

# Nghiên cứu phương pháp phát hiện một số sâu bệnh trên lúa sử dụng đặc trưng SIFT

Nguyễn Ngọc Tú<sup>1</sup>, Bùi Thị Thanh Phương<sup>1</sup>, Lê Hoàng Nam<sup>1</sup>, Ngô Nam Thịnh<sup>2</sup>

<sup>1</sup>Viện Ứng dụng Công nghệ

<sup>2</sup>Trung tâm Giống cây trồng Sóc Trăng

Ngày nhận bài 19/10/2018; ngày chuyển phản biện 23/10/2018; ngày nhận phản biện 26/11/2018; ngày chấp nhận đăng 10/12/2018

## Tóm tắt:

Sinh trưởng và phát triển của cây trồng nông nghiệp phụ thuộc rất nhiều yếu tố như giống, chế độ dinh dưỡng, điều kiện thời tiết..., trong đó yếu tố sâu bệnh tác động trực tiếp đến năng suất và có khả năng lây lan trên diện rộng. Đối với lúa, một loại cây trồng chủ lực của Việt Nam, đóng vai trò quan trọng trong an ninh lương thực và xuất khẩu, mặc dù quy trình chăm sóc - phòng trừ sâu bệnh được tuân thủ một cách nghiêm ngặt, nhưng vẫn không thể kiểm soát hoàn toàn các mầm mống của sâu bệnh. Với mô hình canh tác trên diện tích lớn, sử dụng mắt người rất khó để phát hiện các dấu hiệu của sâu bệnh trong những giai đoạn phát triển ban đầu. Trong bài báo này, các tác giả nghiên cứu đề xuất mô hình sử dụng trích chọn đặc trưng SIFT (Scale-Invariant Feature Transform) và phân lớp SVM (Support Vector Machine) nhằm xử lý các hình ảnh trên lá của cây lúa. Mô hình này có thể phát hiện và nhận biết 4 loại sâu bệnh trên cây lúa: đom vằn, đạo ôn, sâu cuốn lá, rầy nâu. Kết quả thực nghiệm trên mô hình có thể đạt được độ chính xác từ 80 đến 85%.

**Từ khóa:** sâu bệnh lúa, SIFT, SVM.

**Chỉ số phân loại:** 2.2

## **Đặt vấn đề**

Việt Nam là một nước nông nghiệp và hiện đang là một trong những quốc gia đứng đầu về xuất khẩu lúa gạo. Lúa là loại cây lương thực được trồng nhiều vụ trong năm tại hầu hết các vùng đồng bằng trên cả nước, đặc biệt là Đồng bằng sông Cửu Long và Đồng bằng sông Hồng, khi sâu bệnh gây hại sẽ làm sản lượng lúa sụt giảm đáng kể. Trong hầu hết các trường hợp, sâu hoặc bệnh đều được phát hiện qua lá hoặc thân cây lúa (*thể hiện rõ nhất trong giai đoạn trổ bông*). Do đó, việc xác định sớm các triệu chứng của sâu bệnh có ý nghĩa rất quan trọng trong phát triển sản xuất. Để tăng năng suất cho một mùa vụ, người nông dân cần phải tiếp cận các chuyên gia tư vấn về việc điều trị dịch hại, bệnh cho cây trồng và các biện pháp xử lý. Hiện nay, trên thế giới đã có nhiều công trình nghiên cứu về nhận dạng sâu bệnh trên các loại cây ăn quả gần gũi như cà chua, dưa... bằng các phương pháp có sử dụng kỹ thuật xử lý ảnh đã đem lại được những kết quả rất khả quan. Các hệ thống phát hiện này thường chỉ được áp dụng trong các môi trường lý tưởng như môi trường nhà kính, chưa được áp dụng rộng rãi trong điều kiện thực tế ngoài trời. Trong nước cũng chưa có nhiều công trình nghiên cứu về nhận dạng sâu bệnh chuyên cho một loại nông sản, hơn nữa các phương pháp phát hiện sâu bệnh cũng chưa được tối ưu.

Trong những năm gần đây, các nghiên cứu trên thế giới

đã tập trung nhiều hơn vào sử dụng các thuật toán, phương pháp xử lý ảnh để phát hiện và phân loại các loại sâu bệnh cho cây lúa. Nandini và Anoop (2016) [1] đã đưa ra phương pháp phân loại bệnh trên cây lúa sử dụng kỹ thuật biểu đồ thích nghi của Wiener [2], sau đó sử dụng phương pháp Otsu [3] cho tách ngưỡng nhị phân, cuối cùng phân lớp bằng cách kết hợp giữa phương pháp SVM và Fuzzy logic cho độ chính xác đạt được từ 85,71 đến 93,33%. Do sử dụng biểu đồ thích nghi cho tính toán đặc trưng của ảnh, nên phương pháp do nhóm tác giả đưa ra cần sử dụng mẫu đầu vào có độ phân giải cao và bị ảnh hưởng mạnh khi xuất hiện các thành phần khác không phải là dấu hiệu sâu bệnh. Phadikar và cs (2013) [4] đưa ra phương pháp phân đoạn dựa trên năng lượng Fermi để cô lập khu vực bị nhiễm của hình ảnh lá lúa, các tính năng quan trọng được chọn bằng cách sử dụng lý thuyết tập thô (RST), kết quả của phương pháp đạt được 91,89%. Nghiên cứu của Pawankumar và Angadi (2017) [5] đã xây dựng thành công một Web server để xử lý trực tiếp bộ ảnh thu thập, cả hai thuộc tính màu sắc và trích xuất đặc trưng được sử dụng với đa phân lớp SVM đã cho độ chính xác 84,41%. Mohanty và cs (2016) [6] đã đề xuất sử dụng Deep Learning cho phát hiện 26 loại bệnh trên 14 loại lá cây với tập dữ liệu lớn 54.306 ảnh đầu vào, dựa trên các mô hình xây dựng nhóm nghiên cứu đã đạt được độ chính xác lên tới 99,35%.

\*Tác giả liên hệ: Email: ngoctu@cfoc.vn

# Rice pests and diseases identification using SIFT feature

Ngoc Tu Nguyen<sup>1\*</sup>, Thi Thanh Phuong Bui<sup>1</sup>,  
Hoang Nam Le<sup>1</sup>, Nam Thanh Ngo<sup>2</sup>

<sup>1</sup>National Center for Technological Progress  
<sup>2</sup>Soc Trang Plant Breeding Center

Received 19 October 2018; accepted 10 December 2018

## Abstract:

The growth and development of crops in agriculture depends on many factors including seed, nutritional status, weather conditions, and etc., in which pests and diseases directly affect the yield of crops and can spread widely. Rice, a major crop of Vietnam, plays an important role of food security and export. Although the pest and disease control procedures for rice are strictly applied, it is still unable to fully control the germ of pests. With a large-scale cultivation mode, the human eye is found very difficult to detect signs of pests in the early stages of development. In this paper, authors propose a model using SIFT (Scale-Invariant Feature Transform) features and SVM (Support Vector Machine) for processing images of rice's leaves. This model can detect and identify 4 pests in rice: zebra blast, rice blast, leaf rollers, and brown backed hoppers. Experimental results on the model can achieve the accuracy from 80 to 85%.

**Keywords:** rice pests and diseases, SIFT, SVM.

**Classification number:** 2.2

Trong bài báo này, chúng tôi đi sâu vào phương pháp phát hiện sâu bệnh có sử dụng kỹ thuật xử lý ảnh tích hợp thuật toán SIFT và phân lớp SVM. Hệ thống được đề xuất nhằm phát triển một chương trình phần mềm để nhận ra hình ảnh của lá bệnh hay bông lúa bệnh bằng cách sử dụng các lớp đã được huấn luyện trước đó. Các thông số đầu vào của phần mềm gồm: màu sắc của lá, vết thủng hay biến dạng bề mặt lá... Những đặc trưng của từng loại bệnh khi thu được sẽ được thuật toán xử lý rồi đưa ra kết quả một cách chính xác. Từ đó, người nông dân sẽ có phản ứng kịp thời cũng như được hướng dẫn trực tiếp qua phần mềm các phương án đối phó với bệnh. Về hình thức tiếp cận cây lúa, giải pháp sử dụng Drone [7] mang theo thiết bị quét được cho là rất khả quan do tiết kiệm được thời gian và công sức lấy mẫu.

## Đối tượng và phương pháp nghiên cứu

### Đối tượng và địa điểm nghiên cứu

**Đối tượng nghiên cứu:** các mẫu lá lúa bị 4 loại sâu bệnh hại: đốm vằn, đạo ôn, sâu cuốn lá, rầy nâu được chụp từ cánh đồng ươm tạo tại Trung tâm Giống cây trồng Sóc Trăng.

**Địa điểm nghiên cứu:** Phòng thí nghiệm 308, Trung tâm Quang điện tử - Viện Ứng dụng Công nghệ (Thanh Xuân Bắc, Thanh Xuân, Hà Nội).

### Phương pháp nghiên cứu

Bố trí thực nghiệm:

- Tạo mẫu dữ liệu: khảo sát và thu thập mẫu ảnh về lúa, bao gồm lá phát triển bình thường và lá bị bệnh trong giai đoạn trổ bông. Căn cứ theo các dấu hiệu sâu bệnh của lúa [8] để sử dụng phương pháp chọn mẫu ngẫu nhiên đơn giản [9].

- Xử lý dữ liệu ảnh trên máy tính để trích chọn các đặc trưng, phân lớp trên phần mềm.

### Kết quả ứng dụng trích chọn đặc trưng SIFT và phân lớp SVM

Cây lúa nước vào mỗi thời điểm trong năm do điều kiện khí hậu nhiệt đới thích hợp cho các loại sâu bệnh phát triển, gây nên thiệt hại không nhỏ và thể hiện rõ rệt nhất trên thân, lá, bông hạt, đặc biệt là với các bệnh sâu cuốn lá, đốm vằn, đạo ôn và rầy nâu. Dưới đây là một số hình ảnh về các bệnh thông thường trên cây lúa (hình 1, 2). Dữ liệu thực tế thu được là cơ sở để tiến hành xử lý cho quá trình huấn luyện.



**Hình 1.** Những biểu hiện của từng loại sâu bệnh trên lúa. (A) Cháy bìa lá, (B) Bệnh bạc lá, (C, E) Bệnh đạo ôn, (D) Sâu cuốn lá.



Hình 2. Ảnh bệnh cháy bìa lá lúa tại Trung tâm Giống cây trồng Sóc Trăng.

**Trích chọn đặc trưng ảnh bằng kỹ thuật SIFT**

Kỹ thuật SIFT được Lowe và David nghiên cứu, giới thiệu và phát triển từ năm 1999 đến năm 2004 [10]. SIFT có khả năng dò tìm và trích chọn các đặc trưng của đối tượng từ ảnh đầu vào. Các đặc trưng được phát hiện đó có khả năng bất biến khi đối tượng bị thay đổi về tỷ lệ, bị xoay trong ảnh khác.

Quá trình trích chọn điểm đặc trưng SIFT được thực hiện qua các bước sau: xây dựng lựa chọn tỷ lệ - không gian kim tự tháp; xác định vị trí của các “keypoint”; xác định và gắn hướng cho các “keypoint”; mô tả keypoint.

**Xây dựng lựa chọn scale-space kim tự tháp**

Để phát hiện các keypoint, chúng ta sử dụng bộ lọc tuần tự để xác định những điểm có khả năng là “keypoint” tại các vị trí và tỷ lệ. Để nhận biết vị trí những bất biến đối với sự thay đổi về quy mô của bức ảnh, chúng ta sử dụng kernel là hàm Gaussian blur. Các ảnh sau khi thực hiện với hàm Gaussian blur sẽ bị mờ đi, tùy theo tham số lựa chọn mà độ mờ của bức ảnh được thay đổi.

Hàm Gaussian blur áp dụng cho ảnh theo công thức tính như sau:

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \tag{1}$$

Hàm  $G(x, y, \sigma)$  có dạng:

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \tag{2}$$

Các giá trị  $\sigma$  được tính cho ảnh tiếp theo với  $k * \sigma$  ( $k$  là hằng số tự chọn).

**Hàm lọc cho các ảnh trong quy mô không gian SIFT**

Trước khi áp dụng các tham số cho hàm Gaussian blur, cần thực hiện tạo các ảnh trong quy mô không gian SIFT. SIFT được chia thành 4 cột (4 octave), octave sau có kích thước ảnh bằng một nửa octave trước và mỗi octave có 5 ảnh (bảng 1). Các ảnh trong một octave được gọi là scale, các scale trong mỗi octave có kích thước tương đương nhau nhưng khi áp dụng với hàm Gaussian blur thì có giá trị sigma khác nhau. Các scale có thứ tự giống nhau thì tham số sigma là bằng nhau.

Bảng 1. Tham số lựa chọn cho giá trị sigma.

	Tỷ lệ 1	Tỷ lệ 2	Tỷ lệ 3	Tỷ lệ 4	Tỷ lệ 5
Octave	0,707107	1,00	1,414214	2,00	2,828427
	1,414214	2,00	2,828427	4,00	5,656854
	2,828427	4,00	5,656854	8,00	11,313708
	5,656854	8,00	11,313708	16,00	22,627417


**Tìm sai khác trong hàm Gaussian**

Để có được kết quả nhận biết vị trí các keypoint ổn định trong quy mô không gian, chúng ta sử dụng các định trong hàm Difference-of-Gaussian với ảnh (hình 3).  $D(x, y, \sigma)$  được tính là sự khác nhau giữa 2 điểm ảnh ở 2 quy mô không gian kề nhau bởi giá trị  $k$ :

$$D(x, y, \sigma) = G(x, y, k\sigma) - G(x, y, \sigma) * I(x, y, \sigma) \tag{3}$$


$$= L(x, y, k\sigma) - L(x, y, \sigma)$$

$$\text{Do đó: } G(x, y, k\sigma) - G(x, y, \sigma) \approx (k-1) \sigma^2 \nabla^2 G \tag{4}$$



Hình 3. Mô hình thực hiện hàm DOG.

Sau khi tính được Difference-of-Gaussian, ta cần khảo sát điểm đó so với 8 điểm lân cận xung quanh trong một scale với 9 điểm thuộc octave trước và 9 điểm thuộc octave sau (hình 4). Điểm nào không có đủ 26 điểm lân cận sẽ bị loại bỏ. Nếu điểm đó có giá trị nhỏ nhất hoặc lớn nhất so với 26 điểm thì nó được xét là điểm có điều kiện trở thành một keypoint.



Hình 4. Sơ đồ tính cực trị trong Difference of Gaussian.

**Xác định keypoint**

Sau khi đã xác định được những điểm cực trị có khả

năng trở thành một keypoint, tiến hành lọc bớt các điểm có độ tương phản thấp hoặc các điểm nằm trên cạnh của chi tiết. Phương pháp này được phát triển bởi Brown và Lowe (2002) [11] bằng cách sử dụng chuỗi Taylor mở rộng với hàm scale-space  $D(x, y, \sigma)$  để dịch chuyển gốc tại điểm lấy mẫu:

$$D(x) = D + \frac{\partial D^T}{\partial x} X + \frac{1}{2} X^T \frac{\partial^2 D}{\partial x^2} X \quad (5)$$

Với thí nghiệm của Lowe, tất cả các đỉnh với giá trị của  $D(X) < 0,03$  bị loại bỏ (giá trị mức xám của các điểm ảnh cần được đưa từ 0...255 về dải từ 0...1).

**Gán hướng cho “keypoints”**

Bằng việc gán một hướng duy nhất cho mỗi “keypoints” dựa trên thuộc tính tại vị trí trên ảnh, việc mô tả “keypoint” có thể được biểu diễn liên quan tới hướng đó, vì thế có được sự bất biến đối với sự quay của ảnh.


Không gian của keypoint được sử dụng để lựa chọn Gaussian làm mịn ảnh, với  $L$  là quy mô gần nhất, mỗi mẫu ảnh  $L_{x,y}$ , độ lớn của gradient  $m$ , hướng  $\theta$  ta có các công thức tính như sau:

$$m = \sqrt{(L_{x+1,y} - L_{x-1,y})^2 + (L_{x,y+1} - L_{x,y-1})^2} \quad (6)$$

$$\theta = \tan^{-1} \left( \frac{L_{x,y+1} - L_{x,y-1}}{L_{x+1,y} - L_{x-1,y}} \right) \quad (7)$$

**Mô tả keypoint tại vị trí trên ảnh (hình 5)**

Để mô tả keypoints, cần tính toán để mô tả các bất biến tại các vị trí trên ảnh. Sử dụng phương pháp chuẩn hóa tương quan cho các intensity xung quanh keypoint, tuy nhiên tương quan này dễ nhạy cảm với những thay đổi bên ngoài gây ra như biến đổi hình học hoặc các biến dạng khác.



Hình 5. Mô tả tại một keypoint với cửa sổ 2x2.

Một keypoint được mô tả bằng cách tính toán độ lớn của độ dốc và hướng tại mỗi điểm ảnh, những trọng số được tính bằng cách sử dụng một cửa sổ hình tròn Gaussian chồng chập, sau đó chúng được tổng hợp vào biểu đồ hướng tổng trên một khu vực rộng hơn, thông thường người ta sử dụng một cửa sổ mô tả 4x4 cho một mảng mẫu 16x16.

Sau khi nhân các giá trị độ lớn độ dốc với cửa sổ trọng số Gaussian ta thực hiện cho tất cả 16x16 ô để đưa vào

tổng hợp 4x4, với mỗi 16 ô ta đưa các giá trị vào 8 ô theo sự phân chia định hướng, mỗi ô này có giá trị tương ứng từ 0...44°, 45...89°, ... Như vậy, tổng cộng ta tính cho mỗi một keypoint bao gồm 4x4x8=128 điểm khảo sát xung quanh.

Sau khi tổng hợp xong, ta thực hiện chuẩn hóa tất cả các vector trong một “keypoint”. Các keypoint này nằm tại giữa các điểm ảnh, vì thế bước cuối cùng cần phải nội suy để tạo ra định hướng và độ lớn của dữ liệu nằm ở giữa các pixel. Như vậy đã thực hiện xong việc mô tả “keypoint”.

**Huấn luyện phân lớp SVM (hình 6, 7)**

Trong nghiên cứu này, chúng tôi sử dụng phương pháp SVM cho phân lớp các loại đặc trưng trích rút từ SIFT.

Support vector được biểu diễn như sau:  $x_i \cdot w + b = \pm 1$

Khoảng cách giữa điểm và siêu phẳng:  $\frac{|x_i \cdot w + b|}{\|w\|}$


Giới hạn (margin):  $\frac{2}{\|w\|}$

Công thức phân lớp (ranh giới quyết định):

$$w \cdot x + b = \sum_i a_i b_i x_i \cdot x + b$$

- Nếu  $x \cdot w + b \geq 0$  thì điểm thuộc lớp 1

- Nếu  $x \cdot w + b \leq 0$  thì điểm thuộc lớp 2



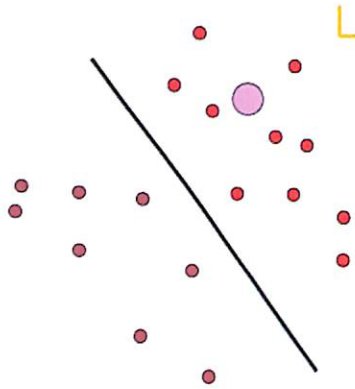
Hình 6. Mô hình tìm siêu phẳng trong SVM.

Nhóm nghiên cứu sử dụng thư viện LibSVM của Chang Chih-Chung và Chih-Jen Lin (2011) [12] để xây dựng mô hình phân lớp sau khi có được tập tin đặc trưng đã chuẩn hóa, tập tin này sẽ trở thành đầu vào của máy học SVM, các bước thực hiện như sau:

Bước 1: các đặc trưng đã được trích xuất ở bước trích chọn SIFT của tập ảnh mẫu sẽ là đầu vào của quá trình huấn luyện phân lớp.

Bước 2: chọn các thông số phù hợp cho việc xây dựng mô hình phân lớp. Đối với mỗi tập tin đặc trưng đầu vào, sử dụng công cụ grid.py của thư viện LibSVM để chọn tham số tốt nhất, đảm bảo cho quá trình huấn luyện đem lại độ chính xác cao nhất. Đối với tập đặc trưng đã chọn ở trên, tham số  $\gamma$  (gamma của hàm nhân) được chọn là 0,125 và  $c$  (chi phí) được chọn là 8.

Bước 3: huấn luyện mô hình SVM bằng hàm thực thi Train() với tập tin đặc trưng đã chọn ở bước 1, các thông số đã chọn ở bước 2.



Hình 7. Quyết định phân lớp cho 1 điểm ngẫu nhiên trong không gian.

Bước 4: kiểm tra độ chính xác của mô hình bằng phương thức EvaluateClassificationProblem(). Đầu ra của giai đoạn này là mô hình phân lớp. Mô hình này dùng để phân lớp nhận dạng sâu bệnh.

**Đánh giá độ chính xác của kết quả chẩn đoán sâu bệnh ứng dụng kỹ thuật SIFT và SVM**

Tập dữ liệu được sử dụng cho thử nghiệm bao gồm 800 hình ảnh. Trong đó, 300 hình ảnh là các lá lúa bình thường và 500 hình ảnh là lá lúa bệnh. 50% hình ảnh trong mỗi lớp được sử dụng để huấn luyện và kiểm tra. Các thực nghiệm được tiến hành với sự kết hợp các tính năng hình ảnh khác nhau. Bảng 2 và 3 cho thấy kết quả phân loại khi sử dụng với SVM với đặc trưng SIFT so sánh kết quả với đặc trưng toàn phần HOG (Histogram of Gradient) [13]. Kết quả cho thấy, tính năng khoảng cách cạnh thông qua thuật toán chuyển dòng cùng với tính năng SIFT cho tỷ lệ phân loại cao hơn 85% so với HOG.

**Bảng 2. Tỷ lệ phân loại (%) đối với lá lúa bình thường và bị sâu bệnh (độ chính xác ACC, tỷ lệ dương tính TPR-True, tỷ lệ âm tính TNR).**

Đặc tính	Số lượng ảnh	ACC (%)	Giá trị thu được (TPR)	TNR	Độ lệch chuẩn	Giá trị dự đoán âm
SIFT	500	85,0	0,858	0,836	0,897	0,779
HOG	500	82,1	0,848	0,776	0,8635	0,754

**Bảng 3. Tỷ lệ phân loại (%) đối với lá lúa bình thường và lúa bị bệnh với 1.000 mẫu mỗi loại.**

Đặc tính	Số mẫu vật	Độ chính xác	Thời gian xử lý trung bình
Khô vằn	1.000	84,6	365 ms
Đạo ôn	1.000	81,2	277 ms
Cuốn lá	1.000	80,1	251 ms
Rầy nâu	1.000	82,7	338 ms

**Kết luận**

Bài báo này đã tập trung vào nghiên cứu ứng dụng trích chọn đặc trưng hình thái học sử dụng SIFT và phân lớp SVM trong việc xác định lá lúa bị sâu bệnh. Các kết quả phân loại thu được bằng cách sử dụng sự kết hợp của cả hai

tính năng mang lại độ chính xác lên tới 85% so với phương pháp chỉ sử dụng đặc trưng mô tả HOG. Hướng phát triển nghiên cứu tiếp theo của chúng tôi nhằm cải thiện độ chính xác cho quá trình phát hiện bệnh trên lúa sẽ giải quyết các vấn đề sau: (1) Thu thập thêm nhiều mẫu ảnh dữ liệu cho quá trình huấn luyện; (2) Sử dụng kết hợp các đặc trưng cục bộ như SIFT, SUFT... với HOG hoặc HOG -DLMA [14]; (3) Sử dụng mạng neural xoắn ốc (deep convolutional neural network) trong phân loại để nâng cao độ chính xác.

**TÀI LIỆU THAM KHẢO**

[1] C. Nandini, G.L. Anoop (2016), "Classification and grading the level of paddy leaf diseases using multi classifiers", *International Journal of Advances in Science Engineering and Technology*, 4(4), pp.28-32.

[2] Wiener, Norbert (1949), *Extrapolation, Interpolation, and Smoothing of Stationary Time Series*, New York: Wiley, ISBN 0-262-73005-7.

[3] N. Otsu (1979), "A threshold selection method from gray level histograms", *IEEE Trans. Systems Ma. and Cybernetics*, 9, pp.62-66.

[4] Phadikar, Santanu, Jaya Sil, and Asit Kumar Das (2013), "Rice diseases classification using feature selection and rule generation techniques", *Computers and Electronics in Agriculture*, 90, pp.76-85.

[5] K.L. Pawankumar, S.A. Angadi (2017), "An automated system for detection and classification of rice plant diseases", *IJSRD - International Journal for Scientific Research & Development*, 5(7), pp.705-707.

[6] Mohanty, P. Sharada, Hughes, P. David, Salathé, Marcel (2016), "Using deep learning for image-based plant disease detection", *Frontiers in Plant Science*, 7, p.1419.

[7] D. Zhang, X. Zhou, J. Zhang, Y. Lan, C. Xu, D. Liang (2018), "Detection of rice sheath blight using an unmanned aerial system with high-resolution color and multispectral imaging", *PLOS ONE*, 13(5), e0187470.

[8] Nguyễn Ngọc Đệ (2008), *Giáo trình cây lúa*, Nhà xuất bản Đại học Quốc gia Tp Hồ Chí Minh.

[9] Vũ Cao Đàm (2003), *Phương pháp luận nghiên cứu khoa học*, Nhà xuất bản Khoa học và Kỹ thuật, Hà Nội.

[10] Lowe, G. David (1999), "Object recognition from local scale-invariant features", *Proceedings of the International Conference on Computer Vision*, 2, pp.1150-1157, doi:10.1109/ICCV.1999.790410.

[11] M. Brown, D. Lowe (2002), "Invariant features from interest point groups", *BMVC 2002: 13th British Machine Vision Conference*, Cardiff, pp.253-262.

[12] Chang Chih-Chung, and Chih-Jen Lin (2011), "LibSVM: a library for support vector machines", *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3), p.27.

[13] N. Dalal and B. Triggs (2005), "Histograms of oriented gradients for human detection", *Proceedings of the Conference on Computer Vision and Pattern Recognition*, 2, pp.886-893.

[14] P. Balamurugan, Rajesh, Reghunadhan (2012), "Neural network based system for the classification of leaf rot disease in cocos nucifera tree leaves", *European Journal of Scientific Research*, 88, pp.1450-216.