

ỨNG DỤNG TRÍ TUỆ NHÂN TẠO TRONG TỰ ĐỘNG HÓA NHẬN DẠNG BỆNH TRÊN TÔM SÚ

APPLICATION OF ARTIFICIAL INTELLIGENCE TO AUTOMATIC DISEASE RECOGNITION IN BLACK TIGER SHRIMP

Nguyễn Đình Hưng¹, Lê Thị Bích Hằng¹, Trần Vĩ Hích²

¹Khoa Công nghệ thông tin, Trường Đại học Nha Trang

²Viện Nuôi trồng thủy sản, Trường Đại học Nha Trang

Tác giả liên hệ: Nguyễn Đình Hưng; email: hungnd@ntu.edu.vn

Ngày nhận bài: 16/4/2024; Ngày phân biệt thông qua: 20/5/2024; Ngày duyệt đăng: 22/5/2024

TÓM TẮT

Nghiên cứu này nhằm thử nghiệm, đánh giá khả năng ứng dụng trí tuệ nhân tạo (artificial intelligence – AI) trong tự động hóa chẩn đoán bệnh trên tôm sú (*Penaeus monodon*). Một số bệnh trên tôm sú có dấu hiệu đặc trưng có thể nhận biết thông qua hình ảnh; trên cơ sở đó chúng tôi vận dụng các kỹ thuật tiên tiến của AI trong lĩnh vực thị giác máy tính (computer vision) để xây dựng hệ thống chẩn đoán hình ảnh có khả năng phân loại một số bệnh thường gặp trên tôm sú ở Việt Nam. Kết quả thực nghiệm trên 4 mẫu bệnh: đen mang, đốm đen, đốm trắng và hoại tử cơ cho thấy hệ thống chẩn đoán hình ảnh đạt độ chính xác cao nhất 87,58% với mô hình mạng neural tích chập (convolutional neural network - CNN) EfficientNet-B4 có áp dụng kỹ thuật học chuyển giao (transfer learning). Kết quả này gợi ý tiềm năng ứng dụng AI vào phân loại bệnh trên tôm sú, giúp rút ngắn thời gian, chi phí chẩn đoán bệnh, góp phần làm giảm thiệt hại của dịch bệnh gây ra cho nghề nuôi tôm.

Từ khóa: trí tuệ nhân tạo, thị giác máy tính, nhận dạng bệnh tôm, nông nghiệp thông minh.

ABSTRACT

This study aims to investigate the application of artificial intelligence (AI) for automatic disease classification in black tiger shrimp (*Penaeus monodon*). Various common diseases in black tiger shrimp have visual signs that can be recognized through images, suggesting the application of AI techniques in computer vision to build a system capable of predicting common diseases in black tiger shrimp in Vietnam. Experimental results of identifying four common shrimp diseases: black gill, black spot, white spot, and infectious myonecrosis show that the AI model obtained the highest accuracy of 87.58 % with the EfficientNet-B4 model using transfer learning technique. This result suggests the potential of applying AI to disease identification in black tiger shrimp which can shorten the time and cost of disease diagnosis, reducing the damage caused by diseases to shrimp farming.

Keywords: artificial intelligence, computer vision, shrimp disease prediction, smart agriculture.

I. ĐẶT VẤN ĐỀ

Công nghiệp nuôi tôm có vai trò quan trọng đối với nền kinh tế Việt Nam. Nước ta có điều kiện tự nhiên thuận lợi cho phát triển nuôi trồng thủy sản nói chung, công nghiệp nuôi tôm nói riêng, đặc biệt là vùng Đồng bằng sông Cửu Long. Theo công bố của Hiệp hội chế biến và xuất khẩu thủy sản Việt Nam (VASEP), nước ta hiện là nước sản xuất tôm sú hàng đầu thế giới với hơn 600.000 ha nuôi tôm cho sản lượng 300.000 tấn mỗi năm [1], giá trị xuất khẩu chiếm 13 đến 14% tổng giá trị xuất khẩu tôm toàn thế giới. Hằng năm, ngành tôm nước ta góp khoảng 40 đến 45% tổng giá trị xuất khẩu

thủy sản; giải quyết việc làm cho hơn 3 triệu lao động [2]. Chính phủ đặt mục tiêu đến năm 2025, ngành tôm đạt 10 tỷ USD doanh thu, đóng góp 10% vào GDP cả nước [3]. Để ngành tôm phát triển bền vững, việc ứng dụng khoa học, công nghệ mới để nâng cao năng suất, chất lượng sản phẩm là xu thế tất yếu; trong đó, việc ứng dụng khoa học vào quản lý môi trường, kiểm soát hiệu quả dịch bệnh trong các trang trại nuôi tôm có vai trò quan trọng.

Dịch bệnh là nguy cơ gây thiệt hại hàng đầu đối với công nghiệp nuôi tôm. Ở Việt Nam, sự bùng phát của loại bệnh trên tôm có tên Hội chứng tử vong sớm (early mortality syndrome

- EMS) đã gây thiệt hại nặng nề kể từ lần đầu tiên xuất hiện vào năm 2011. Các loại bệnh phổ biến khác gồm có bệnh đốm trắng (white spot syndrome virus - WSSV), bệnh phân trắng (white feces syndrome - WFS) và bệnh đầu vàng (yellow head virus - YHV). Do đặc điểm của môi trường nuôi tôm công nghiệp có mật độ nuôi cao, khi dịch bệnh xảy ra thường lây lan nhanh chóng. Để giảm bớt thiệt hại do bệnh tôm gây ra, việc phát hiện sớm các dấu hiệu của bệnh và xử lý kịp thời có ý nghĩa rất quan trọng.

Một số bệnh trên tôm có thể nhận biết thông qua các triệu chứng đặc trưng. Ví dụ, EMS có thể được phát hiện bằng cách xem xét các dấu hiệu vật lý của tôm, bao gồm gan tụy nhợt nhạt, teo lại hoặc teo, vỏ mềm và đầy một phần đến ruột luôn trống rỗng. Với bệnh WSSV, các dấu hiệu điển hình bao gồm giảm tiêu thụ thức ăn đột ngột, lớp biểu bì lỏng lẻo và sự hiện diện của các đốm trắng có đường kính từ 0,5 đến 2,0 mm trên bề mặt bên trong của mai, phần phụ và lớp biểu bì trên các đoạn bụng.

Những năm gần đây, các nghiên cứu của lĩnh vực trí tuệ nhân tạo (AI) đã đạt được nhiều thành tựu đột phá, các kết quả nghiên cứu ngày càng được ứng dụng đa dạng và chuyên sâu vào đời sống. Các kết quả nghiên cứu nổi bật dựa vào kỹ thuật học sâu (deep learning - DL) đã giải quyết thành công nhiều vấn đề phức tạp tồn tại trong lĩnh vực AI trong nhiều năm. Một số lĩnh vực ứng dụng tiêu biểu của DL bao gồm thị giác máy tính, xử lý ngôn ngữ tự nhiên, phương tiện tự lái và chẩn đoán y khoa [4].


Nghiên cứu này khảo sát, xây dựng thử nghiệm một mô hình AI có khả năng dự đoán một số bệnh thường gặp trên tôm sú thông qua hình ảnh. Nghiên cứu sử dụng các phương pháp, kỹ thuật tiên tiến của AI trong lĩnh vực thị giác máy tính, cụ thể là thuật học sâu (DL), tập trung vào mô hình mạng neural tích chập (convolutional neural network - CNN) và phương pháp học chuyển giao (transfer learning) để xây dựng hệ thống có khả năng thu nhận ảnh chụp mẫu vật và đưa ra kết quả chẩn đoán hoàn toàn tự động. Mục tiêu của nghiên cứu nhằm hướng tới ứng dụng trí tuệ nhân tạo và các hệ thống thông minh vào công nghiệp nuôi tôm, góp phần giảm thiểu thiệt hại của dịch bệnh gây ra cho ngành tôm.

II. ĐỐI TƯỢNG VÀ PHƯƠNG PHÁP NGHIÊN CỨU

1. Đối tượng nghiên cứu

Chúng tôi sử dụng mô hình mạng neural tích chập (CNN) để huấn luyện hệ thống tự động phát hiện và nhận dạng bệnh tôm thông qua hình ảnh mẫu vật [5]. Mô hình CNN là một loại mạng neural nhân tạo (artificial neural network - ANN), trong đó có ít nhất một lớp tích chập (convolutional layer). Tích chập là một phép biến đổi tuyến tính bao gồm phép nhân một tập các trọng số (weights) với dữ liệu đầu vào. Với bài toán nhận dạng ảnh, dữ liệu đầu vào là một mảng hai chiều các điểm ảnh (pixels), tập trọng số là ma trận vuông $n \times n$ chiều được gọi là bộ lọc (filter) hay nhân (kernel). Các kết quả phép nhân sau đó được cộng lại thành một số thực, vì thế phép biến đổi này được gọi là tích chập (convolution). Phép tích chập được áp dụng lên toàn bộ ảnh đầu vào tạo ra tập các giá trị được gọi là bản đồ đặc trưng (feature map). Bản đồ đặc trưng này được truyền qua phép biến đổi phi tuyến (nonlinearity) thông qua hàm kích hoạt (activation) trước khi truyền cho lớp kế tiếp. Sau mỗi lớp tích chập, ảnh được truyền qua lớp gộp (pooling layer) thu được ảnh đồng dạng có kích thước nhỏ hơn, do đó các đặc trưng ở lớp sau có mức độ tổng thể cao hơn lớp trước, giúp hệ thống có khả năng trích xuất được đặc trưng của ảnh ở nhiều cấp độ khác nhau, từ đó làm gia tăng hiệu quả nhận dạng.

Cấu trúc cơ bản của mô hình CNN được mô tả trong Hình 1, gồm có ba thành phần chính: lớp đầu vào là ảnh đối tượng, tiếp theo là một số lớp tích chập kết hợp với lớp gộp, cuối cùng là lớp đầu ra chứa xác suất dự đoán của các nhãn quan tâm. Mô hình CNN cần được huấn luyện từ dữ liệu để đạt độ chính xác cao; quá trình huấn luyện mô hình CNN từ bộ dữ liệu đã biết trước nhãn được gọi là học có giám sát (supervised learning). Mục tiêu của quá trình huấn luyện nhằm tính toán được bộ tham số của mô hình nhận dạng ảnh sao cho sai số dự đoán là nhỏ nhất. Phương pháp chung để tính toán bộ tham số là áp dụng giải thuật lan truyền ngược (back propagation) và giám đạo hàm (gradient descent).



Hình 1. Cấu trúc cơ bản của mô hình CNN.

2. Vật liệu nghiên cứu

2.1 Bộ dữ liệu

Bộ dữ liệu được sử dụng là ảnh chụp mẫu vật của tôm khỏe mạnh và tôm bị nhiễm bốn loại bệnh phổ biến: Bệnh đen mang, bệnh đốm đen, bệnh đốm trắng và bệnh hoại tử cơ.

Bảng 1. Bộ dữ liệu sử dụng trong nghiên cứu.

STT	Nhãn	Số mẫu
1	Đen mang	125
2	Đốm đen	103
3	Đốm trắng	173
4	Hoại tử cơ	115
5	Tôm khỏe mạnh	75

Số lượng ảnh mẫu của mỗi loại được liệt kê trong Bảng 1. Một số ảnh mẫu được liệt kê trong Hình 3 (cột trái).

2.2 Hệ thống xây dựng và huấn luyện mô hình CNN

Quá trình huấn luyện mô hình phân lớp CNN thực hiện nhiều thao tác tính toán, đòi hỏi hệ thống máy tính đủ mạnh để xử lý. Chúng tôi tiến hành thực nghiệm trên hệ thống máy tính có cấu hình được mô tả trong Bảng 2. Trong hệ thống này, bộ xử lý đồ họa (graphical processing unit - GPU) được khai thác để thực hiện các tác vụ tính toán song song, giúp rút ngắn thời gian huấn luyện các mô hình học máy so với sử dụng bộ xử lý trung tâm (central processing unit - CPU).

Để triển khai lập trình và vận hành huấn luyện các mô hình AI phân lớp, chúng tôi sử dụng các công cụ phần mềm chính được liệt kê trong Bảng 3. Các công cụ này hiện được sử dụng rộng rãi trong nghiên cứu và phát triển ứng dụng trí tuệ nhân tạo.

Bảng 2. Cấu hình của hệ thống máy tính huấn luyện mô hình CNN.

STT	Thiết bị	Thông số kỹ thuật	Hãng sản xuất
1	Bộ xử lý trung tâm (CPU)	Core i5 12500; tốc độ xử lý 4,6 GHz	Intel
2	Bộ nhớ RAM	Dung lượng 16 GB; tốc độ 3200 MHz	Kingston
3	Bộ nhớ ngoài	SSD 980 PCIe M.2 2280; dung lượng 1 TB	Samsung
4	Bộ xử lý đồ họa (GPU)	GeForce RTX 4070; dung lượng bộ nhớ VRAM 12 GB; tốc độ xử lý 2520 MHz; 7168 nhân CUDA	MSI

Bảng 3. Danh mục các phần mềm sử dụng trong thực nghiệm.

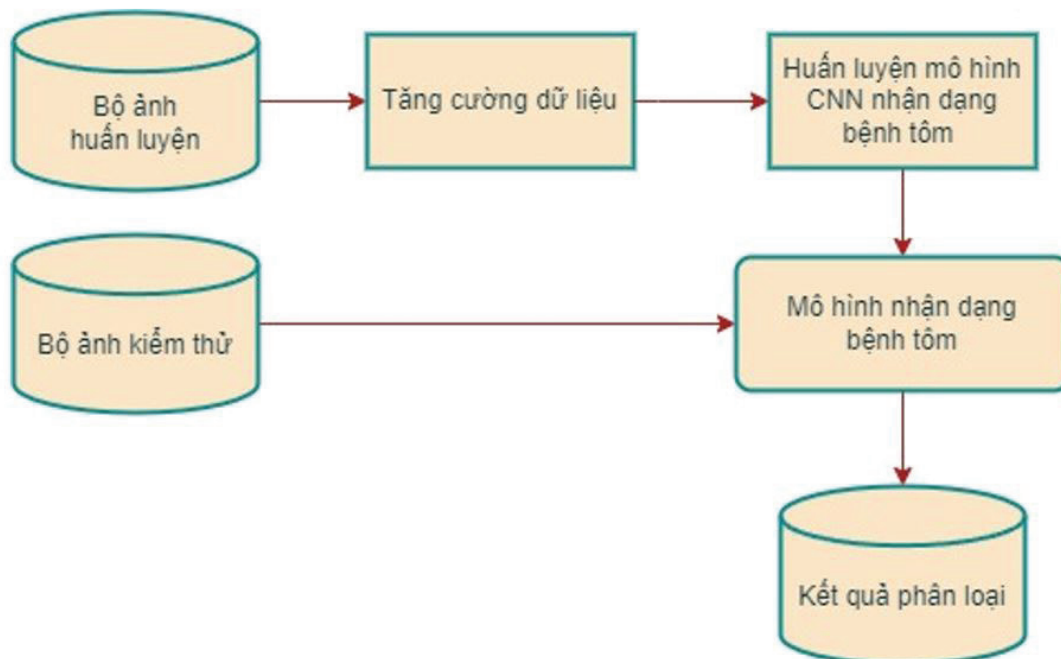
STT	Loại phần mềm	Tên, phiên bản phần mềm	Hãng sản xuất
1	Ngôn ngữ lập trình	Python 3.8	The Python Software Foundation
2	Thư viện lập trình AI	Pytorch 2.0	Meta AI
3	Thư viện xử lý song song	CUDA 11.0	NVIDIA
4	Hệ điều hành	Ubuntu 18.04	Canonical
5	Thư viện xử lý hình ảnh	OpenCV 4.3.0	OpenCV Team

3. Phương pháp nghiên cứu

Quy trình thực nghiệm xây dựng và huấn luyện mô hình AI nhận dạng bệnh tôm được thể hiện trong Hình 2. Bộ dữ liệu được chia ngẫu nhiên làm hai phần: 80% của mỗi lớp dùng để huấn luyện các mô hình CNN nhận dạng bệnh tôm, 20% còn lại dùng để kiểm định độ chính xác của mô hình huấn luyện. Chúng tôi áp dụng kỹ thuật tăng cường dữ liệu (data augmentation) để tạo ra số lượng ảnh huấn luyện nhiều hơn bộ dữ liệu gốc nhằm nâng cao độ chính xác của mô hình CNN. Các xử lý tăng cường dữ liệu được thực hiện tự động trên bộ dữ liệu huấn luyện, gồm có: cắt lấy trung tâm ảnh (center crop), lật ảnh theo chiều ngang/dọc (horizontal/vertical flip), và xoay ảnh ngẫu nhiên (random rotation). Kết quả, từ 473 ảnh ban đầu thu được 1892 ảnh đưa vào huấn luyện. Để tăng độ chính xác của hệ thống nhận dạng, chúng tôi áp dụng xử lý loại bỏ ảnh nền trên bộ dữ liệu để giữ lại ảnh của đối tượng, tương tự nghiên cứu [6]. Khác với [6] thực hiện xử lý loại bỏ ảnh nền bằng tay với phần mềm xử lý ảnh chuyên dụng Adobe Photoshop, chúng tôi thử nghiệm xử lý tự động loại bỏ ảnh nền sử dụng mô hình

học sâu U2-Net [14] và thư viện OpenCV [8]. Hình 3 thể hiện kết quả xử lý loại bỏ ảnh nền với một số mẫu trong bộ dữ liệu. Với cải tiến này, hệ thống nhận dạng bệnh tôm thực hiện hoàn toàn tự động từ ảnh đầu vào đến kết quả dự đoán.

Chúng tôi áp dụng kỹ thuật học chuyển giao (transfer learning) vào nghiên cứu này nhằm thu được hệ thống nhận dạng có độ chính xác cao hơn [8]. Các mô hình CNN cần sử dụng bộ dữ liệu đủ lớn trong quá trình huấn luyện để chúng học được bộ tham số cho kết quả nhận dạng tối ưu. Tuy nhiên, trong thực tế việc thu thập dữ liệu thường không đáp ứng yêu cầu; vì thế kỹ thuật học chuyển giao thường được áp dụng để khắc phục hạn chế này. Kỹ thuật học chuyển giao sử dụng mô hình AI của bài toán liên quan, đã được huấn luyện từ một bộ dữ liệu đủ lớn và cho kết quả tốt. Mô hình mới tiếp tục huấn luyện trên bộ dữ liệu của tác vụ mới và thường mang lại độ chính xác cao hơn so với chỉ huấn luyện với bộ dữ liệu hiện có. Chúng tôi lựa chọn năm mô hình CNN đã được huấn luyện và cho độ chính xác cao trong bài toán nhận dạng ảnh của dự án ImageNet [9] để thực nghiệm. Bảng



Hình 2. Sơ đồ quy trình huấn luyện mô hình phân loại bệnh tôm qua ảnh.

4 liệt kê tên và đặc điểm chính của các mô hình này. Các mô hình này đã thể hiện độ chính xác cao trong giải quyết bài toán nhận dạng của dự án ImageNet, đồng thời chúng có kích thước bộ tham số không quá lớn, phù hợp cho triển khai huấn luyện trên hệ thống máy tính hiện có [10].

Các thông số thực nghiệm được thiết lập giống nhau cho các mô hình CNN: số chu trình huấn luyện (epoch) là 100, giải thuật SGD [11] được sử dụng để tối ưu hóa mô hình với tốc độ cập nhật (learning rate) ban đầu là 0.001, số lượng ảnh đưa vào tại mỗi bước huấn luyện là 16.



Hình 3. Kết quả xử lý loại bỏ hình nền tự động.
Bên trái: Ảnh ban đầu, bên phải: ảnh thu được sau khi xử lý.

III. KẾT QUẢ NGHIÊN CỨU VÀ THẢO LUẬN

Độ chính xác (accuracy) được dùng để đánh giá hiệu năng của mô hình nhận dạng, thể hiện qua công thức sau:

$$\text{Độ chính xác} = \frac{\text{Số mẫu dự đoán đúng}}{\text{Tổng số mẫu dự đoán}} * 100\%$$

Bảng 4 thể hiện độ chính xác của các mô


hình nhận dạng bệnh tôm trên bộ dữ liệu kiểm thử. Kết quả thực nghiệm cho thấy năm mô hình CNN đều cho độ chính xác dự đoán trên 80%, giá trị trung bình là 84.7%, trong đó mô hình Efficient Net - B4 có độ chính xác cao nhất (87.58%). Kết quả dự đoán với một ảnh mẫu vật được minh họa trong Hình 5 với mô hình Efficient Net - B4, thể hiện giá trị dự đoán chính xác (tôm bị bệnh đốm đen).

Bảng 4. Độ chính xác của các mô hình CNN sau huấn luyện.

STT	Mô hình	Số lượng tham số (đơn vị tính: triệu)	Độ chính xác (%)
1	Resnet18 [12]	11.7	82.35
2	Resnet50 [12]	25.6	87.23
3	Resnet101 [12]	44.5	85.71
4	Efficient Net - B0 [13]	5.3	80.61
5	Efficient Net - B4 [13]	19.3	87.58

So sánh với nghiên cứu [6], nhóm tác giả thực nghiệm với hai mô hình phân lớp MobileNet-V1 và Inception-V3 với số chu trình huấn luyện đến 3000 epoch, có sử dụng kỹ thuật tìm kiếm lưới (grid search) để tìm mô hình tối ưu. Ngoài ra, trong nghiên cứu [6] hệ thống dự đoán bệnh tôm chưa hoàn toàn tự động do áp dụng xử lý loại bỏ ảnh nền được thực hiện bằng tay. Độ chính

xác cao nhất đạt được là 90,02% với mô hình Inception-V3. Trong nghiên cứu này, chúng tôi thiết lập hệ thống nhận dạng cho phép quá trình nhận dạng từ ảnh đầu vào đến kết quả đầu ra hoàn toàn tự động. Khi thực nghiệm với số chu trình huấn luyện 1000 epoch và tốc độ cập nhật là 0.01, độ chính xác thu được tương đương với kết quả của nghiên cứu này.

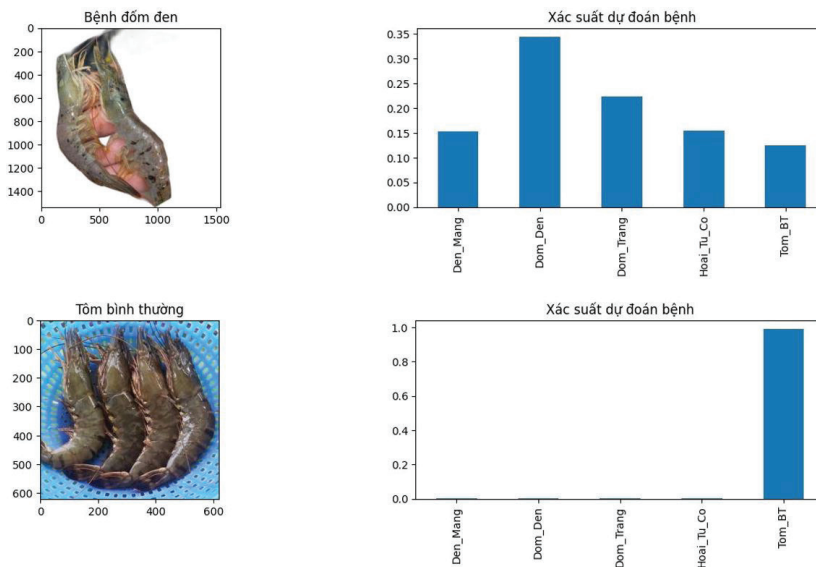


Hình 4. Đồ thị thể hiện độ chính xác (accuracy) của mô hình thu được trong quá trình huấn luyện.

Hình 4 thể hiện đồ thị biểu diễn độ chính xác của mô hình Efficient Net - B0 trong quá trình huấn luyện. Trong đó đồ thị màu xanh thể hiện độ chính xác thu được trên bộ dữ liệu huấn luyện, đồ thị màu vàng thể hiện độ chính xác thu được trên bộ dữ liệu kiểm thử. Đồ thị cho thấy

trong quá trình huấn luyện, độ chính xác của mô hình CNN tăng lên rất nhanh trong những epoch đầu tiên, sau đó tăng thêm rất ít hoặc không đổi.

Để gia tăng độ chính xác cần huấn luyện với bộ dữ liệu lớn hơn và/hoặc thử nghiệm với mô hình nhận dạng tốt hơn.



Hình 5. Kết quả dự đoán với hai mẫu ảnh.

IV. KẾT LUẬN VÀ KIẾN NGHỊ

Nghiên cứu này khảo sát thực nghiệm ứng dụng trí tuệ nhân tạo (AI) trong tự động hóa quá trình nhận dạng bệnh trên tôm sú (*Penaeus monodon*). Mô hình mạng neural tích chập (CNN) được sử dụng để huấn luyện hệ thống chẩn đoán bệnh tôm từ hình ảnh mẫu vật. Nghiên cứu cũng đề xuất một hệ thống nhận dạng bệnh tôm hoàn toàn tự động ứng dụng kỹ thuật học sâu (DL). Kết quả thực nghiệm cho thấy hệ thống nhận dạng đạt độ chính xác cao

nhất là 87.58% với mô hình phân lớp Efficient Net - B4.

Kết quả nghiên cứu cho thấy tiềm năng của ứng dụng AI vào dự đoán bệnh tôm, giúp giảm thiểu thời gian và chi phí so với phương pháp truyền thống, góp phần hạn chế thiệt hại của dịch bệnh gây ra đối với công nghiệp nuôi tôm.

Lời cảm ơn

Nghiên cứu này được tài trợ bởi Trường Đại học Nha Trang thông qua đề tài cấp trường mã số TR2022-13-03.

TÀI LIỆU THAM KHẢO

1. <https://vasep.com.vn/san-pham-xuat-khau/tom/tong-quan-nganh-tom> (VASEP, 2022, Tổng quan ngành tôm), truy cập ngày 19/7/2022.
2. <https://nhandan.vn/ung-dung-nhieu-giai-phap-tien-bo-ky-thuat-phat-trien-ben-vung-nghe-nuoi-tom-post763722.html> (Báo Nhân dân, 2023, Ứng dụng nhiều giải pháp, tiến bộ kỹ thuật phát triển bền vững nghề nuôi tôm), truy cập ngày 15/9/2023.
3. <https://baohinhphu.vn/tu-tin-huong-den-muc-tieu-10-ty-usd-gia-tri-xuat-khau-tom-102288978.htm> (Báo Chính phủ, 2022, Tự tin hướng đến mục tiêu 10 tỷ USD giá trị xuất khẩu tôm), truy cập ngày 19/7/2022.
4. Alex Krizhevsky, Ilya Sutskever and Geoffrey E Hinton (2012), "ImageNet Classification with Deep Convolutional Neural Networks", *Advances in Neural Information Processing Systems*, vol. 25.
5. Yann LeCun *et al.* (1989), "Backpropagation applied to handwritten zip code recognition", *Neural Computation*, vol. 1, no. 4, pp. 541-551.
6. Nghia Duong-Trung, Luy-Da Quach and Chi-Ngon Nguyen (2020), "Towards Classification of Shrimp Diseases Using Transferred Convolutional", *Advances in Science, Technology and Engineering Systems Journal*, vol. 5, no. 4, pp. 724-732.
7. <https://opencv.org> (OpenCV Team, OpenCV, 2023), accessed 20/7/2023.
8. Weiss, Karl, Taghi M. Khoshgoftaar, and DingDing Wang (2016), "A survey of transfer learning", *Journal of Big Data*, vol. 3, no. 1, pp. 1-40.
9. <https://www.image-net.org> (Stanford University, 2023, ImageNet), accessed 6/7/2023.
10. <https://pytorch.org/vision/stable/models.html> (The Linux Foundation, 2023, Pytorch Documentation), accessed 10/7/2023.
11. Y. Liu, Y. Gao and W. Yin (2020), "An Improved Analysis of Stochastic Gradient Descent with Momentum", *Neural Information Processing Systems*, vol. 33, pp. 18261-18271.
12. Kaiming He *et al.* (2016), "Deep Residual Learning for Image Recognition", in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770-778.
13. Tan Mingxing and Quoc Le (2019), "Efficientnet: Rethinking model scaling for convolutional neural networks", in *International Conference on machine learning*, pp. 6105-6114.
14. Xuebin Qin *et al.* (2020), "U2-Net: Going deeper with nested U-structure for salient object detection", *Journal of Pattern Recognition*, vol. 106, pp. 107404.