

# PHÂN LOẠI BỆNH PHẤN TRẮNG VÀ BỆNH SƯƠNG MAI TRÊN CÂY DƯA CHUỘT VỚI MÔ HÌNH RESNET KẾT HỢP

## CLASSIFICATION OF POWDERY MILDEW AND DOWNY MILDEW ON CUCUMBER BY COMBINING RESNET MODEL

Ngô Quang Ước<sup>1,2</sup>, Ngô Trí Dương<sup>2</sup>, Bùi Đăng Thành<sup>1\*</sup>

<sup>1</sup>Trường Đại học Bách khoa Hà Nội

<sup>2</sup>Học viện Nông nghiệp Việt Nam

\*Tác giả liên hệ: thanh.buidang@hust.edu.vn

(Nhận bài: 08/12/2021; Chấp nhận đăng: 24/3/2022)

**Tóm tắt** - Dịch bệnh trên cây trồng ảnh hưởng lớn đến năng suất và chất lượng sản phẩm. Việc phát hiện bệnh kịp thời và chính xác sẽ giúp sử dụng thuốc bảo vệ thực vật một cách khoa học và hợp lý, nâng cao năng suất cây trồng và bảo vệ môi trường. Tuy nhiên, việc phát hiện bệnh trong môi trường thực tế gặp nhiều khó khăn do nhiễu của nền và ánh sáng. Bài viết này nhóm tác giả đã sử dụng mô hình kết hợp ResNet 50 và ResNet 152 để phân loại bệnh trên cây dưa chuột với bộ dữ liệu nhiễu nhiễu. Kết quả cho thấy, mô hình đề xuất kết hợp ResNet 50 và ResNet 152 có độ chính xác là 98% cao hơn từ 0,83% đến 6,08% so với các mô hình khác được đề cập trong bài viết. Với kết quả đạt được mô hình sẽ được áp dụng cho hệ thống phân loại bệnh trên cây dưa chuột trong môi trường thực.

**Từ khóa** - CNN; ResNet; bệnh phấn trắng; bệnh sương mai; bệnh trên cây dưa chuột.

**Abstract** - Diseases on crops will greatly affect the yield and quality of products. Timely and accurate detection of diseases will help to achieve scientific and rational use of pesticides, improve crop yields and protect the environment. However, detecting the disease in the real environment is difficult due to background and light noise. In this article, we used the combined ResNet 50 and ResNet 152 model to classify diseases on cucumber plants with complex datasets similar to the real environment. The results show that the proposed model combining ResNet 50 and ResNet 152 has an accuracy of 98%, which is higher from 0.83% to 6.08% than other models mentioned in the article. With the achieved results, the model will be applied to the disease classification system on cucumber plants in the real environment.

**Key words** - CNN; ResNet; powdery mildew; downy mildew; cucumber diseases.

### 1. Đặt vấn đề

Dưa chuột (*Cucumis sativus* L.) là một loại rau phổ biến trên thế giới và nó rất dễ canh tác trong môi trường nhà lưới [1, 2]. Dưa chuột cũng là loại cây có giá trị kinh tế cao và có nhiều lợi ích cho con người [3]. Sâu bệnh là một trong những nguyên nhân làm giảm năng suất của cây trồng [4, 5]. Để giảm tác hại của sâu bệnh thì thuốc bảo vệ thực vật được sử dụng dẫn đến sự lo ngại về an toàn thực phẩm [6, 7]. Ở cây dưa chuột, bệnh phấn trắng và bệnh sương mai là hai bệnh phổ biến trên loại cây này [8-10], phát hiện sớm và chính xác để cảnh báo nhằm có những giải pháp xử lý sớm sẽ làm giảm lượng thuốc bảo vệ thực vật và tăng năng suất là điều hết sức cần thiết. Đã có nhiều tác giả sử dụng các thuật toán khác nhau để phân vùng và phân loại các loại bệnh trên cây này với độ chính xác tương đối cao. Trong công trình nghiên cứu [11], các tác giả sử dụng các kỹ thuật xử lý ảnh kết hợp với thuật toán Support Vector Machines (SVM) để phân loại bệnh trên cây dưa chuột cho độ chính xác đạt 91,48%. Hay là sự kết hợp hai mô hình DeepLabV3 và U-Net để phân vùng và phân loại bệnh trên cây này của Wang và cộng sự cũng đạt được độ chính xác tương ứng là 93,27% và 92,85% [12]. Đặc biệt, kể đến mô hình của Khan và cộng sự đã kết hợp xử lý ảnh, mô hình VGG và SVM để phân loại bệnh trên cây dưa chuột đã cho độ chính xác lên đến 98,08% [13]. Một số công trình khác [14-18] đã sử dụng các thuật toán khác nhau để phân vùng và phân loại một số bệnh trên cây dưa chuột, các công trình này đều cho độ chính xác dưới 94%.

Một điểm nhận thấy là đa số các công trình này có bộ dữ liệu đào tạo, xác thực và kiểm tra đều ít nhiễu, hoặc đã xử lý hết nhiễu. Như trong công trình [13] có độ chính xác cao (98,08%) nhưng nhiễu trong tập dữ liệu lại ít, điều này sẽ khó áp dụng được vào môi trường thực tế khi có nhiễu nhiễu nền và ánh sáng. Trong bài viết này, nhóm tác giả tập trung xây dựng một bộ dữ liệu của hai loại bệnh phổ biến trên cây dưa chuột là bệnh phấn trắng, bệnh sương mai và bình thường của cây dưa chuột trong môi trường tự nhiên có nền nhiễu đa dạng, có nhiễu nhiễu ánh sáng từ yếu đến mạnh và triệu chứng bệnh từ ít đến nhiều, từ đó đề xuất một mô hình kết hợp để đạt được một mô hình tốt nhằm ứng dụng cho thực tế trong sản xuất cây trồng này.

### 2. Kết quả nghiên cứu và thảo luận

#### 2.1. Mô hình ResNet

Năm 2016, He và cộng sự [19] đã đề xuất một mạng học sâu, được gọi là ResNet. Ở thuật toán này, lớp đầu tiên được sử dụng là lớp tích chập 7x7, các lớp sau là các khối residual xếp chồng lên nhau của các lớp tích chập 3x3, số lượng bộ lọc được tăng gấp đôi và sử dụng bước nhảy (stride) là 2. Các mô hình của ResNet không có các lớp kết nối đầy đủ ở cuối. Chúng có các độ sâu khác nhau là 34, 50, 101 và 152. Đối với cấu trúc có các lớp tích chập lớn hơn 50, họ đã sử dụng lớp bottleneck để giảm kích thước và nâng cao hiệu quả. Thiết kế bottleneck của chúng bao gồm lớp tích chập 1x1, 3x3 và 1x1. Các cấu trúc của mô hình thuật toán ResNet được trình bày trong Bảng 1.

<sup>1</sup> Hanoi University of Science and Technology (Ngo Quang Uoc, Bui Dang Thanh)

<sup>2</sup> Vietnam National University of Agriculture (Ngo Quang Uoc, Ngo Tri Duong)


**Bảng 1.** Cấu trúc các mô hình thuật toán ResNet [19]

Layer name	Output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112x112	7x7,64, stride 2				
conv2_x	56x56	3x3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28x28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14x14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7x7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1x1	Average pool, 1000-d fc, softmax				
FLOPS		1.8x10 <sup>9</sup>	3.6x10 <sup>9</sup>	3.8x10 <sup>9</sup>	7.6x10 <sup>9</sup>	11.3x10 <sup>9</sup>

**2.2. Thu thập và xử lý dữ liệu**

Bộ dữ liệu được nhóm tác giả thu thập từ môi trường có độ nhiễu khác nhau bằng các thiết bị máy ảnh, điện thoại với độ phân giải khác nhau. Dữ liệu gồm 10744 ảnh cho ba lớp: Bình thường, bệnh phấn trắng và bệnh sương mai. Bộ dữ liệu được phân ngẫu nhiên với kỹ thuật random\_split

thành 80% cho đào tạo và 20% cho xác thực. Một bộ dữ liệu khác dùng cho kiểm tra được chuẩn bị với mỗi loại có 400 ảnh để đánh giá mô hình. Hình 1 là mô tả khu vực và quá trình thu thập bộ dữ liệu, ở Hình 2 và Hình 3 là một số hình ảnh của các tập dữ liệu đào tạo, xác thực và kiểm tra, Hình 4 là phân bố dữ liệu nghiên cứu.



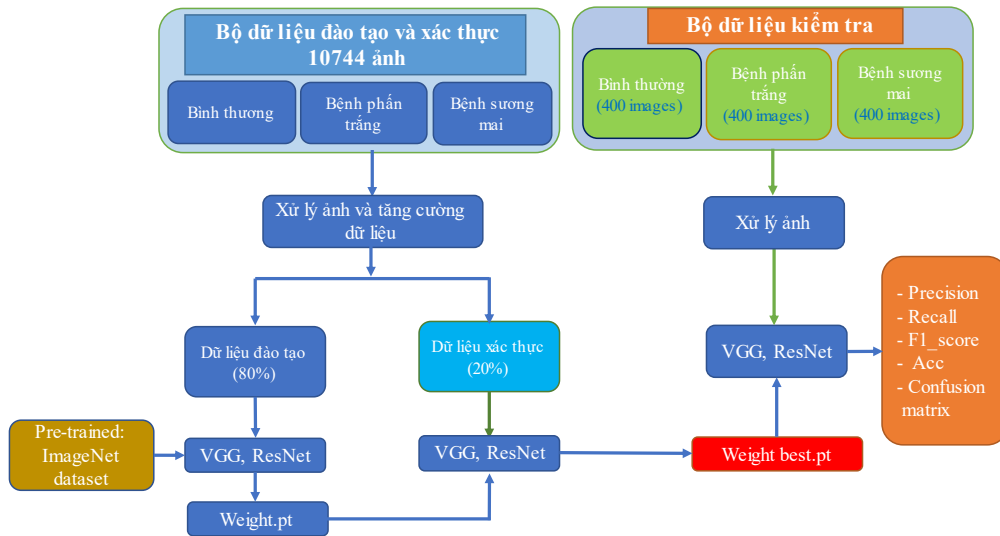
**Hình 1.** Quá trình thu thập các bộ dữ liệu



**Hình 2.** Một số mẫu hình ảnh của tập dữ liệu đào tạo và xác thực




**Hình 3.** Một số mẫu hình ảnh của tập dữ liệu kiểm tra



Hình 4. Lưu đồ phân bố dữ liệu cho quá trình đào tạo, xác thực và kiểm tra của các mô hình trong nghiên cứu

Xử lý ảnh: Hình ảnh trong các bộ dữ liệu đào tạo, xác thực và kiểm tra có kích thước độ phân giải khác nhau, vì vậy trước khi đào tạo, xác thực và kiểm tra, dữ liệu được thay đổi kích thước và chuẩn hóa dữ liệu bởi các kỹ thuật là: Resize (224), CenterCrop (224), ToTensor (), and Normalize (mean = [0,485, 0,456, 0,406], std = [0,229, 0,224, 0,225]) [21]. Các kỹ thuật tăng cường ảnh đã được nhóm tác giả sử dụng trong nghiên cứu này là xoay ảnh, lật ngang ảnh và cắt ảnh được thể hiện trên Hình 5.



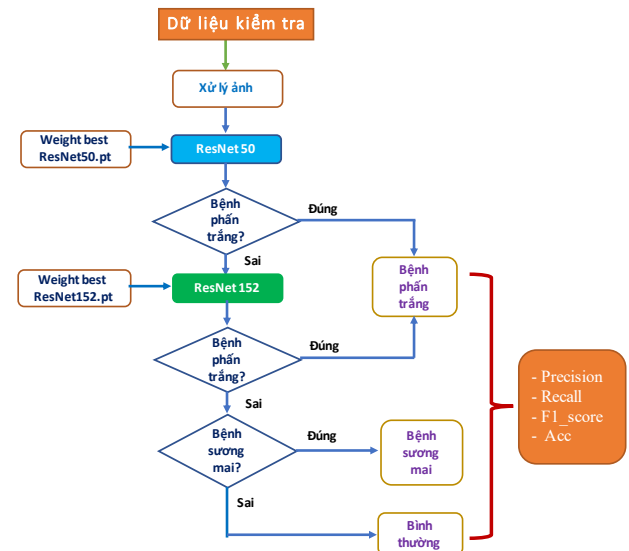
Hình 5. Các kỹ thuật tăng cường ảnh được sử dụng

Để giảm quá trình đào tạo cho các mô hình trong nghiên cứu, trọng số ban đầu (Pre-trained) được sử dụng là các mô hình được đào tạo bởi bộ dữ liệu lớn ImageNet.

### 2.3. Mô hình đề xuất

Trên Hình 6, biểu diễn mô hình thuật toán đề xuất của nhóm tác giả, nó được kết hợp của 2 mô hình ResNet 50 và ResNet 152. Dữ liệu vào sẽ xử lý và chuẩn hóa để cho qua mô hình ResNet 50 trước, nếu nhận ra đó là bệnh phấn trắng thì sẽ kết thúc, nếu ResNet 50 không phân loại ra là

bệnh phấn trắng thì sẽ tiếp tục qua mô hình ResNet 152 và thực hiện phân loại bệnh phấn trắng, bệnh sương mai và bình thường theo mô hình ResNet 152.



Hình 6. Lưu đồ mô hình đề xuất kết hợp 2 mô hình ResNet 50 và ResNet 152

### 2.4. Phương pháp đánh giá

Để xác định trọng số tốt 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, Acc là độ chính xác của mô hình.

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

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


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

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

Các mô hình được đào tạo, xác thực và kiểm tra trên cấu hình phần cứng CPU Intel XEON, GPU GTX 1060 6GB, Ram 64 GB và hệ điều hành Windows 10.

**2.5. Kết quả**

Với bộ dữ liệu có tổng số 10744 ảnh của ba lớp, đã sử dụng các kỹ thuật tăng cường ảnh, xử lý và chuẩn hóa bộ dữ liệu, chia bộ dữ liệu thành 80% đào tạo và 20% xác thực, nhóm tác giả đã tiến hành đào tạo với các mô hình VGG [20] (VGG 11, VGG 13, VGG 16, VGG 19), ResNet 18, ResNet 34, Resnet 50, ResNet 101 và ResNet 152. Kết quả đào tạo cho độ chính xác trên tập dữ liệu xác thực của các mô hình nghiên cứu này được thể hiện trên Hình 7. Trên Hình 7 cho thấy, các thuật toán của ResNet đều có kết quả tốt hơn so với VGG. Với bộ dữ liệu xác thực thì mô hình ResNet 34 cho độ chính xác lớn nhất là 98,98%, và thấp nhất là VGG 11 chỉ đạt 97,49%. Các mô hình ResNet 50, và ResNet 152 cho độ chính xác tương ứng là 98,6% và 98,28%.



**Hình 7.** Kết quả độ chính xác của các mô hình đào tạo trên bộ dữ liệu xác thực

Với kết quả đào tạo được trên các mô hình của VGG và ResNet, nhóm tác giả tiến hành đánh giá trên tập dữ liệu kiểm tra được chuẩn bị với mỗi lớp 400 ảnh. Kết quả thể hiện precision, recall, F1-score, và Accuracy của các mô hình VGG, ResNet và mô hình đề xuất kết hợp ResNet 50 + ResNet 152 được thể hiện trên Bảng 3.

Trên Hình 8, biểu diễn kết quả một số ảnh bị phân loại nhầm lẫn khi sử dụng mô hình đề xuất của nhóm tác giả (ResNet 50+ResNet 152). Kết quả cho thấy, các hình ảnh bị nhầm lẫn có mức độ nhiễu ánh sáng lớn, dễ bị nhầm lẫn

ngay cả mắt thường, một số thì chất lượng ảnh không tốt nên làm cho quá trình phân loại cũng dễ nhầm lẫn.

**Bảng 3.** Kết quả đánh giá các mô hình với bộ dữ liệu kiểm tra

Mô hình	Lớp	Precision (%)	Recall (%)	F1-score (%)	Acc (%)
VGG 11	Bình thường	94,75	91,77	93,23	94,83
	Bệnh phấn trắng	91,75	97,35	94,47	
	Bệnh sương mai	98,00	95,61	96,79	
VGG 13	Bình thường	89,50	91,79	90,63	91,92
	Bệnh phấn trắng	87,75	98,32	92,73	
	Bệnh sương mai	98,50	86,98	92,38	
VGG 16	Bình thường	93,75	90,14	91,91	92,83
	Bệnh phấn trắng	92,25	96,85	94,49	
	Bệnh sương mai	92,50	91,81	92,15	
VGG 19	Bình thường	96,50	91,25	93,80	94,50
	Bệnh phấn trắng	93,50	94,44	93,97	
	Bệnh sương mai	93,50	98,16	95,77	
ResNet 18	Bình thường	96,50	93,46	94,96	96,00
	Bệnh phấn trắng	96,50	97,72	97,11	
	Bệnh sương mai	95,00	96,94	95,96	
ResNet 34	Bình thường	93,00	98,15	95,51	96,33
	Bệnh phấn trắng	96,75	98,22	97,48	
	Bệnh sương mai	99,25	92,97	96,01	
ResNet 50	Bình thường	93,50	95,90	94,68	<b>96,33</b>
	Bệnh phấn trắng	97,50	98,48	97,99	
	Bệnh sương mai	98,00	94,69	96,31	
ResNet 101	Bình thường	95,00	92,46	93,71	94,83
	Bệnh phấn trắng	96,75	95,79	96,27	
	Bệnh sương mai	92,75	96,36	94,52	
ResNet 152	Bình thường	<b>97,25</b>	96,29	96,77	<b>97,17</b>
	Bệnh phấn trắng	95,75	<b>98,97</b>	97,33	
	Bệnh sương mai	<b>98,50</b>	96,33	97,40	
Proposed method (ResNet 50 + ResNet 152)	Bình thường	<b>96,75</b>	97,48	97,11	<b>98,00</b>
	Bệnh phấn trắng	99,00	<b>98,26</b>	98,63	
	Bệnh sương mai	<b>98,25</b>	98,25	98,25	




Thực tế: Bệnh phấn trắng  
Dự đoán: Bình thường



Thực tế: Bình thường  
Dự đoán: Bệnh phấn trắng



Thực tế: Bình thường  
Dự đoán: Bệnh phấn trắng



Thực tế: Bình thường  
Dự đoán: Bệnh sương mai




Thực tế: Bình thường  
Dự đoán: Bệnh sương mai



Thực tế: Bệnh sương mai  
Dự đoán: Bình thường



Thực tế: Bệnh sương mai  
Dự đoán: Bình thường



Thực tế: Bệnh sương mai  
Dự đoán: Bệnh phấn trắng

**Hình 8.** Kết quả một số hình ảnh bị phân loại nhầm lẫn giữa các lớp của mô hình đề xuất

Trong Bảng 3, thể hiện kết quả đánh giá các mô hình VGG, ResNet và model kết hợp ResNet 50+ResNet 152 mà nhóm tác giả đề xuất. Qua Bảng 3 cho thấy, phương pháp đề xuất đã cho độ chính xác là 98% cao hơn so với ResNet 152 và ResNet 50 lần lượt là 0,83% và 1,67% và cao hơn các mô hình VGG và các ResNet còn lại; Precision, recall và F1-score của các lớp gần như đều cao hơn tất cả các mô hình được so sánh. Chỉ có precision ở lớp bình thường, lớp bệnh sương mai và recall ở lớp bệnh phấn trắng thấp hơn so với model ResNet 152 một ít. Nếu lấy trung bình thì các precision, recall và F1-score của mô hình đề xuất đều cao hơn tất cả các mô hình còn lại.

### 3. Bàn luận

Việc phân loại bệnh trong môi trường tự nhiên hết sức là khó khăn, do ảnh hưởng của nhiều môi trường, nhiều nền phức tạp sẽ làm cho độ chính xác của các mô hình đào tạo giảm; trong các bài toán phân loại bệnh trên cây dưa chuột của một số tác giả cho thấy các bộ dữ liệu trông khá là sạch nhiễu, không thực sự giống với môi trường sản xuất khi thiết bị vận hành chụp ảnh được, điều này sẽ làm giảm độ chính xác khi đưa vào ứng dụng cho môi trường sản xuất. Các kết quả thu được từ các mô hình trong các nghiên cứu [11-12, 14-18] chỉ đạt được độ chính xác trung bình dưới 93,5%, đặc biệt trong bài [13] với việc ứng dụng thuật toán VGG, SVM kết quả cho độ chính xác nhận ra vùng bệnh là 98,08%, tuy nhiên nhận thấy bộ dữ liệu ảnh được sử dụng cho bài toán này đã được xử lý, không phức tạp nhiễu. Với bộ dữ liệu nhiễu nhiễu và trong môi trường thực được nhóm tác giả thu thập, có thể thuật toán sẽ khó đạt được độ chính xác như đã trình bày. Bằng việc kết hợp thuật toán ResNet 50 và ResNet 152 nhóm tác giả đã có được mô hình đạt độ chính xác trên bộ dữ liệu kiểm tra là 98%, cao hơn mô hình riêng lẻ ResNet 50 và ResNet 152 cũng như các mô hình VGG và ResNet còn lại (Bảng 3). Kết quả đạt được từ mô hình đề xuất của nhóm nghiên cứu sẽ có tính ứng dụng cao trong thực tế để phân loại bệnh phấn trắng, bệnh sương mai và bệnh thương trên cây dưa chuột.

### 4. Kết luận

Với bộ dữ liệu bệnh phấn trắng, bệnh sương mai và bệnh thương được thu thập trong môi trường phức tạp, nhiễu nhiễu. Nhóm tác giả đã đề xuất được mô hình kết hợp ResNet 50 và ResNet 152 đạt được độ chính xác tốt (98%) hơn so với các mô hình được đề cập trong bài viết. Với kết quả đạt được, mô hình đề xuất sẽ có ứng dụng cao cho phân loại bệnh phấn trắng, bệnh sương mai và bệnh thương trong quá trình sản xuất dưa chuột.

### TÀI LIỆU THAM KHẢO

[1] Abdullah Alsaedi, Hassan El-Ramady, Tarek Alshaal, Mohamed El-Garawany, Nevien Elhawat, Awadh Al-Otaibi, "Silica nanoparticles boost growth and productivity of cucumber under water deficit and salinity stresses by balancing nutrients uptake", *Plant Physiology and Biochemistry* 139, 2019, pp. 1–10.

[2] E.V. Maas, G.J. Hoffman, "Crop salt tolerance – current assessment", *J. Irrig. And Drainage Div. ASCE*, 103 (IR2), 1977, pp. 115-134.

[3] Gulzar Ahmad Nayik, Amir Gull, *Antioxidants in Vegetables and Nuts – Properties and Health Benefits*. ISBN 978-981-15-7469-6 ISBN 978-981-15-7470-2, (eBook) <https://doi.org/10.1007/978-981-15-7470-2>, Springer Nature Singapore Pte Ltd. Pp. 333-340, 2020

[4] OERKE, E.-C. "Crop losses to pests", *The Journal of Agricultural Science*, 2006, 144.1: 31-43.

[5] FRIED, Guillaume, et al, "Decreases in crop production by non-native weeds, pests, and pathogens". In: *Impact of biological invasions on ecosystem services*. Springer, Cham, 2017. p. 83-101.

[6] OMARI, Rose; FREMPONG, Godfred K.; ARTHUR, Winifred, "Public perceptions and worry about food safety hazards and risks in Ghana", *Food Control*, 2018, 93: 76-82.

[7] HA, Thanh Mai; SHAKUR, Shamim; DO, Kim Hang Pham, "Risk perception and its impact on vegetable consumption: A case study from Hanoi, Vietnam", *Journal of Cleaner Production*, 2020, 271: 122793.

[8] A. Berdugo, R. Zito, S. Paulus and A.-K. Mahlein (2014), "Fusion of sensor data for the detection and differentiation of plant diseases in cucumber", *Plant Pathology*, 2014, 63, 1344–1356

[9] Wang H, Jiang YP, Yu HJ et al., "Light quality affects incidence of powdery mildew, expression of defence-related genes and associated metabolism in cucumber plants", *European Journal of Plant Pathology*, 2010, 127,125–35.

[10] Watson A, Napier T, "Disease of cucurbit vegetables", *Primefacts*, 2009, 832:1–6, [https://www.dpi.nsw.gov.au/\\_data/assets/pdf\\_file/0003/290244/diseases-of-cucurbit-vegetables.pdf](https://www.dpi.nsw.gov.au/_data/assets/pdf_file/0003/290244/diseases-of-cucurbit-vegetables.pdf).

[11] Shanwen Zhang, Yihai Zhu, Zhuhong You, Xiaowei Wu, "Fusion of super-pixel, expectation maximization and PHOG for recognizing cucumber diseases", *Computers and Electronics in Agriculture*, 2017, 140: 338-347.

[12] WANG, Chunshan, et al, "A cucumber leaf disease severity classification method based on the fusion of DeepLabV3+ and U-Net", *Computers and Electronics in Agriculture*, 2021, 189: 106373.

[13] KHAN, Muhammad Attique, et al, "An automated system for cucumber leaf diseased spot detection and classification using improved saliency method and deep features selection", *Multimedia Tools and Applications*, 2020, 79.25: 18627-18656.

[14] ZHOU, Bingyu, et al, "Research on cucumber downy mildew detection system based on SVM classification algorithm", In: *3rd Int'l Conf on Mat, Mech and Manu Eng*. 2015.

[15] MA, Juncheng, et al, "A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network", *Computers and electronics in agriculture*, 2018, 154: 18-24.

[16] ZHANG, Shanwen; WANG, Zhen, "Cucumber disease recognition based on Global-Local Singular value decomposition", *Neurocomputing*, 2016, 205: 341-348.

[17] ZHANG, Shanwen, et al, "Leaf image based cucumber disease recognition using sparse representation classification", *Computers and electronics in agriculture*, 2017, 134: 135-141.

[18] PAWAR, Pooja; TURKAR, Varsha; PATIL, Pravin, "Cucumber disease detection using artificial neural network", In: *2016 International Conference on Inventive Computation Technologies (ICICT)*. IEEE, 2016, p. 1-5.

[19] HE, Kaiming, et al. "Deep residual learning for image recognition", In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, p. 770-778.

[20] SIMONYAN, Karen; ZISSERMAN, Andrew, "Very deep convolutional networks for large-scale image recognition", *arXiv preprint arXiv:1409.1556*, 2014.

[21] Pytorch, *Models and pre-trained weights*, [Online] <https://pytorch.org/vision/stable/models.html>.