

MÔ HÌNH TỔNG QUÁT PHÁT TRIỂN HỆ THỐNG NHẬN DIỆN SÂU BỆNH DỰA TRÊN HỌC CHUYỂN GIAO VỚI MẠNG NƠ-RON TÍCH CHẬP

Võ Thị Hồng Loan, Lê Thị Kim Anh
Khoa Kỹ Thuật – Công Nghệ, Trường Đại học Phú Yên

Tóm tắt: Bài viết này phân tích các đặc điểm nổi bật của mạng nơ-ron tích chập trong nhận diện ảnh và ưu điểm của kỹ thuật học chuyển giao (Transfer Learning) trong vấn đề đào tạo mô hình học có dữ liệu huấn luyện hạn chế. Từ đó đề xuất mô hình tổng quát để xây dựng hệ thống nhận diện ảnh dựa trên học chuyển giao với mạng nơ-ron tích chập. Giải pháp này cho phép tận dụng sức mạnh của các mô hình đã được đào tạo trước trên tập dữ liệu công khai để giải quyết các bài toán chuyên biệt có tập dữ liệu nhỏ hơn nhằm giảm nhu cầu về dữ liệu huấn luyện và tài nguyên tính toán khi triển các khai dự án mới.

Từ khóa: học sâu, học chuyển giao, mạng nơ-ron tích chập, nông nghiệp, phát hiện sâu bệnh, nhận diện ảnh.

GENERAL FRAMEWORK FOR THE DEVELOPMENT OF A PEST AND DISEASE RECOGNITION SYSTEM BASED ON TRANSFER LEARNING WITH CONVOLUTIONAL NEURAL NETWORKS

Vo Thi Hong Loan, Le Thi Kim Anh
Faculty of Engineering and Technology, Phu Yen University

Abstract: This paper investigates the distinctive advantages of Convolutional Neural Networks (CNNs) in image recognition tasks and explores the effectiveness of Transfer Learning in scenarios with limited training data. Based on this analysis, a general framework is introduced for developing an image recognition system by leveraging transfer learning in conjunction with CNN architectures. This approach facilitates the reuse of pre-trained models on large-scale public datasets to enhance performance on domain specific tasks with smaller datasets, thereby reducing the need for extensive training data and computational resources when developing new projects.

Keywords: deep learning, transfer learning, convolutional neural networks, sustainable agriculture, pest detection, image recognition

Nhận bài: 19/05/2025

Phản biện: 19/06/2025

Duyệt đăng: 24/06/2025

I. ĐẶT VẤN ĐỀ

Sâu bệnh là một trong những nguyên nhân chính gây ảnh hưởng nghiêm trọng đến sự phát triển của cây trồng và làm giảm năng suất mùa vụ, đặt ra nhiều thách thức cho sản xuất nông nghiệp hiện nay. Theo bà Đặng Thị Thủy – Phó Giám đốc Sở Nông nghiệp và Phát triển Nông thôn tỉnh Phú Yên, đa số nông dân tại địa phương vẫn chủ yếu dựa vào quan sát bằng mắt thường để phát hiện sâu bệnh, bên cạnh các phương pháp truyền thống như bẫy dính và bẫy đèn UV. Tuy nhiên, các phương pháp này còn hạn chế, dễ bỏ sót sâu bệnh ở giai đoạn đầu, và việc phun thuốc hóa học không kiểm soát có thể gây ô nhiễm môi trường và giảm năng suất.

Để khắc phục hạn chế, bài viết đề xuất áp dụng công nghệ thông tin nhằm nâng cao hiệu quả kiểm soát sâu bệnh thông qua việc giám sát thường xuyên và phân tích dữ liệu cây trồng. Phương pháp này cho phép phát hiện sâu bệnh sớm, xử lý kịp thời và chính xác, đồng thời tiết kiệm chi phí và giảm thiểu tác động môi trường, góp phần phát triển nông nghiệp bền vững.

Bên cạnh đó, bài viết tập trung vào việc ứng

dụng mạng nơ-ron tích chập (CNN) trong nhận diện hình ảnh sâu bệnh trên cây trồng và phân tích hiệu quả của kỹ thuật học chuyển giao (transfer learning). Mô hình đề xuất kết hợp giữa CNN và học chuyển giao giúp tăng độ chính xác trong nhận dạng và phù hợp với điều kiện thực tiễn. Tác giả cũng nhấn mạnh vai trò then chốt của dữ liệu huấn luyện và đề xuất các kỹ thuật xử lý dữ liệu phù hợp để nâng cao hiệu quả mô hình nhận diện.

II. NỘI DUNG NGHIÊN CỨU

2.1. Mạng nơ-ron tích chập

2.1.1 Kiến trúc

Mạng nơ-ron tích chập (CNN) là mô hình mạng nơ-ron nhiều lớp, được thiết kế để trích xuất các đặc trưng trong dữ liệu đầu vào có cấu trúc lưới bao gồm hình ảnh, video, âm thanh và ngôn ngữ tự nhiên [2-4]. Hình 1 là một kiến trúc tổng quát của mạng CNN, bao gồm ba thành phần chính: các lớp tích chập (convolutional layer), lớp gộp (pooling layer), lớp kết nối đầy đủ (fully connected layer).

Lớp tích chập: thành phần đầu tiên của mạng thực hiện trích xuất các đặc điểm nổi bật từ một

bức ảnh đầu vào. Quá trình này được thực hiện thông qua các phép toán dựa trên hàm tích chập.

Lớp gộp: nằm bên cạnh các lớp tích chập và được sử dụng để làm giảm kích cỡ hình ảnh đầu vào bằng cách loại bỏ những thông tin không cần thiết sau khi thực hiện tích chập, chỉ giữ lại các đặc trưng nổi bật của ảnh. Điều này cho phép giảm mức độ tính toán xuống dần mà không làm mất đi các đặc điểm quan trọng của ảnh. Hàm lấy mẫu gộp (pooling) có 3 loại chính là lấy phần tử lớn nhất (Max pooling), lấy nhóm trung bình (Average pooling), lấy tổng của tất cả các phần tử trong bản đồ đặc trưng (Sum pooling). Trong đó Max pooling là kiểu thường được sử dụng nhất.

Lớp kết nối đầy đủ: sau khi các đặc trưng được các lớp tích chập trích xuất và được lấy mẫu xuống bởi các lớp gộp pooling, chúng sẽ được ánh xạ bởi một tập hợp con gồm các lớp được kết nối đầy đủ tới đầu ra cuối cùng của mạng. Lớp kết nối đầy đủ cuối cùng thường có cùng số lượng nút với số lượng lớp. Các bản đồ đặc trưng đầu ra của lớp gộp cuối cùng thường được làm phẳng, nghĩa là được chuyển đổi thành mảng số hoặc vector một chiều. Cuối cùng hàm softmax được sử dụng để phân loại đối tượng.

2.1.2 Ưu điểm

Trong những năm gần đây, việc ứng dụng các mô hình học sâu, đặc biệt là mạng nơ-ron tích chập (CNN), trong lĩnh vực nông nghiệp thông minh đã đạt được nhiều thành tựu đáng kể. CNN được chứng minh là có khả năng vượt trội trong các nhiệm vụ nhận diện hình ảnh như phân loại đất, phát hiện tình trạng thiếu nước, lập bản đồ năng suất, phân loại cây trồng – cỏ dại và nhận dạng sâu bệnh. Nhờ khả năng học trực tiếp từ dữ liệu lớn và trích xuất đặc trưng hiệu quả, CNN mang lại độ chính xác cao hơn so với các mô hình truyền thống như SVM hay KNN.

Nhiều nghiên cứu đã xác nhận hiệu quả của CNN. Zhang và cộng sự cho thấy CNN phát hiện cỏ dại với độ chính xác 96,88%, cao hơn hẳn so với SVM (89,4%). Liang và nhóm nghiên cứu của mình cũng xây dựng hệ thống nhận dạng cỏ dại sử dụng kiến trúc CNN và chứng minh CNN hoạt động tốt hơn các phương pháp trích xuất đặc trưng như LBP và HoG. Tương tự, Nkemelu et al. so sánh CNN với KNN và SVM trong phân loại cây giống, kết quả CNN đạt 92,6% – vượt trội so với hai mô hình còn lại. Pearlstein và cộng sự cũng chứng minh CNN có thể nhận diện chính xác cây trồng dù có vật thể che khuất.

Từ các dẫn chứng trên, có thể thấy CNN là mô hình lý tưởng trong các bài toán xử lý ảnh nông nghiệp. Do đó, nghiên cứu này đề xuất sử dụng CNN như một kiến trúc mô hình cơ sở. Tuy nhiên, việc triển khai CNN trong các dự án thực tế vẫn

gặp một số khó khăn. Phần tiếp theo của bài viết sẽ tập trung phân tích những thách thức này và đề xuất các giải pháp triển khai phù hợp.

2.1.3 Khó khăn

Mặc dù các nghiên cứu ứng dụng mạng học sâu trong nhận dạng sâu bệnh cây trồng đã đạt nhiều kết quả tích cực, việc triển khai các mô hình này trong thực tế vẫn đối mặt với nhiều thách thức. Hầu hết các mô hình hiện tại được huấn luyện trên tập dữ liệu lý tưởng – sạch, có điều kiện ánh sáng chuẩn và ít nhiễu – nên khi áp dụng vào môi trường thực tế với biến đổi khí hậu, điều kiện canh tác đa dạng, giống cây khác nhau và triệu chứng bệnh không ổn định, độ chính xác của mô hình bị suy giảm đáng kể. Các yếu tố như độ ẩm, ánh sáng mặt trời, sự thay đổi màu sắc hoặc hình dạng của triệu chứng bệnh, cũng như việc nhiều bệnh có thể xuất hiện trên cùng một lá cây, đều làm tăng độ phức tạp trong nhận dạng hình ảnh.

Một khó khăn khác là mạng CNN yêu cầu lượng dữ liệu lớn để huấn luyện từ đầu. Việc thu thập, gán nhãn và kiểm tra dữ liệu rất tốn kém và mất thời gian, trong khi nếu dữ liệu không đủ lớn, mô hình có thể gặp tình trạng “quá khớp” (overfitting), làm giảm hiệu quả khi áp dụng với dữ liệu mới.

Để khắc phục vấn đề này, bài viết đề xuất ứng dụng học chuyển giao (transfer learning) – kỹ thuật sử dụng lại mô hình đã được huấn luyện trước để giải quyết nhiệm vụ tương tự trong một ngữ cảnh mới. Phương pháp này giúp giảm đáng kể dữ liệu huấn luyện cần thiết và tăng tính khả thi khi triển khai thực tế. Trong phạm vi nghiên cứu, nhóm tác giả đề xuất mô hình kết hợp giữa học sâu và mạng CNN như một giải pháp hiệu quả để nhận dạng sâu bệnh trong điều kiện nông nghiệp thực tế.

2.2. Học chuyển giao với mạng nơ-ron tích chập


2.2.1 Học chuyển giao

Kỹ thuật học chuyển giao đã trở thành một công cụ quan trọng trong học sâu, cho phép các mạng học sâu hoạt động tốt ngay cả khi khan hiếm dữ liệu huấn luyện hoặc tài nguyên tính toán bị hạn chế. Mohanty và cộng sự sử dụng một mô hình mạng học sâu InceptionV3 được huấn luyện trên bộ dữ liệu ImageNet để phân loại bệnh trên cây như táo, cà chua và nho. Kết quả cho thấy học chuyển giao có hiệu quả khi nhận diện các bệnh như nấm, vết đốm với độ chính xác cao, ngay cả khi bộ dữ liệu có kích thước tương đối nhỏ. Saeed và cộng sự sử dụng hai mô hình mạng InceptionV3 và ResNet được huấn luyện trên tập dữ liệu mã nguồn mở PlantVillage để phát hiện bệnh vết đốm lá cây cà chua. Kết quả nghiên cứu chỉ ra học chuyển giao có thể nâng cao độ chính xác trong nhận diện sâu bệnh ở giai đoạn sớm. Trong một nghiên cứu khác, Shafik đã ứng dụng

học chuyển giao xây dựng hai mô hình DDNet-AE và PDDNet-LVE để phát hiện và phân loại bệnh ở cây trồng. Các mô hình này hoạt động hiệu quả khi nhận diện mức độ nhiễm bệnh trên cây trồng. Như vậy các nghiên cứu này đã chứng minh kỹ thuật học chuyển giao giúp giải quyết vấn đề thiếu dữ liệu trong nhận diện bệnh trên cây trồng.

2.2.2 Học chuyển giao với mạng nơ-ron tích chập

2.2.2.1 Mô hình



Hình 1. Mô hình học chuyển giao với mạng CNN

Phương pháp học chuyển giao liên quan đến việc trích xuất tính năng cố định của một số lớp (feature extractor) và tinh chỉnh một số lớp trong mô hình đào tạo trước (fine-tuning). Các lớp trong mô hình đào tạo trước chia thành hai phần gồm các lớp được *đóng băng* (frozen layers) và các lớp được *đào tạo* (trainable layers). Các lớp đóng băng là các lớp từ mô hình đào tạo trước được giữ nguyên để giữ lại các đặc điểm chung đã học được. Các lớp được đào tạo bao gồm các lớp trong mô hình đào tạo trước chứa thông tin áp dụng cho cả nhiệm vụ gốc và nhiệm vụ mới. Những lớp này được tinh chỉnh, học các đặc trưng từ tập dữ liệu mới để mô hình đáp ứng các yêu cầu của nhiệm vụ mới. Tinh chỉnh có thể được hiểu là quá trình huấn luyện lại một số lớp bằng dữ liệu của nhiệm vụ mới. Phương pháp này giúp giữ lại kiến thức đã được đào tạo trước khi điều chỉnh các tham số để đáp ứng các yêu cầu cụ thể của tác vụ mới nhằm cải thiện độ chính xác và khả năng thích ứng của mô hình học mới.

2.2.2.2 Quy trình triển khai

Quy trình chung để triển khai xây dựng mô hình nhận diện ảnh dựa trên phương pháp học chuyển giao với mạng nơ-ron tích chập có thể phân chia thành 9 giai đoạn.

Giai đoạn 1. Thu thập và xử lý dữ liệu: Dữ liệu hình ảnh có thể lấy từ các bộ dữ liệu công khai như PlantDoc hoặc từ thiết bị thực tế như camera và drone, bao gồm cả hình ảnh cây trồng khỏe mạnh và bị bệnh. Sau đó, hình ảnh được gắn nhãn theo

Học chuyển giao với mạng nơ-ron tích chập (CNN) là phương pháp sử dụng các mô hình được đào tạo trước để giải quyết các tác vụ mới có liên quan. Hình 2 mô tả phương pháp học chuyển giao với mạng CNN, trong đó kiến trúc và kiến thức đã học được của mô hình đào tạo trước cho một nhiệm vụ có liên quan đến nhiệm vụ mới được chuyển giao để đào tạo mô hình học mới.

từng loại bệnh và xử lý để phù hợp với yêu cầu đầu vào của mô hình (chuyển sang định dạng JPEG, kích thước 224x224 hoặc 256x256 pixel). Kỹ thuật tăng cường dữ liệu như xoay, lật, dịch chuyển, thay đổi độ sáng... được sử dụng nhằm tránh hiện tượng overfitting và tăng tính khái quát cho mô hình. Dữ liệu sau đó được chia thành 3 phần: huấn luyện (70%), xác thực (10%) và kiểm tra (20%).

Giai đoạn 2. Chọn một mô hình mạng CNN : Chọn mô hình được đào tạo trước phù hợp với nhiệm vụ và tập dữ liệu: VGG16, InceptionV3, ResNet50 và EfficientNet. Các mô hình này có sẵn trong các thư viện học sâu TensorFlow hoặc PyTorch. lựa chọn mô hình CNN phù hợp. Các mô hình phổ biến như VGG16, InceptionV3, ResNet và EfficientNet được đánh giá dựa trên độ chính xác và yêu cầu phần cứng. EfficientNet đặc biệt phù hợp trong bối cảnh hạn chế tài nguyên vì có khả năng mở rộng đồng đều về độ sâu, độ rộng và độ phân giải.

Giai đoạn 3. Tải mô hình CNN: Tải mô hình CNN được đào tạo trước mà không có các lớp trên cùng

Giai đoạn 4. Đóng băng: đóng băng trọng số của các lớp được đào tạo trước để ngăn chúng bị cập nhật trong quá trình đào tạo. Điều này đảm bảo rằng các tính năng được đào tạo trước được giữ nguyên và không bị sửa đổi.

Giai đoạn 5. Điều chỉnh mô hình: thêm các lớp mới vào mô hình được đào tạo trước để điều chỉnh mô hình cho phù hợp với vấn đề đang giải quyết. Các lớp này phải có kiến trúc phù hợp cho nhiệm

vụ của mới, chẳng hạn như phải bao gồm một lớp làm phẳng (flatten layer), các lớp kết nối đầy đủ, các lớp tích chập và một lớp dày đặc với kích hoạt softmax để phân loại.

Giai đoạn 6. Huấn luyện mô hình: huấn luyện mô hình bằng cách sử dụng tập dữ liệu hiện có để huấn luyện cho các lớp mới thêm vào mô hình; các lớp được huấn luyện trước vẫn bị đóng băng.

Giai đoạn 7. Tinh chỉnh (Fine-tuning): trong trường hợp có đủ dữ liệu và muốn cải thiện hiệu suất hơn nữa, chúng ta có thể mở khóa một số lớp được đào tạo trước và tinh chỉnh chúng cùng với các lớp mới. Điều này cho phép mô hình thích ứng với các đặc trưng của tập dữ liệu đang có.

Giai đoạn 8. Đánh giá và kiểm tra mô hình: đánh giá mô hình và kiểm tra mô hình trên dữ liệu chưa biết để ước tính hiệu suất thực tế của mô hình thông qua các số liệu về độ chính xác và độ mất mát thông tin.

Giai đoạn 9. Triển khai hệ thống: khi triển khai hệ thống cần liên tục thu thập thêm dữ liệu thực tế để cập nhật mô hình.

Bên cạnh các kỹ thuật nói trên, chúng ta có thể tạo kênh thu thập dữ liệu từ cộng đồng. Khuyến khích nông dân gửi hình ảnh sâu bệnh thu thập được về cho bộ phận thu thập dữ liệu của các dự án, sau đó chuyển bộ hình ảnh này cho chuyên gia để phân tích và gắn nhãn. Chia sẻ dữ liệu giữa các dự án nghiên cứu cũng là cách để tăng dữ liệu. Hơn nữa, dữ liệu sẽ trở nên chính xác hơn nếu có nhiều bộ dữ liệu khác nhau về cùng một loại sâu bệnh được chia sẻ.

2.2.2.3 Ưu điểm của mô hình

Việc xây dựng hệ thống theo phương pháp học chuyển giao giúp giảm đáng kể nhu cầu về một tập dữ liệu lớn đã được gắn nhãn, thông qua việc tận dụng các mô hình đã được huấn luyện trước trên những tập dữ liệu quy mô lớn như ImageNet. Cách tiếp cận này đặc biệt hiệu quả trong các tình huống mà dữ liệu huấn luyện bị hạn chế, cho phép

đào tạo mô hình với hiệu suất cao ngay cả khi lượng dữ liệu đầu vào không đầy đủ.

Học chuyển giao hoạt động bằng cách khai thác kiến thức thu được từ nhiệm vụ nguồn trong mô hình huấn luyện trước, nhằm cải thiện hiệu suất đối với nhiệm vụ mục tiêu. Các mô hình đã được huấn luyện trước có khả năng trích xuất các đặc trưng phổ quát từ ảnh đầu vào, do đó quá trình tinh chỉnh (fine-tuning) trên tập dữ liệu cụ thể trở nên nhanh chóng và hiệu quả hơn so với các phương pháp học máy truyền thống. Ngoài ra, phương pháp này còn giúp giảm thiểu đáng kể chi phí tính toán trong quá trình huấn luyện. Bằng cách tận dụng các mạng CNN được huấn luyện trước, mô hình không chỉ đạt được khả năng khái quát hóa tốt hơn mà còn tăng cường tính ứng dụng trong các điều kiện thực tiễn, đặc biệt là trong bối cảnh triển khai tại những khu vực hạn chế về tài nguyên và dữ liệu.

III. KẾT LUẬN

Trong bài báo này, tác giả đã tiến hành phân tích và đánh giá một số nghiên cứu ứng dụng các mô hình học sâu trong lĩnh vực nhận diện ảnh, đặc biệt là mạng nơ-ron tích chập (CNN). Qua đó, bài báo làm rõ các ưu điểm, hạn chế của việc sử dụng CNN trong điều kiện dữ liệu hạn chế, đồng thời phân tích tiềm năng của phương pháp học chuyển giao trong việc cải thiện hiệu suất mô hình. Trên cơ sở đó, chúng tôi đã đề xuất một mô hình tổng quát ứng dụng học chuyển giao kết hợp với mạng CNN để xây dựng hệ thống nhận diện ảnh phục vụ cho việc phát hiện bệnh trên cây trồng. Hướng nghiên cứu tiếp theo sẽ tập trung vào việc thu thập dữ liệu hình ảnh thực tế về sâu bệnh, tiến hành huấn luyện và đánh giá mô hình trên các loại cây trồng cụ thể như lúa và một số cây nông nghiệp khác. Với mô hình được đề xuất, chúng tôi kỳ vọng sẽ góp phần cung cấp một giải pháp hiệu quả, dễ triển khai và phù hợp với điều kiện thực tiễn tại tỉnh Phú Yên.

TÀI LIỆU THAM KHẢO

- Ngọc Hân. Chủ động phòng trừ sâu bệnh hại lúa đồng xuân. Phú Yên Online. 2025. Truy cập ngày 5/4/2025. <https://baophuyen.vn/>
- Abdel-Hamid, O., et al. Convolutional Neural Networks for Speech Recognition. IEEE/ACM Trans. Audio, Speech, and Language Processing, 2014.
- Kamilaris, A. and Prenafeta-Boldú, F.X. Disaster monitoring using unmanned aerial vehicles and deep learning. arXiv, 2018.
- Senan, N., et al. An Efficient Convolutional Neural Network for Paddy Leaf Disease and Pest Classification. IJAC-SA, 2020. 11(7).
- Zhang, W., et al. Broad-Leaf Weed Detection in Pasture. In Proc. of 3rd IEEE ICIVC, 2018.
- Liang, W.-C., Yang, Y.-J., Chao, C.-M. Low-Cost Weed Identification System Using Drones. In Proc. of 7th IEEE CANDARW, 2019.
- Nkemelu, D.K., Omeiza, D., Lubalo, N. Deep CNN for Plant Seedlings Classification. arXiv, 2018.
- Pearlstein, L., Kim, M., Seto, W. CNN application to plant detection based on synthetic imagery. In Proc. of IEEE AIPR, 2016.
- Mohanty, S.P., Hughes, D.P., Salathé, M. Using deep learning for image-based plant disease detection. Front. Plant Sci, 2016. 7.
- Saeed, A., et al. Smart Detection of Tomato Leaf Diseases Using Transfer Learning-Based CNNs. Agriculture, 2023. 13(1).
- Shafik, W., et al. Using transfer learning-based plant disease classification and detection for sustainable agriculture. BMC Plant Biology, 2024. 24.