (ReLU)) để làm cho mô hình phân loại tốt hơn và cải thiện thời gian tính toán vì các mô hình trước đó sử dụng các hàm tanh hoặc sigmoid.

3. PHƯƠNG PHÁP ĐỀ XUẤT

3.1. Các độ đo đánh giá mô hình

Để xác định trọng số cho biết hiệu quả của các mô hình thì các thông số precision, recall, Acc và F1-score được xác định bằng các công thức từ (1) - (4). Trong đó, TP (true positive) là tổng số ảnh của lớp đang xét được phân loại đúng, FP (fault positive) là tổng số ảnh phân loại sai vào lớp đang xét, TN (true negative) là tổng số ảnh của lớp khác được phân loại đúng, FN (fault negative) là tổng số ảnh của lớp đang xét bị phân loại vào lớp khác, Accuracy là độ chính xác của mô hình [10].

$$\text{Precision} = \frac{TP}{(TP + FP)} \times 100\% \quad (1)$$

$$\text{Recall} = \frac{TP}{(TP + FN)} \times 100\% \quad (2)$$

$$\text{Accuracy} = \frac{TP + TN}{(TP + FP + TN + FN)} \times 100\% \quad (3)$$

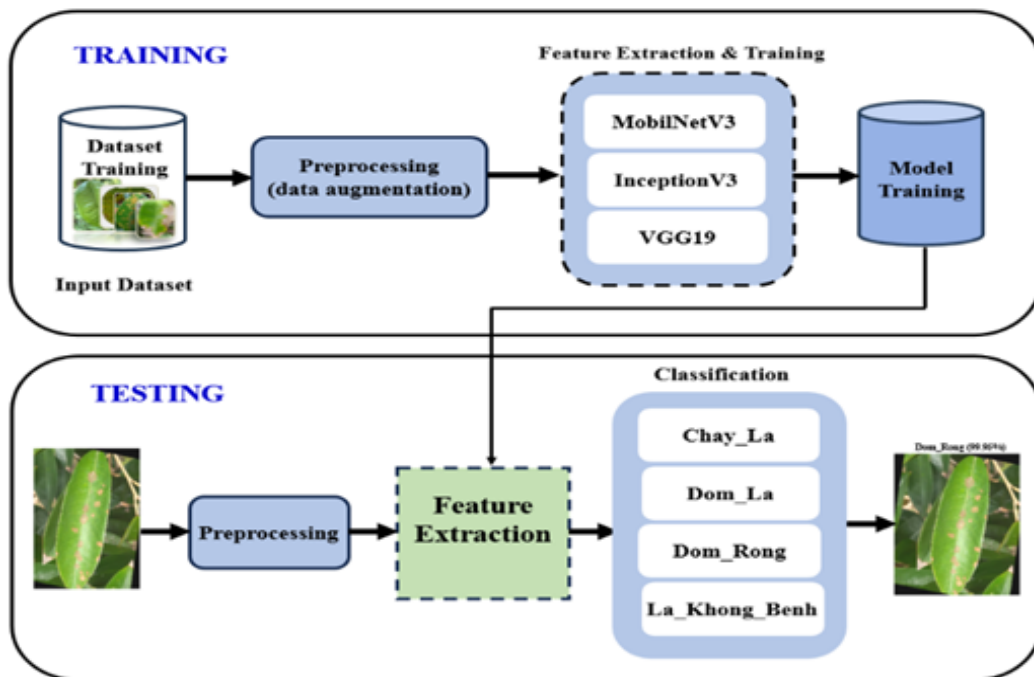
$$F1 - score = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Để đánh giá độ mất mát (tỷ lệ tiên đoán lỗi), chúng tôi sử dụng độ đo Loss. Độ đo Loss được tính bằng công thức số (5) sau khi có được công thức số (3) và (4).

$$\text{Loss} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - R_i)^2} \quad (5)$$

3.2. Mô hình đề xuất

Trong nghiên cứu này, sử dụng phương pháp học chuyển giao dựa trên kỹ thuật học sâu với ba mô hình mạng đề xuất là MobileNetV3, InceptionV3 và VGG19 để nhận diện một số bệnh phổ biến trên cây sầu riêng như: cháy lá, đốm lá, đốm rong và lá không bệnh thông qua hình ảnh thể hiện trên lá và so sánh, lựa chọn mô hình tốt nhất trong ba mô hình đã đề xuất. Mô hình đề xuất gồm 2 giai đoạn là huấn luyện (training) và kiểm thử (testing). Chi tiết của các giai đoạn được thể hiện ở Hình 2.



Hình 2. Mô hình đề xuất nhận diện một số bệnh phổ biến trên cây sầu riêng

3.2.1. Huấn luyện mô hình

Ở giai đoạn tiền xử lý, chúng tôi thực hiện chuẩn hóa kích thước ảnh thành 224 x 224

pixel, đây là kích thước phù hợp để tạo bản vá từ hình ảnh đầu vào. Sau đó, chúng tôi tiến hành tăng cường dữ liệu bằng cách xoay, lật ảnh ngẫu nhiên, cắt xén, thay đổi độ sáng của

ảnh và gán nhãn cho dữ liệu. Sau quá trình tiền xử lý dữ liệu, chúng tôi tiến hành rút trích đặc trưng các đặc điểm của các loại bệnh trên ảnh lá sầu riêng thu thập được và tiến hành huấn luyện bằng phương pháp học sâu gồm các mô hình MobileNetV3, InceptionV3 và VGG19 như đã trình bày ở phần mô hình đề xuất ở trên (Hình 2).

3.2.2. Kiểm thử

Ở giai đoạn kiểm thử, dữ liệu đầu vào sẽ là tập dữ liệu hình ảnh được mô tả trong phần 3.3.2 để nhận dạng và phân loại bệnh lá sầu

riêng. Ở quá trình tiền xử lý, ảnh đầu vào sẽ được chuẩn hóa về kích thước thành 224 x 224, sau đó sẽ tiến hành đưa qua mô hình đã được huấn luyện để tiến hành dự đoán. Kết quả kiểm thử sẽ đưa ra một trong bốn kết luận là: cháy lá, đốm lá, đốm rong hoặc lá không bệnh.

3.3. Kịch bản

3.3.1. Các kịch bản áp dụng

Để tiến hành thực nghiệm cho mô hình đề xuất, chúng tôi thực hiện ba kịch bản như trong Bảng 1: với các tham số huấn luyện:

Bảng 1: Các kịch bản được đề xuất và các tham số huấn luyện

Kịch bản	Kiến trúc mạng	Epochs	Learning rate	Input shape	Activation Function
1	MobileNetV3	100	1e-5	224x224	Softmax
2	Inception	100	1e-5	224x224	Softmax
3	VGG19	100	1e-5	224x224	Softmax

3.3.2. Môi trường cài đặt và tập dữ liệu thực nghiệm

a. *Môi trường cài đặt:* Hệ thống được cài đặt bằng ngôn ngữ Python và chạy trên cùng một môi trường Google Colab Pro (T4 GPU). Thư viện hỗ trợ huấn luyện mô hình mạng sử dụng là Tensorflow và Keras.



b. *Tập dữ liệu thực nghiệm:* Tập dữ liệu được chúng tôi thu thập từ trang Roboflow.com và chụp từ các vườn sầu riêng ở Vĩnh Long vào năm 2023. Tập dữ liệu bao gồm 3,256 hình ảnh với kích thước hình ảnh khác nhau. Sau khi sử dụng các thuật toán tăng cường dữ liệu, chúng tôi có tổng cộng 8,682 ảnh. Sử dụng 80% cho tập huấn luyện mô hình (6,957 ảnh) và 20% cho kiểm thử mô hình (1,725 ảnh). Các hình ảnh ở định dạng JPG, JPEG và được phân loại thành bốn loại: cháy lá, đốm lá, đốm rong, và lá không bệnh.

c. *Phân bố tập test:* Cháy lá: 432 ảnh, Đốm lá: 431 ảnh, Đốm rong: 430 ảnh, Lá không bệnh: 432 ảnh.



4. CÁC KẾT QUẢ THỰC NGHIỆM

4.1. Độ đo Loss và Accuracy

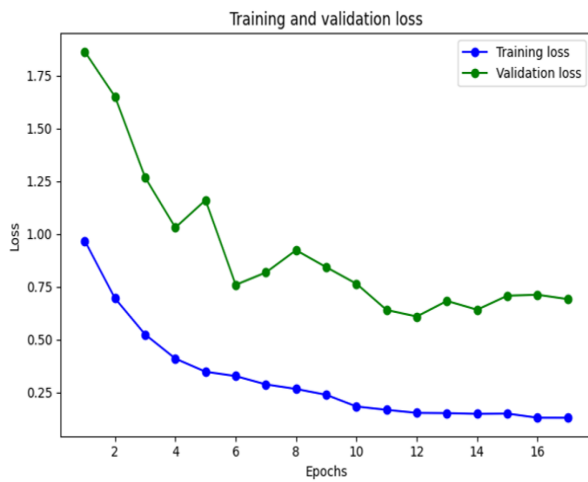
Trong quá trình huấn luyện, chúng tôi chọn giá trị 224 x 224 cho kích thước ảnh đầu vào. Hình 3 thể hiện giá trị Loss và Accuracy của các kịch bản 1, kịch bản 2 và kịch bản 3. Giá trị validation loss của các kịch bản lần lượt là 0.5155, 0.2933, 0.6946. Tuy nhiên, kịch bản 1 và 2 có validation loss thấp hơn kịch bản 3 nhưng biểu hiện không ổn định với những điểm tăng đột biến, cho thấy mô hình huấn luyện chưa tối ưu và có thể dẫn đến sai lệch trong quá trình dự đoán. Đối với kịch bản 3, giá trị validation loss tuy cao hơn hai kịch bản còn lại nhưng validation loss và training loss có xu hướng giảm đều và song song nhau qua từng epoch, cho thấy mô hình học tốt và không có dấu hiệu của hiện tượng overfitting. Để tránh overfitting, chúng tôi áp dụng kỹ thuật early stopping để dừng huấn luyện khi validation loss không cải thiện sau một số epoch nhất định. Độ chính xác của các kịch bản lần lượt là 52.33%, 89.48%, 95.87%. Kết quả thực nghiệm cho thấy kịch bản 3 có độ chính xác cao hơn trên tập dữ liệu đề xuất, phù hợp cho nhận dạng bệnh trên lá sầu riêng trong thực tế.



a. Kịch bản 1



b. Kịch bản 2



c. Kịch bản 3

Hình 3. Biểu đồ về độ đo Accuracy và Loss của kịch bản 1, 2 và 3

4.2. Confusion Matrix và Độ chính xác trên từng loại bệnh

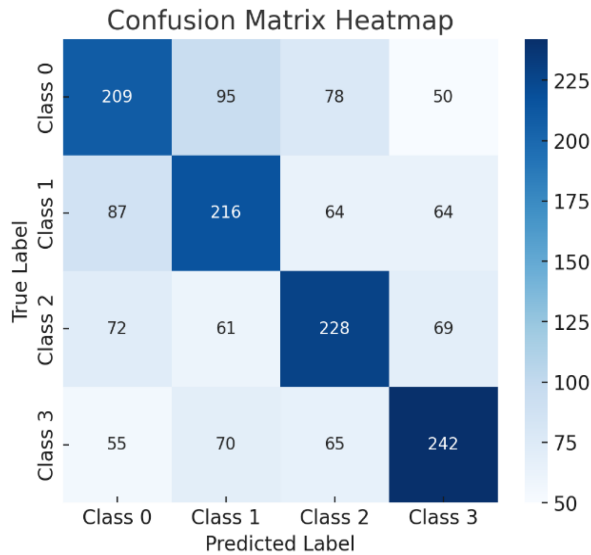
Để đánh giá chi tiết hơn, chúng tôi cung cấp confusion matrix cho từng kịch bản.

Confusion matrix giúp xác định bệnh nào dễ nhận dạng đúng và bệnh nào dễ nhầm lẫn sang bệnh khác.

Kịch bản 1 (MobileNetV3):

Độ chính xác trên từng loại: Cháy lá: 48.5%, Đốm lá: 50.2%, Đốm rong: 53.1%, Lá không bệnh: 57.4% (Hình 4)

Confusion Matrix:




Hình 4. Confusion Matrix kịch bản 1 (MobileNetV3)

Kịch bản 2 (InceptionV3):

Độ chính xác trên từng loại: Cháy lá: 87.3%, Đốm lá: 88.6%, Đốm rong: 90.1%, Lá không bệnh: 91.2% (Hình 5)

Confusion Matrix:




Hình 5. Confusion Matrix kịch bản 2 (InceptionV3)

Kịch bản 3 (VGG19):

Độ chính xác trên từng loại: Cháy lá: 94.5%, Đốm lá: 95.1%, Đốm rong: 96.3%, Lá không bệnh: 97.2% (Hình 6)

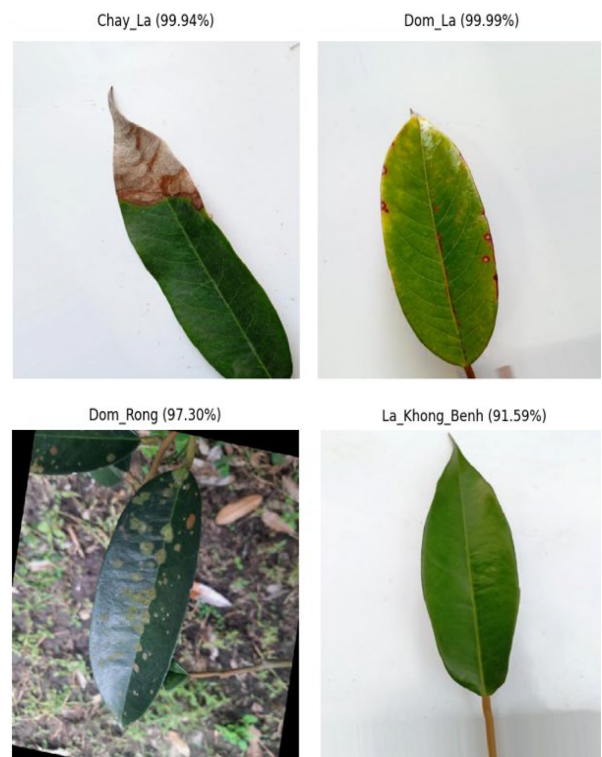
Confusion Matrix:

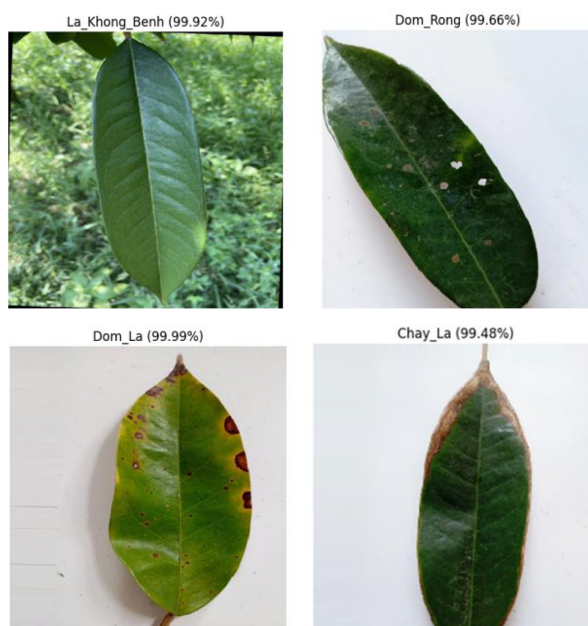


Hình 6. Confusion Matrix kịch bản 3 (VGG19)

4.3. Một số kết quả thực nghiệm

Một số kết quả thực nghiệm của quá trình nhận diện và phân loại một số loại bệnh trên hình ảnh lá sầu riêng dựa trên mô hình mạng đề xuất được thể hiện ở Hình 7





Hình 7. Một số kết quả thực nghiệm

Qua thực nghiệm đã chứng minh hiệu quả cao của mô hình trong việc nhận diện các loại bệnh trên lá sầu riêng được đề xuất. Đối với các bệnh có sự khác biệt về màu sắc, đặc điểm, hình dạng và kích thước, mô hình kịch bản 3 vẫn cho kết quả nhận dạng chính xác cao trong các trường hợp khác nhau của tập dữ liệu kiểm thử.

KẾT LUẬN

Bài báo này trình bày nghiên cứu ứng dụng phương pháp học sâu để nhận diện một số loại bệnh phổ biến trên lá sầu riêng thông qua hình ảnh. Việc nhận diện mang ý nghĩa quan trọng trong việc giúp người nông dân xác định chính xác loại bệnh và điều trị kịp thời, góp phần nâng cao năng suất và lợi nhuận từ cây sầu riêng. Chúng tôi đã sử dụng các kiến trúc mạng học sâu tiêu biểu hiện nay bao gồm MobileNetV3, InceptionV3 và VGG19 để so sánh kết quả giữa các kiến trúc, góp phần đánh giá và lựa chọn được phương pháp phù hợp. Kết quả thử nghiệm cho thấy mô hình VGG19 đạt độ chính xác cao nhất lên đến 95.87% (so với một số nghiên cứu có liên quan, mô hình VGG19 trong nghiên cứu này có độ chính xác cao hơn so với nghiên cứu của Jay Al Gallenero và cộng sự [2], N. A. H. A. Halim và cộng sự [4], AL. Sabarre và

cộng sự [5] lần lượt là 4.21%, 2.54%, 18.9% và 5.87%).

Bộ dữ liệu được sử dụng trong nghiên cứu này bao gồm 8,682 hình ảnh lá sầu riêng, được thu thập từ các vườn sầu riêng tại tỉnh Tiền Giang và Đồng Nai, Việt Nam, trong khoảng thời gian từ tháng 3 đến tháng 6 năm 2023. Dữ liệu được chia thành 4 loại chính: lá khỏe mạnh, lá bị bệnh cháy lá (Leaf Scorch), lá bị bệnh đốm lá (Cercospora Leaf Spot), và lá bị bệnh thối lá (Phytophthora Blight). Mỗi loại bệnh được thu thập với số lượng tương đương nhau để đảm bảo tính cân bằng trong tập dữ liệu. Ngoài ra, chúng tôi cũng sử dụng một phần dữ liệu từ nguồn công khai trên Roboflow.com để bổ sung và đa dạng hóa tập dữ liệu. Quá trình tiền xử lý dữ liệu bao gồm resize ảnh về kích thước 224x224, áp dụng kỹ thuật data augmentation (xoay, lật, thay đổi độ sáng) để tăng cường độ phong phú của dữ liệu.

Nghiên cứu này khẳng định tiềm năng to lớn của học sâu trong việc nhận diện bệnh trên cây sầu riêng. Độ chính xác và độ tin cậy cao của mô hình mở ra hướng đi mới cho việc ứng dụng trí tuệ nhân tạo vào lĩnh vực nông nghiệp. Hướng nghiên cứu tiếp theo là áp dụng mô hình trên nhiều loại mạng khác nhau và mở rộng phạm vi nhận diện sang nhiều loại bệnh phổ biến trên lá và quả sầu riêng.

TÀI LIỆU THAM KHẢO

- [1] Lim, T. K., & Sangchote, S. (2003). Diseases of Durian (*Durio zibethinus*) in Thailand. *Australasian Plant Pathology*, 32(1), 71-73.
- [2] Al Gallenero, J., & Villaverde, J. (2023, March). Identification of Durian Leaf Disease Using Convolutional Neural Network. In 2023 15th International Conference on Computer and Automation Engineering (ICCAE) (pp. 172-177). IEEE.
- [3] Drenth, A., & Guest, D. I. (2004). Diversity and management of Phytophthora in South-east Asia. *ACIAR Monograph No. 114*.

- [4] Halim, N. A. H. A., Sari, S., Taujuddin, N. S. A. M., & Roslan, H. (2023). Durian Tree Type Identification Based on Durian Leaves. *Evolution in Electrical and Electronic Engineering*, 4(1), 551-558.
- [5] Sabarre, A. L., Navidad, A. S., Torbela, D. S., & Adtoon, J. J. (2021). Development of durian leaf disease detection on Android device. *International Journal of Electrical and Computer Engineering*, 11(6), 4962.
- [6] Machha, S., Jadhav, N., Kasar, H., & Chandak, S. (2020). Crop leaf disease diagnosis using convolutional neural network. *International Research Journal of Engineering and Technology (IRJET)*, 7(02).
- [7] Howard, A., Sandler, M., Chu, G., Chen, L., Chen, B., Tan, M., ... & Adam, H. (2019). Searching for mobilenetv3. *CoRR abs/1905.02244* (2019). *arXiv preprint arXiv:1905.02244*.
- [8] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2015). Rethinking the Inception Architecture for Computer Vision. *arXiv: 1512.00567 [cs]*. *arXiv preprint arXiv:1512.00567*.
- [9] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2015). Rethinking the Inception Architecture for Computer Vision. *arXiv: 1512.00567 [cs]*. *arXiv preprint arXiv:1512.00567*.
- [10] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.