

TOMATO DISEASES CLASSIFICATION BASED ON LEAF IMAGES USING MOBILENET V2

Nguyễn Thị Thanh Nhan

TNU - University of Information and Communication Technology

ARTICLE INFO	ABSTRACT
Received: 05/5/2025 Revised: 26/6/2025 Published: 28/6/2025	Tomato is one of the most valuable and widely consumed vegetable crops in the world. Tomato plants are frequently attacked by various pathogens, leading to reduced yield and fruit quality. Therefore, early detection of leaf disease symptoms in the early stages will help farmers promptly apply preventive measures, limit the spread and minimize agricultural losses. This paper proposes the application of a lightweight deep learning architecture, MobileNet V2, for the classification of tomato leaf diseases. The model is trained using transfer learning, with several configurations of hyperparameters, data splitting strategies, and data balancing techniques. The program is designed to classify ten categories: nine classes corresponding to different tomato leaf diseases and one class representing healthy plants, using images from the PlantVillage dataset. The results show that MobileNet V2 can classify diseases with the best accuracy of 95.73%, opening up the direction of deploying an automatic tomato disease monitoring system on mobile devices with fast inference speed and low computational cost.
KEYWORDS	
MobileNet V2	
Convolutional neural network	
Tomato leaf disease	
Fine tuning	
Plant disease identification	

PHÂN LOẠI BỆNH TRÊN CÂY CÀ CHUA DỰA TRÊN HÌNH ẢNH LÁ SỬ DỤNG MẠNG MOBILENET V2

Nguyễn Thị Thanh Nhan

Trường Đại học Công nghệ thông tin và Truyền thông - ĐH Thái Nguyên

THÔNG TIN BÀI BÁO	TÓM TẮT
Ngày nhận bài: 05/5/2025 Ngày hoàn thiện: 26/6/2025 Ngày đăng: 28/6/2025	Cây cà chua là một trong những loại cây rau quả có giá trị kinh tế cao và được tiêu thụ rộng rãi trên toàn thế giới. Cây cà chua thường xuyên bị tấn công bởi nhiều loại mầm bệnh khác nhau dẫn đến giảm năng suất và chất lượng trái. Do vậy, việc phát hiện sớm các triệu chứng bệnh trên lá cây trong giai đoạn đầu sẽ giúp nông dân kịp thời áp dụng biện pháp phòng trừ, hạn chế lây lan và giảm thiểu tổn thất nông sản. Bài báo này đề xuất ứng dụng kiến trúc học sâu nhẹ, MobileNet V2, để phân loại bệnh lá cà chua. Mô hình được huấn luyện sử dụng kỹ thuật học chuyển giao, với một số cấu hình siêu tham số, chiến lược phân chia dữ liệu và kỹ thuật cân bằng dữ liệu. Chương trình được thiết kế để phân loại mười lớp: chín lớp tương ứng với các bệnh lá cà chua khác nhau và một lớp đại diện cho cây khỏe mạnh, sử dụng hình ảnh từ tập dữ liệu PlantVillage. Kết quả cho thấy MobileNet V2 có thể phân loại bệnh với độ chính xác tốt nhất đạt 95,73%, mở ra hướng triển khai hệ thống giám sát bệnh cây cà chua tự động trên các thiết bị di động với tốc độ suy diễn nhanh và chi phí tính toán thấp.
TỪ KHÓA	
MobileNet V2	
Mạng nơ ron tích chập	
Bệnh cây cà chua	
Tinh chỉnh mạng	
Nhận dạng bệnh cây	

DOI: <https://doi.org/10.34238/tnu-jst.12722>

Email: nttnhan@ictu.edu.vn

<http://jst.tnu.edu.vn>

231

Email: jst@tnu.edu.vn

1. Giới thiệu

Bệnh cây trồng là một vấn đề quan trọng vì chúng làm giảm đáng kể số lượng và chất lượng sản xuất nông nghiệp. Đó là lý do tại sao việc phát hiện và phân loại bệnh là một nhiệm vụ quan trọng trong lĩnh vực nông nghiệp.

Cà chua là một loại rau được tiêu thụ rộng rãi trên thế giới cung cấp nguồn dinh dưỡng tốt với nhiều vitamin và khoáng chất. Tuy nhiên, cây cà chua dễ bị nhiễm nhiều loại bệnh khác nhau do các tác nhân như nấm, vi khuẩn, vi rút gây ảnh hưởng đến năng suất của cây cà chua [1]. Trong đó, nhiều bệnh có thể quan sát dấu hiệu trên lá. Việc xác định chính xác bệnh của cây cà chua là một nhiệm vụ thách thức đối với các nhà nông học. Việc nhận dạng và phân loại bệnh thực vật nói chung và cây cà chua nói riêng đóng vai trò quan trọng trong lĩnh vực nông nghiệp, quyết định đến chất lượng, số lượng và năng suất của cây trồng. Do vậy, cần phát triển một hệ thống phân loại tự động bệnh của cây, từ đó giúp nông dân chuẩn đoán bệnh ở giai đoạn đầu để can thiệp kịp thời nhằm ngăn ngừa tổn thất lớn.

Học sâu là một nhánh của trí tuệ nhân tạo được thiết kế bao gồm nhiều lớp, đã đạt được các kết quả vượt trội so với phương pháp học máy truyền thống cho các bài toán nhận dạng ảnh. Mạng học sâu có khả năng tự học từ dữ liệu. Học sâu có rất nhiều ứng dụng trong đó có các ứng dụng nông nghiệp thông minh như các bài toán nhận dạng cây, phân lớp bệnh của cây [2], [3].

Mạng nơ-ron tích chập (CNN) là một thuật toán học sâu mạnh mẽ để phát hiện và phân loại hình ảnh, tự động trích xuất và phân tích các đặc điểm của hình ảnh. Do đó, ứng dụng của CNN đang tăng vọt trong hầu hết các lĩnh vực. Mạng CNN là mạng rất thành công trong nhận dạng, phân loại hình ảnh, các mạng điển hình như AlexNet, GoogleNet, VGG, DenseNet [4] - [6].

Hiện cũng có nhiều nghiên cứu được thực hiện với bài toán phân loại bệnh cây cà chua, mỗi nghiên cứu tiếp cận một cách khác nhau. Trong nghiên cứu [7], mạng AlexNet được sử dụng để trích chọn đặc trưng, sau đó sử dụng bộ phân lớp k láng giềng gần nhất áp dụng trên cơ sở dữ liệu tự thu thập gồm 450 ảnh trên 9 lớp đạt độ chính xác là 76,1%. Đối với cơ sở dữ liệu cây cà chua trong tập PlantVillage, bài báo [8] đề xuất một mạng CNN tự xây dựng đạt độ chính xác 91,2%; bài báo [1] thực hiện trên 4 lớp cây cà chua sử dụng mạng MobileNetV2 đạt độ chính xác 94,34%.

Một số kiến trúc CNN chứa một số lượng lớn các lớp sâu với số lượng tham số cực lớn, chúng cần khả năng tính toán cao để cập nhật các tham số này dẫn đến sự gia tăng độ phức tạp của phân loại. Mục tiêu của nghiên cứu là áp dụng một kiến trúc mạng CNN nhẹ, kết hợp với phương pháp học chuyên giao, lựa chọn các siêu tham số tốt, phân chia tập dữ liệu, cân bằng các lớp dữ liệu để phân lớp các bệnh của cây cà chua mà vẫn đạt độ chính xác cao. Phương pháp sẽ làm giảm đáng kể nhu cầu các nguồn lực tính toán lớn và xây dựng mô hình.

2. Phương pháp nghiên cứu


MobileNet là một kiến trúc học sâu tập trung vào nền tảng di động, nơi tài nguyên tính toán bị hạn chế. Sau đó, một phiên bản cải tiến, được gọi là MobileNet V2 [9] với một số sửa đổi nhỏ so với phiên bản gốc. MobileNet V2 được huấn luyện trên tập dữ liệu ImageNet bao gồm 1,4 triệu hình ảnh với 1000 lớp [9]. Các tham số mạng MobileNet là 4,2 triệu trong khi mạng MobileNet V2 giảm xuống chỉ còn 3,4 triệu tham số. Số tham số này giảm hơn rất nhiều so với các mạng CNN khác như GoogleNet là 6,8 triệu, AlexNet là 60 triệu, và mạng VGG16 là 138 triệu tham số nhưng kết quả phân lớp mạng Mobile V2 có độ chính xác cao hơn các mạng đề cập ở trên khi thực hiện trên cơ sở dữ liệu ImageNet [9], [10]. Do các ưu điểm của phương pháp MobileNet V2, nên trong bài báo này mạng MobileNet V2 được đề xuất, tiến hành các phương pháp tinh chỉnh để phân loại bệnh cây cà chua.

MobileNet V2 là một cải tiến so với MobileNet V1. Cả hai đều vẫn giữ lại lớp tích chập có thể tách rời làm lớp lõi, trong đó số lượng tham số được đào tạo giảm đáng kể so với lớp tích chập đầy đủ. Yêu cầu nhỏ về số lượng tham số cho phép MobileNet V2 phù hợp với các ứng dụng điện thoại di động. Tích chập có thể tách rời được chia thành hai bước riêng biệt, đó là tích

chập theo chiều sâu và tích chập theo điểm.

MobileNet V2 nổi bật với khối “inverted residual” kết hợp “linear bottleneck”: đầu tiên bằng phép mở rộng (áp dụng lớp tích chập 1×1) tăng chiều kênh, sau đó dùng tích chập phân tách theo chiều sâu giúp tính toán hiệu quả, rồi giảm số kênh qua tích chập 1×1 . Kiến trúc MobileNet V2 bao gồm lớp tích chập đầy đủ ban đầu với 32 bộ lọc, tiếp theo là 19 lớp thắt nút cổ chai (residual bottleneck layers), sử dụng ReLU6 làm hàm phi tuyến [9].

Cơ sở dữ liệu bệnh cây cà chua thực nghiệm được trích từ tập cơ sở dữ liệu PlantVillage bao gồm 10 lớp (9 lớp bệnh, 1 lớp khoẻ mạnh) chứa các ảnh lá có nền đơn giản. Tổng bao gồm 18160 ảnh [11], ảnh có kích thước 256×256 . Các lớp dữ liệu với số ảnh tương ứng bao gồm: bệnh héo lá sớm (1000 ảnh), đốm vi khuẩn (2127 ảnh), mốc sương (1909 ảnh), nấm mốc (952 ảnh), đốm lá Septoria (1771 ảnh), nhện ve hai đốm (1676 ảnh), điểm mục tiêu (1404 ảnh), vi rút khảm (373 ảnh), vi rút xoắn lá vàng (5357 ảnh), cây khoẻ mạnh (1591 ảnh). Hình ảnh minh hoạ cho các lớp được trình bày trong Hình 1. Dữ liệu được phân chia thành tập huấn luyện và tập kiểm tra. Dữ liệu đánh giá quá trình huấn luyện (validation) được lấy 20% từ tập dữ liệu huấn luyện. Để đáp ứng yêu cầu đầu vào của mạng MobileNet V2, dữ liệu được chuẩn hóa về kích thước 224×224 .



Hình 1. Ví dụ 10 lớp ảnh tương ảnh bệnh cây cà chua trong cơ sở dữ liệu PlantVillage

Sau đó mạng MobileNet V2 được sử dụng để huấn luyện, sử dụng phương pháp học chuyển giao sử dụng bộ trọng số đã được tiền huấn luyện trên cơ sở dữ liệu lớn ImageNet. Các phương pháp tinh chỉnh được áp dụng để lựa chọn các siêu tham số huấn luyện khác nhau, việc phân chia tập dữ liệu và cân bằng dữ liệu giữa các lớp sẽ được trình bày chi tiết trong phần 3. Độ đo chính xác (accuracy) và độ đo mất mát (Loss) được sử dụng để đo kết quả phân loại.

3. Kết quả nghiên cứu

Trong bài báo này, kết quả thử nghiệm được thực hiện trên CPU Intel core i3-1115 G4 @ 3,0 GHz với RAM 8 GB, đây là một cấu hình phân khúc phổ thông. Thực hiện bằng ngôn ngữ lập trình Python với khung Keras, sử dụng thư viện tensorflow. Tiến hành huấn luyện mạng MobileNet V2 theo các kịch bản khác nhau bằng cách thay đổi các siêu tham số bao gồm bộ tối ưu hóa, kích thước bó (batch size), tốc độ học (learning rate). Các phương pháp này thực hiện khi dữ liệu huấn luyện và dữ liệu kiểm tra được chia theo tỷ lệ 8:2. Tiếp theo là thực nghiệm trên bộ dữ liệu huấn luyện, kiểm tra được phân chia theo các tỷ lệ khác nhau; thực hiện trên dữ liệu cân bằng và cuối cùng tổng hợp các lựa chọn tối ưu. Số epoch thực hiện cho các thực nghiệm là 10. Quá trình thực nghiệm được thực hiện tuần tự, trong đó thiết lập tốt nhất của từng siêu tham số được kiểm tra riêng để tìm ra thiết lập tối ưu.

3.1. Đánh giá các bộ tối ưu hóa

Thực nghiệm tiến hành huấn luyện theo bốn bộ tối ưu hóa khác nhau, cụ thể là Adam, Adagrad, SGD và RMSprop. Tốc độ học được lựa chọn là 0,001, kích thước batch 32. Kết quả đánh giá trên tập kiểm tra được trình bày trong Bảng 1. Trong số bốn bộ tối ưu hóa này, Adam đạt hiệu suất cao nhất với độ chính xác 0,9249, độ mất mát 0,2145. Tiếp theo là RMSprop (Độ chính xác = 0,9208, độ mất mát = 0,2249), SGD (Độ chính xác = 0,9049, độ mất mát = 0,2976) và Adagrad trả về độ chính xác thấp nhất trong việc phân loại bệnh cây cà chua (Độ chính xác = 0,8106, độ mất mát = 0,6671). Các thử nghiệm tiếp theo sẽ lựa chọn bộ tối ưu Adam là bộ tối ưu mặc định.

Bảng 1. Độ chính xác và độ mất mát cho các bộ tối ưu khác nhau

Bộ tối ưu	Độ chính xác	Độ mất mát
Adam	0,9249	0,2145
Adagrad	0,8106	0,6671
SGD	0,9049	0,2976
RMSprop	0,9208	0,2249

3.2. Đánh giá tốc độ học (Learning rate) trên bộ tối ưu Adam

Tốc độ học là một siêu tham số kiểm soát mức độ lỗi gradient sẽ được sử dụng để cập nhật các trọng số hiện tại. Kích thước batch được lựa chọn là 32. Bốn tốc độ học được thử nghiệm là 0,01, 0,001, 0,0001 và 0,00001, kết quả độ chính xác và độ mất mát được hiển thị trong Bảng 2. Tốc độ học 0,001 đạt độ chính xác cao nhất (0,9249) và tỷ lệ mất mát thấp nhất (0,2145) cho thấy tốc độ học cập nhật đủ lớn để nhanh chóng di chuyển về hướng gradient giảm độ mất mát.

Bảng 2. Kết quả thực hiện bộ tối ưu Adam với các tỷ lệ học khác nhau

Tốc độ học	Độ chính xác	Độ mất mát
0,00001	0,6956	1,0854
0,0001	0,8859	0,3732
0,001	0,9249	0,2145
0,01	0,9104	0,4519

3.3. Đánh giá kích thước batch trên bộ tối ưu Adam

Kích thước batch (batch size) là siêu tham số kiểm soát số lượng hình ảnh được đưa vào mạng cho một lần lặp huấn luyện. Nó cho phép phân tích cục bộ một số hình ảnh thay vì một hình ảnh riêng lẻ. Bốn kích thước batch được thực nghiệm bao gồm 16, 32, 64 và 128 với bộ tối ưu Adam, tốc độ học 0,001. Bảng 3 hiển thị độ chính xác phân loại và độ mất mát khi kích thước batch tăng từ 16 lên 128. Hiệu suất tốt nhất đạt được khi kích thước batch 64 được sử dụng với giá trị độ chính xác là 0,9255. Khi kích thước batch tăng từ 16, 32 đến 64, độ chính xác cải thiện rất nhẹ gần như bão hòa, tuy nhiên giảm nhẹ ở kích thước batch là 128 cho thấy mô hình bị giảm khả năng khái quát hóa khi kích thước batch quá lớn. Mặc dù kích thước batch 64 cho độ chính xác cao nhất, nhưng độ mất mát lại thấp nhất (0,2145) tại kích thước batch 32. Khi kích thước batch tăng đến 128, độ mất mát tăng đáng kể cho thấy mô hình học ít hiệu quả hơn và ít nhạy cảm hơn với dữ liệu huấn luyện.

Bảng 3. Kết quả thực hiện bộ tối ưu Adam với các kích thước batch khác nhau

Kích thước batch	Độ chính xác	Độ mất mát
16	0,9249	0,2175
32	0,9249	0,2145
64	0,9255	0,2243
128	0,9205	0,2475

3.4. Chia tỷ lệ dữ liệu huấn luyện và kiểm tra khác nhau

Dữ liệu huấn luyện là tập dữ liệu được sử dụng để huấn luyện mạng MobileNet V2, trong khi dữ liệu kiểm tra là mẫu được sử dụng để đánh giá hiệu suất của mạng đã huấn luyện. Trong bài báo này, sáu cách phân chia giữa dữ liệu huấn luyện và dữ liệu kiểm tra với tỷ lệ dữ liệu huấn

luyện giảm dần, đó là tỷ lệ 9:1, 8:2, 7:3, 6:4, 5:5 và 4:6. Kết quả phân loại trong Bảng 4 cho thấy hiệu suất đạt tốt nhất với tỷ lệ 9:1, độ chính xác 0,9292 và tỷ lệ mất mát là 0,1812. Điều này dễ hiểu vì mô hình được nhiều mẫu hơn, học được đặc trưng tốt hơn. Ngược lại, khi giảm tỉ lệ dữ liệu huấn luyện (ví dụ 5:5 hoặc 4:6), độ chính xác giảm rõ rệt (xuống ~0,915) và độ mất mát đặc biệt tăng cao ở tỉ lệ 4:6 (0,2652), do tập huấn luyện quá nhỏ không đủ đa dạng.

Bảng 4. Kết quả thực hiện trên các tỷ lệ chia dữ liệu khác nhau

Tỷ lệ tập huấn luyện và tập kiểm tra	Độ chính xác	Độ mất mát
9:1	0,9292	0,1812
8:2	0,9249	0,2145
7:3	0,9283	0,2137
6:4	0,9283	0,2182
5:5	0,9151	0,2165
4:6	0,9138	0,2652

3.5. Thực hiện cân bằng dữ liệu

Do dữ liệu gốc về bệnh cây cà chua là không cân bằng, lớp có ít dữ liệu nhất là 373 ảnh trong khi lớp nhiều nhất có 5357 ảnh, dẫn đến mạng phân loại sẽ thiên vị các lớp có nhiều dữ liệu. Nghiên cứu thực nghiệm trên các bộ dữ liệu khác nhau để cho thấy ảnh hưởng của bộ dữ liệu đến hiệu suất hệ thống.

Dữ liệu 1: Dữ liệu gốc ban đầu như mô tả trên

Dữ liệu 2: Giảm số ảnh trong các lớp dữ liệu trong đó mỗi lớp dữ liệu có 373 ảnh, là số ảnh của lớp có dữ liệu cực tiểu.

Dữ liệu 3: Tăng cường dữ liệu các lớp dữ liệu trong đó mỗi lớp dữ liệu có 5357 ảnh, là số ảnh của lớp có dữ liệu cực đại.

Dữ liệu 4: Tăng cường dữ liệu với 3 lớp ít ảnh (vì rút khám: 373 ảnh, nấm mốc: 952 ảnh, bệnh héo lá sớm: 1000 ảnh), và xoá bớt dữ liệu với lớp nhiều ảnh nhất (vì rút xoắn lá vàng: 5357 ảnh), dữ liệu thu được giữa các lớp nằm trong khoảng 1400 đến 2357.

Việc tăng cường dữ liệu thực hiện các phép như phép lấy gương, xoay ảnh, tịnh tiến, phép biến dạng, phóng to thu nhỏ. Thực nghiệm tiến hành trên bộ tối ưu Adam, kích thước bó: 32, tốc độ học: 0,001, tỷ lệ phân chia dữ liệu là 8:2. Các kết quả thực nghiệm được thể hiện ở trên Bảng 5. Kết quả tốt nhất đạt được trên dữ liệu 4 với độ chính xác là 0,9469 và độ mất mát là 0,1485; tại đó, dữ liệu các lớp được cân bằng với số lượng từ 1400 đến 2357 ảnh dữ liệu nằm trong khoảng ở giữa, có 4 lớp thay đổi dữ liệu, 6 lớp dữ liệu giữ nguyên.

Bảng 5. Kết quả thực hiện trên các tập dữ liệu cân bằng khác nhau

Tập dữ liệu	Độ chính xác	Độ mất mát
Dữ liệu 1	0,9249	0,2145
Dữ liệu 2	0,8720	0,4123
Dữ liệu 3	0,9023	0,2805
Dữ liệu 4	0,9469	0,1485

Chiến lược cân bằng dữ liệu 4 đạt hiệu suất tốt nhất vì nó điều chỉnh số mẫu mỗi lớp về khoảng 1400–2357, vừa giảm thiểu thiên lệch lớp, vừa giữ lại đa dạng đặc trưng của các lớp ban đầu; các phép tăng cường dữ liệu giúp bổ sung tính biến đổi cho những lớp ít ảnh, từ đó nâng cao khả năng khái quát hóa và ổn định hội tụ của mô hình.

3.6. Tổng hợp các siêu tham số, kỹ thuật tối ưu

Từ các kết quả thực nghiệm đơn lẻ trên, thực nghiệm tổng hợp đã được áp dụng với các lựa chọn tối ưu như sau: áp dụng trên dữ liệu 4, chia theo tỷ lệ huấn luyện và dữ liệu kiểm tra là 9:1, bộ tối ưu Adam, tốc độ học 0,001, kích thước bó: 64, số epoch là 10. Việc lựa chọn kích thước bó bằng 64 được đưa ra dựa trên kết quả thực nghiệm đánh giá kích thước bó với bộ tối ưu Adam,

trong đó kích thước bó = 64 đạt độ chính xác phân loại cao nhất (0,9255) so với các giá trị 16, 32 và 128. Mặc dù tổn thất huấn luyện tại bó bằng 16 và 32 thấp hơn đôi chút (0,2145 so với 0,2243), kích thước bó 64 vẫn cho thấy sự cân bằng tối ưu giữa độ ổn định của gradient và khả năng khái quát hóa, đồng thời tận dụng hiệu quả khả năng tính toán song song của GPU và giảm thiểu hiện tượng over-fitting so với các bó nhỏ. Do đó, kích thước bó = 64 không chỉ tối ưu về mặt độ chính xác trên tập kiểm tra mà còn đảm bảo tính ổn định và hiệu suất huấn luyện tổng thể. Trên cấu hình này, MobileNet V2 đạt được độ chính xác **0,9573**, độ mất mát **0,1330** cải thiện đáng kể so với các thiết lập tối ưu theo từng tham số riêng lẻ.

Confusion Matrix – MobileNetV2

Đốm vi khuẩn	203	0	1	0	5	1	1	2	0	0
Héo lá sớm	1	191	1	6	1	0	0	0	0	0
Mốc sương	0	0	185	0	1	1	2	1	0	1
Nấm mốc	0	3	0	183	0	0	0	0	5	0
Đốm lá Septoria	2	0	1	0	170	2	3	0	0	0
Nhện ve hai đốm	0	0	0	0	0	163	2	2	0	1
Điểm mục tiêu	2	0	0	0	10	8	117	1	0	3
Ví rút xoắn lá	1	0	1	0	0	2	0	232	0	0
Ví rút khảm	0	0	0	1	0	0	0	0	149	0
Khoẻ mạnh	0	0	0	0	0	2	1	0	0	157

Nhãn dự báo

Hình 2. Bảng ma trận nhầm lẫn

Bảng ma trận nhầm lẫn (Hình 2) thu được trên tập kiểm tra cho thấy mô hình MobileNet V2 đạt độ chính xác phân loại tổng thể cao đối với hầu hết các lớp, điển hình như Nhện ve hai đốm (163/168 mẫu), Ví rút xoắn lá (232/236 mẫu), Ví rút khảm (149/150 mẫu) và Khoẻ mạnh (157/160 mẫu). Tuy nhiên, các lớp có biểu hiện triệu chứng hình ảnh tương đồng với các lớp khác như Điểm mục tiêu, Đốm lá Septoria, Héo lá sớm và Đốm vi khuẩn lại thể hiện tỷ lệ nhầm lẫn tương đối cao, cụ thể Điểm mục tiêu chỉ đạt 117/141 mẫu phân loại đúng, trong đó 10 mẫu bị nhận nhầm thành Đốm lá Septoria và 8 mẫu thành Nhện ve hai đốm; tương tự, 5 mẫu Đốm vi khuẩn bị phân loại nhầm sang các lớp Đốm lá Septoria và 1 mẫu thành Điểm mục tiêu, trong khi 6 mẫu Héo lá sớm bị gán nhầm sai thành Nấm mốc. Kết quả này cho thấy MobileNet V2 có khả năng trích xuất đặc trưng tốt với các lớp dễ phân biệt nhưng gặp khó khăn khi đối mặt với những bệnh lý có triệu chứng thị giác gần giống nhau.

Mặc dù nghiên cứu đã chứng minh MobileNet V2 đạt được độ chính xác cao trên tập dữ liệu PlantVillage, tuy nhiên, bộ dữ liệu PlantVillage chủ yếu gồm ảnh chụp trong điều kiện phòng thí nghiệm hoặc trên nền đơn giản, chưa phản ánh đầy đủ sự đa dạng về môi trường thực địa (ánh sáng thay đổi, nền phức tạp, góc chụp khác nhau), nên khả năng khái quát của mô hình khi triển khai ngoài thực tế sẽ gặp hạn chế. Do vậy, hướng phát triển của nghiên cứu trong tương lai là mở rộng tập dữ liệu thực địa.

4. Kết luận

Trong nghiên cứu này, mạng MobileNet V2 đã được áp dụng với nhiều phương pháp tinh chỉnh, kỹ thuật khác nhau để phân loại chín loại bệnh cây cà chua và một lớp khỏe mạnh sử dụng dữ liệu PlantVillage. Thông qua loạt thực nghiệm tuần tự về bộ tối ưu, tốc độ học, kích thước bỏ, tỷ lệ dữ liệu huấn luyện, dữ liệu kiểm tra và chiến lược cân bằng dữ liệu để thấy rõ ảnh hưởng của các tham số đến kết quả phân loại bệnh. Mô hình đạt độ chính xác cao nhất là 0,9573 khi kết hợp các siêu tham số tối ưu, kỹ thuật ở các thực nghiệm này. Kết quả này cho thấy rõ tầm quan trọng của việc tinh chỉnh tham số đồng thời với cân bằng dữ liệu, chia tỷ lệ dữ liệu để khai thác tối đa khả năng của mạng CNN. Nghiên cứu mở ra hướng ứng dụng hệ thống giám sát bệnh cà chua tự động trên thiết bị di động với chi phí tính toán thấp và độ chính xác cao.

TÀI LIỆU THAM KHẢO/REFERENCES

- [1] S. Z. M. Zaki, M. A. Zulkifley, M. M. Stofa, N. A. M. Kamari, and N. A. Mohamed, "Classification of tomato leaf diseases using MobileNet v2," *IJ-AI*, vol. 9, no. 2, pp. 290-296, Jun. 2020, doi: 10.11591/ijai.v9.i2.pp290-296.
- [2] J. Yao, S. N. Tran, S. Garg, and S. Sawyer, "Deep Learning for Plant Identification and Disease Classification from Leaf Images: Multi-prediction Approaches," *arXiv*: arXiv:2310.16273, Oct. 25, 2023, doi: 10.48550/arXiv.2310.16273.
- [3] L. Li, S. Zhang, and B. Wang, "Plant Disease Detection and Classification by Deep Learning—A Review," *IEEE Access*, vol. 9, pp. 56683–56698, 2021, doi: 10.1109/ACCESS.2021.3069646.
- [4] C. Szegedy *et al.*, "Going deeper with convolutions," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA: IEEE, Jun. 2015, pp. 1–9, doi: 10.1109/CVPR.2015.7298594.
- [5] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, Jun. 2016, pp. 770–778, doi: 10.1109/CVPR.2016.90.
- [6] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Commun. ACM*, vol. 60, no. 6, pp. 84–90, May 2017, doi: 10.1145/3065386.
- [7] A. Batool, S. B. Hyder, A. Rahim, N. Waheed, M. A. Asghar, and Fawad, "Classification and Identification of Tomato Leaf Disease Using Deep Neural Network," in *2020 International Conference on Engineering and Emerging Technologies (ICEET)*, Lahore, Pakistan: IEEE, Feb. 2020, pp. 1–6, doi: 10.1109/ICEET48479.2020.9048207.
- [8] M. Agarwal, A. Singh, S. Arjaria, A. Sinha, and S. Gupta, "ToLeD: Tomato Leaf Disease Detection using Convolution Neural Network," *Procedia Computer Science*, vol. 167, pp. 293–301, 2020, doi: 10.1016/j.procs.2020.03.225.
- [9] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT: IEEE, Jun. 2018, pp. 4510–4520, doi: 10.1109/CVPR.2018.00474.
- [10] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," *arXiv*: arXiv:1704.04861, Apr. 17, 2017, doi: 10.48550/arXiv.1704.04861.
- [11] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using Deep Learning for Image-Based Plant Disease Detection," *Front. Plant Sci.*, vol. 7, pp. 1–10, Sep. 2016, doi: 10.3389/fpls.2016.01419.