

ỨNG DỤNG MÔ HÌNH HỌC MÁY FASTER R-CNN PHÁT HIỆN NẤM ĂN ĐƯỢC VÀ KHÔNG ĂN ĐƯỢC

Trần Thu Hương⁽¹⁾

(1) Trường Đại học Thủ Dầu Một

Ngày nhận bài 21/7/2024; Chấp nhận đăng 11/9/2024

Liên hệ email: huongtt@tdmu.edu.vn

Tóm tắt

Nấm từ lâu đã được biết đến như một nguồn thực phẩm giàu dinh dưỡng, giàu chất chống oxy hóa và chất xơ. Đặc biệt là một nguồn nhiều vitamin B, selen, kẽm và đồng - các chất quan trọng trong việc sản xuất năng lượng trong tế bào, cần thiết cho một hệ thống miễn dịch mạnh mẽ. Đối với con người, nấm trở thành món ăn ưa chuộng trên toàn thế giới. Tuy nhiên, việc tiêu thụ nhầm nấm độc có thể dẫn đến hậu quả nghiêm trọng, bao gồm buồn nôn, nôn mửa, suy nhược thần kinh, rối loạn, thiếu máu cấp tính, thậm chí có thể dẫn tới tử vong nếu không cấp cứu kịp thời. Nhưng không phải ai cũng biết cách nhận biết nấm độc, chất độc và nấm ăn được, và rất khó để chúng ta phân biệt nấm ăn được hay nấm không ăn được, từ hình dáng bên ngoài giống nhau của chúng. Bài viết này nhằm giải quyết vấn đề bằng cách sử dụng mô hình học máy Faster Region-based Convolutional Neural Network (Faster R-CNN) để phân loại nấm ăn được và nấm độc. Mô hình Faster R-CNN được huấn luyện trên tập dữ liệu hình ảnh nấm đa dạng, tập trung vào các đặc điểm hình dạng, màu sắc và kết cấu. Sau quá trình huấn luyện, mô hình đã đạt độ chính xác ấn tượng lên đến 99,10% trong việc phân loại nấm. Kết quả này chứng minh tiềm năng của mô hình Faster R-CNN trong việc hỗ trợ người dùng nhận diện nấm an toàn, góp phần giảm thiểu nguy cơ ngộ độc và tử vong do nấm độc.

Từ khóa: học máy, Faster R-CNN, nấm ăn được, nấm độc

Abstract

APPLICATION OF FASTER R-CNN MACHINE LEARNING MODEL TO DETECTE EDIBLE AND NON-EDIBLE MUSHROOMS

Mushrooms have long been recognized as a nutritious food source, rich in antioxidants and fiber. They are also a good source of B vitamins, selenium, zinc, and copper - essential elements for cellular energy production and a strong immune system. As a result, mushrooms have become a popular culinary ingredient worldwide. However, accidental consumption of poisonous mushrooms can lead to severe consequences, including nausea, vomiting, neurological impairment, disorders, acute anemia, and even death if not treated promptly. Distinguishing between poisonous and edible mushrooms is not always easy, as their appearances can be remarkably similar. This paper aims to address this issue by utilizing the Faster Region-based Convolutional Neural Network (Faster R-CNN) machine learning model to classify edible and poisonous mushrooms. The Faster R-CNN model is trained on a diverse dataset of mushroom images, focusing on features such as shape, color, and texture. Following the training process, the model achieved an impressive accuracy of 99.10%

in mushroom classification. This result demonstrates the potential of Faster R-CNN in aiding users to identify safe mushrooms, contributing to the reduction of mushroom poisoning and related fatalities.

1. Đặt vấn đề

Nấm có tên khoa học là Fungi tiếng Anh là Mushroom, bao gồm các sinh vật nhân chuẩn dị dưỡng có tế bào cấu tạo bởi Kitin. Chúng không phải thực vật, mà thuộc giới riêng biệt. Nấm có vai trò quan trọng trong hệ sinh thái, tham gia vào quá trình phân hủy các chất hữu cơ và tạo nên mối quan hệ cộng sinh với nhiều loại thực vật. Giới nấm bao gồm rất nhiều loại khác nhau từ nấm men đơn bào đến nấm lớn như nấm rơm, nấm mỡ, nấm hương..., cho đến gần đây nhiều loại nấm đã được miêu tả dựa trên những đặc điểm hình thái, như kích cỡ và hình dạng các bào tử hay quả thể (Hibbett, Binder, Bischoff và cs., 2007). Sinh sản của nấm thường thông qua bào tử, được tạo ra trên các cấu trúc đặc biệt hoặc quả thể (như tai nấm, mũ nấm). Một số loài mất khả năng tạo ra cấu trúc sinh sản chuyên biệt và nhân lên bằng sinh sản sinh dưỡng. Các loài phổ biến nhất được ăn như rau trong nhiều bữa ăn trên khắp thế giới, một số loại nấm phổ biến nhất bao gồm: nấm mỡ, nấm rơm, nấm hương, nấm kim châm, nấm bào ngư, nấm dai, nấm đùi gà..., (Nguyễn Lâm Dũng, 2004; Friedman, 2015). Nấm có khả năng thích nghi đáng kinh ngạc, chúng phân bố trên toàn thế giới và phát triển ở nhiều loại môi trường sống khác nhau, bao gồm cả sa mạc, những nơi có nồng độ muối cao, bức xạ ion hóa (Vaupotic và cs., 2008; Dadachova và cs., 2007) cũng như trầm tích biển sâu (Raghukumar và cs., 1998). Dựa vào tỉ lệ giữa số loài nấm với số loài thực vật ở trong cùng một môi trường, người ta ước tính giới nấm có khoảng 1,5 triệu loài (Hawksworth, 2006), trong đó có khoảng hơn 300 loài nấm được liệt kê ghi nhận trong tổng số hơn 2000 loài nấm ăn được được xác định, trong đó khoảng 20 loài có thể được nuôi trồng: nấm mỡ, nấm rơm, nấm hương, nấm sò, mộc nhĩ, nấm kim châm..., (Friedman, 2015; Nguyễn Lâm Dũng, 2004). Các loài nấm quả thể được biết đến với hai dạng: nấm ăn được và nấm không ăn được, thông thường ta có thể nhận dạng nấm ăn được và không ăn được bằng cách quan sát hình thái bên ngoài của nấm (Vũ Văn Hùng và cs., 2023). Nấm ăn được: thường không có màu sắc sặc sỡ, không có bao gốc nấm và vòng cuống nấm, không có độc tố hoặc rất ít độc tố không gây hại, nấm độc: thường có màu sắc sặc sỡ hơn, có bao gốc nấm và có thêm vòng cuống nấm bao quanh thân nấm ở dưới phiến mũ nấm rõ ràng, độc tố từ ít đến cao vô cùng, sẽ gây hại nhiên (Vũ Văn Hùng và cs., 2023). Tuy nhiên, việc nhận dạng nấm ăn được và nấm độc chỉ dựa vào hình thái bên ngoài là không đủ và có thể gây nguy hiểm. Có một số loại nấm không ăn được rất giống nấm ăn được, khiến việc phân biệt bằng mắt thường trở nên khó khăn. Ví dụ, nấm rơm có thể bị nhầm với một số loại nấm độc, đặc biệt là trong giai đoạn nấm còn non và chưa nở hoàn toàn như nấm độc tán trắng, nấm mũ tử thần.

Để giải quyết vấn đề này và giảm thiểu số ca tử vong do ăn phải nấm độc, bài viết này đề xuất sử dụng một mô hình cải tiến dựa trên mạng nơ-ron tích chập Faster Region-based Convolutional Neural Networks (Faster R-CNN). Mô hình này được kỳ vọng sẽ tăng tốc độ và duy trì độ chính xác cao trong việc phân loại nấm không ăn được và nấm ăn được.

Các nghiên cứu về sử dụng mô hình Học sâu được sử dụng cho việc nhận dạng nấm được mô tả trong bảng 1.

Bảng 1. Các nghiên cứu cùng mục tiêu quan đến việc nhận dạng nấm

| Tác giả | Kiểu dữ liệu | Phương pháp | Kết quả |
|---|--|--|---------|
| G Devika và Asha Gowda Karegowda (2021) | Các hình ảnh dùng để thử nghiệm được thu thập từ các nguồn: http://www.mushroom.world và http://archive.ics.uci.edu/ml/datasets/Mushroom . | DCNN | 97.03% |
| Norbert Kiss và László Czúni (2021) | Tác giả tham lấy dữ liệu hình ảnh từ: hai nguồn dữ liệu được gắn nhãn, cụ thể là tập dữ liệu của Thử thách Phân loại nấm FGVCx 2018 (Challenge, n.d.) và hình ảnh từ trang web có tên Mushroom Observer (observer, n.d.). | Classification with CNNs | 92,6% |
| Orawan haowalit, Fuangfar Pensiri và Porawat Visutsak (2020) | Kiểu dữ liệu trong tài liệu hình ảnh nấm này được tác giả lấy từ nhiều nguồn dữ liệu khác nhau và được chụp từ máy ảnh Kỹ thuật số. | Classification by Convolution Neural Networks. | 74% |
| Wacharaphol Ketwongsa (2022) | Dữ liệu hình ảnh được sử dụng trong nghiên cứu này được tác giả thu thập trực tiếp phía đông bắc, Thái Lan là hai loại nấm: Khon Kaen và Sakon Nakhon. Được chứng nhận bởi PGS. Giáo sư Tiến sĩ Sophon Boonlue, Khoa Vi sinh, Đại học Khon Kaen. | R-CNN (ResNet-50) | 99.50% |

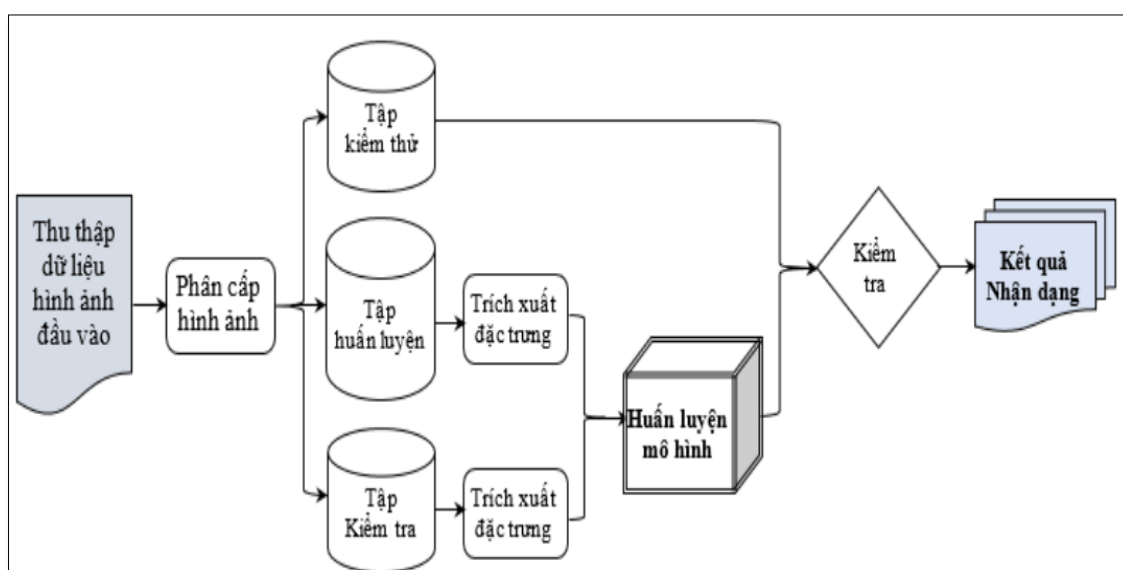
2. Tổng quan

Bài viết này trình bày một chiến lược nhận dạng đối tượng để nhận dạng nấm ăn được và không ăn được từ hình ảnh trong bộ dữ liệu huấn luyện. Đầu ra yêu cầu là xác định vị trí của nấm ăn được trong ảnh và liệu chúng có thực sự ăn được hay không. Đầu vào có thể là hình ảnh hoặc video chứa một hoặc nhiều đối tượng, từ đó các đặc trưng có thể được xuất ra. Bằng cách xử lý các hình ảnh đầu vào với nhiều lớp tích chập (convolutional layers) và lớp tổng hợp (pooling layers), mạng nơ-ron tích chập (CNN) có thể trích xuất các đặc trưng hình ảnh quan trọng, chẳng hạn như hình dáng, màu sắc, kết cấu. Các đặc trưng này được học từ dữ liệu và có thể được sử dụng để phân loại hoặc nhận dạng các đối tượng trong ảnh. Trong trường hợp phân loại nấm ăn được và nấm không ăn được, CNN có thể học cách nhận biết các đặc điểm đặc trưng của các loại nấm (mũ nấm, phiến nấm, màu sắc), sau khi được huấn luyện trên tập dữ liệu nấm đã được gắn nhãn, CNN có thể dự đoán xem một hình ảnh nấm mới là nấm ăn được hay nấm độc với độ chính xác cao. Fast R-CNN (Shaoqing Ren và cs., 2016) được tạo ra từ điều này, bao gồm hai giai đoạn chính. Tìm kiếm bộ lọc được sử dụng trước tiên để tìm các hộp giới hạn phù hợp nhất (được gọi là Vùng quan tâm hoặc RoI), sau đó CNN được sử dụng để trích xuất các hộp giới hạn. Để tìm các khu vực được đề xuất, R-CNN được kết hợp với một chiến lược tìm kiếm chọn lọc, đóng vai trò là nền tảng cho Fast R-CNN. (Inkyu Sa và cs., 2016) đề xuất sử dụng phương pháp mạng nơ-ron tích chập để huấn luyện mô hình nhận dạng trái cây trong “Hệ thống phát hiện trái cây sử dụng mạng nơ-ron sâu”. (Byoungjun Kim và cs., 2021) đề xuất một phương pháp cải tiến dựa trên thị giác để phát hiện bệnh Dâu tây bằng cách sử dụng mạng nơ-ron sâu (DNN) có khả năng được tích hợp vào hệ thống robot tự động. Jose Luis Rojas-Aranda và cs. (2020) đã trình bày một phương pháp phân loại hình ảnh, dựa trên mạng nơ-ron tích chập (CNN) nhẹ để tăng độ chính xác phân loại, các đặc trưng đầu vào khác nhau được thêm vào kiến trúc CNN. (Changqing Cao và cs., 2019) đề xuất một thuật toán cải tiến dựa trên CNN dựa trên

vùng nhanh hơn (Faster R-CNN) để phát hiện vật thể nhỏ. Tang Yunchao và cs. (2020) đề xuất một phương pháp đào tạo dựa trên mạng nơ-ron sâu để phát hiện trái cây từ ảnh. Muresan và Oltean (2018) đề xuất sử dụng mạng nơ-ron tích chập (CNN) với thị giác máy tính để tạo ra một hệ thống nhận dạng trái cây. Có rất nhiều nghiên cứu sử dụng mô hình nhận dạng CNN và các mô hình cải tiến được đề xuất để áp dụng trong phát hiện và nhận dạng hình ảnh kỹ thuật số (Yuting Zhang và cs., 2015; Nguyễn Hà Huy Cường và cs., 2021). Việc nhận dạng và phân loại nấm là một công việc khó khăn thử thách, cần phải có một công cụ nhận dạng hiệu quả để nhận dạng nấm độc và không độc. Trong bài viết này, đề xuất một giải pháp công nghệ có sử dụng Faster R-CNN bổ sung tham khảo để xây dựng mô hình dự đoán nấm độc hay nấm ăn được. Mô hình phân loại được xây dựng bằng Faster R-CNN có thể phân loại trong hoàn cảnh thực tế, chẳng hạn như khi thực hiện các thử nghiệm về nông nghiệp thì thủ tục phân loại sẽ được thực hiện trên bộ phân loại đã được huấn luyện để tìm nấm độc hay không độc. Grishick (2021), Shaoqing Ren và Kaiming He (2015) bổ sung tham khảo để xây dựng mô hình dự đoán nấm độc hay nấm ăn được.

3. Phương pháp đề xuất

Trong bài viết này, toàn bộ quá trình được chia thành ba giai đoạn: i) tiền xử lý dữ liệu; ii) huấn luyện mô hình; iii) đánh giá kết quả, sơ đồ được hiển thị trong hình bên dưới



Hình 1. Quy trình thiết kế hệ thống nhận dạng nấm ăn được và nấm độc

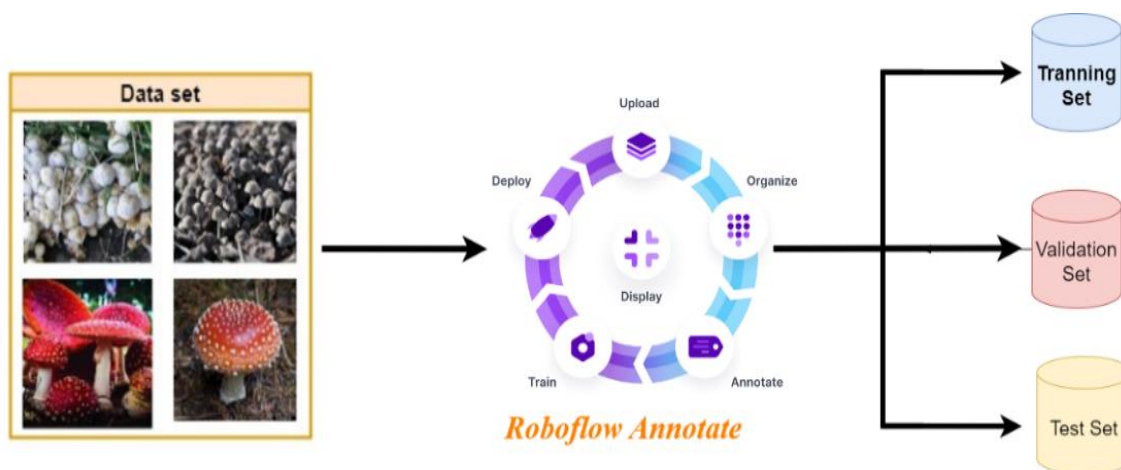
i) **Tiền xử lý dữ liệu:** Giai đoạn này bao gồm các bước như thu thập dữ liệu hình ảnh nấm, làm sạch dữ liệu, chuẩn hóa kích thước ảnh và tăng cường dữ liệu để làm phong phú thêm tập dữ liệu huấn luyện.

ii) **Huấn luyện mô hình:** Ở giai đoạn này, mô hình Faster R-CNN cải tiến sẽ được huấn luyện trên tập dữ liệu đã qua tiền xử lý. Quá trình huấn luyện sẽ điều chỉnh các tham số của mô hình để nó có thể học cách phân biệt các đặc trưng của nấm ăn được và nấm độc.

iii) **Đánh giá kết quả:** Sau khi huấn luyện, mô hình sẽ được đánh giá trên một tập dữ liệu riêng biệt để kiểm tra hiệu suất và độ chính xác của nó trong việc phân loại nấm.

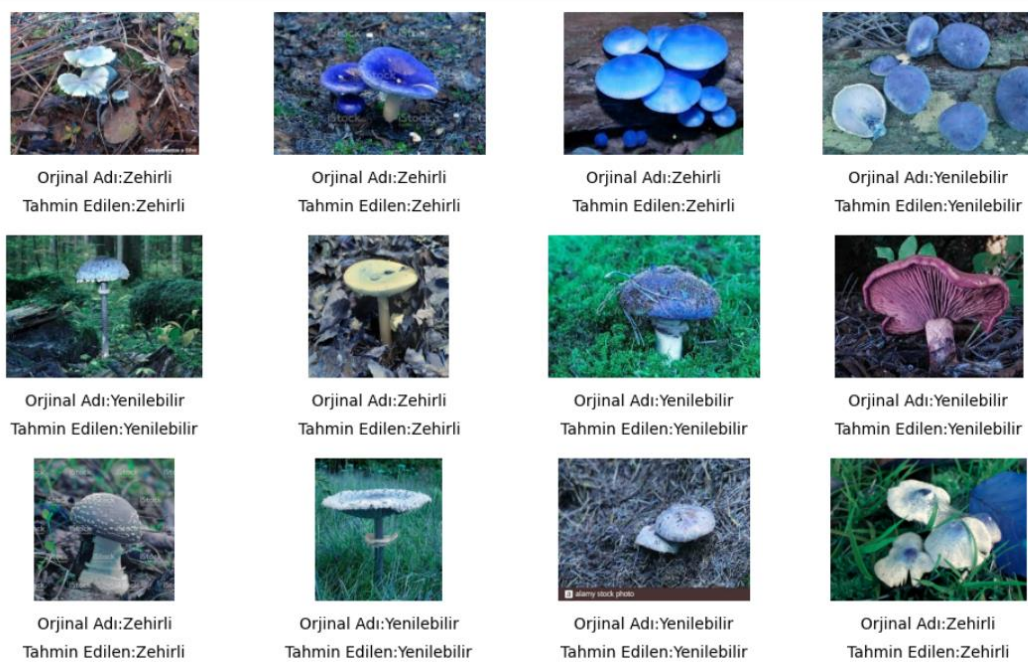
3.1. Giai đoạn 1: Thu thập và xử lý dữ liệu

Trong giai đoạn này, tôi đã thu thập một lượng lớn hình ảnh nấm ăn được và nấm không ăn được từ nguồn (Marcos Volpato, 2021), tập dữ liệu có hơn 3.000 hình ảnh của nấm ăn được và không ăn được: gồm 1.181 nấm ăn được và 2.220 nấm không ăn được. Để tăng cường khả năng khái quát hóa của mô hình, nghiên cứu này đã áp dụng các kỹ thuật tăng cường dữ liệu như xoay ảnh, cắt ảnh, làm sắc nét, điều chỉnh độ tương phản và độ sáng. Công cụ Roboflow Annotate đã được sử dụng để tự động gán nhãn cho các hình ảnh, giúp tiết kiệm thời gian và công sức so với việc gán nhãn thủ công. Công cụ Roboflow Annotate được sử dụng để tự động gán nhãn dữ liệu, giúp đơn giản hóa việc xử lý ảnh thô thành mô hình thị giác máy tính để triển khai đào tạo và dùng đặt tên cho các ảnh thu thập được. Tập dữ liệu nấm được chia thành ba phần: tập huấn luyện, tập xác định và tập kiểm tra, với các tỷ lệ lần lượt là 0,8; 0,1 và 0,1. Mục tiêu chính của học máy là xây dựng mô hình có khả năng khái quát hóa tốt, tức là hoạt động tốt trên dữ liệu mới chưa từng gặp trong quá trình huấn luyện. Việc chia dữ liệu thành các tập riêng biệt giúp đánh giá khả năng này một cách khách quan hơn. Tất cả hình ảnh đã được xử lý để loại bỏ dữ liệu sai, sau đó được xác định và lưu vào các thư mục khác nhau. Đây là một tỷ lệ phân chia khá phổ biến và thường được sử dụng khi kích thước tập dữ liệu đủ lớn. Tỷ lệ này đảm bảo tập huấn luyện đủ lớn để mô hình học được các đặc trưng quan trọng, đồng thời tập xác thực và tập kiểm tra đủ lớn để đánh giá mô hình một cách đáng tin cậy. Việc lựa chọn tỷ lệ này dựa trên kinh nghiệm thực tế và các nghiên cứu trước đây trong lĩnh vực học máy. Tỷ lệ 80% cho tập huấn luyện đảm bảo mô hình có đủ dữ liệu để học các đặc trưng quan trọng. Tập xác thực (10%) giúp đánh giá mô hình trong quá trình huấn luyện và điều chỉnh các siêu tham số. Cuối cùng, tập kiểm tra (10%) được sử dụng để đánh giá hiệu suất cuối cùng của mô hình trên dữ liệu chưa từng thấy.



Hình 2. Giai đoạn xử lý Tập dữ liệu hình ảnh nấm bằng Roboflow Annotate

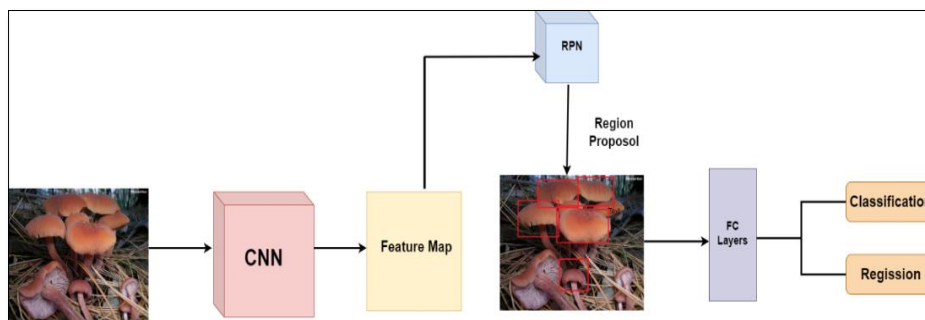
Tập huấn luyện được sử dụng để phù hợp với mô hình, tập xác thực được sử dụng để điều chỉnh các tham số của mô hình và đánh giá sơ bộ hiệu năng của mô hình, bộ kiểm tra cuối cùng được sử dụng để xác nhận khả năng khái quát của mô hình. Công cụ này có thể tạo ra một hình chữ nhật xung quanh nấm có thể nhìn thấy được. Kết quả không chỉ thu được các hộp giới hạn mà còn có các pixel của nấm dựa trên đặc điểm hình thái của chúng như: vảy nấm, mũ nấm, phiến nấm, màu sắc... Đầu ra cuối cùng sẽ là tập dữ liệu có chú thích được lưu dưới dạng Microsoft COCO từ Roboflow. Tiếp theo sẽ thay đổi kích thước của ảnh thành 224×224×3 làm đầu vào của mô hình.



Hình 3. Hình ảnh mẫu của các loại nấm

3.2. Giai đoạn 2: Xây dựng mô hình dự đoán

Mục tiêu của nghiên cứu này là trình bày một phương pháp kỹ thuật hiệu quả để nhận dạng nấm, đặc biệt tập trung vào việc sử dụng và cải tiến mô hình Faster R-CNN nhằm tăng tốc độ phát hiện đối tượng và đảm bảo độ chính xác cao trong quá trình phân loại nấm ăn được và nấm độc.



Hình 4. Giai đoạn huấn luyện bằng Kiến trúc hệ thống Faster R-CNN

Faster R-CNN là một mô hình học sâu mạnh mẽ trong lĩnh vực thị giác máy tính, đặc biệt là trong bài toán phát hiện đối tượng. Mô hình này sử dụng một mạng lưới đề xuất vùng (Region Proposal Network - RPN) để tạo ra các vùng ứng viên có khả năng chứa đối tượng, sau đó sử dụng một mạng phân loại để xác định xem vùng đó có chứa đối tượng hay không và thuộc lớp nào.

3.3. Giai đoạn 3: Đánh giá hiệu suất

Hiệu suất của phương pháp đề xuất, được đánh giá bằng cách sử dụng độ chính xác phân loại (Classification Accuracy) làm thước đo chính. Độ chính xác phân loại được định nghĩa là tỷ lệ phần trăm số lượng hình ảnh nấm được phân loại chính xác trên tổng số hình ảnh trong tập dữ liệu kiểm tra:

$$Accuracy = \frac{Correct\ classification}{The\ number\ of\ entire\ instance}$$

$$IoU = \frac{Area\ of\ Overlap}{Area\ of\ Union} \quad (1) \qquad IoU = \frac{TP}{(TP + EP + FN)} \quad (2)$$

$$Precision = \frac{TP}{TP + FP'} \quad (3) \qquad Recall = \frac{TP}{TP + FN} \quad (4)$$

Trong đó:

▪ **TP (True Positive):** Số điểm ảnh được phân loại đúng là dương tính (ví dụ: điểm ảnh thuộc về một đối tượng).

▪ **FP (False Positive):** Số điểm ảnh bị phân loại sai là dương tính (ví dụ: điểm ảnh nền được phân loại là một phần của đối tượng).


▪ **FN (False Negative):** Số điểm ảnh bị phân loại sai là âm tính (ví dụ: điểm ảnh thuộc về một đối tượng nhưng bị phân loại là nền).

• Công thức Accuracy là cách tính độ chính xác trong các bài toán phân loại của học máy (Machine learning). Cụ thể, độ chính xác được tính bằng tỷ lệ giữa số lượng mẫu được phân loại đúng (correct classification) và tổng số lượng mẫu trong tập dữ liệu (the number of entire instance).

• IoU: công thức tính Intersection over Union (IoU), một độ đo được sử dụng để đánh giá độ chính xác của các mô hình trong các tác vụ thị giác máy tính như phát hiện đối tượng và phân đoạn ngữ nghĩa. Tỷ lệ giữa diện tích giao nhau (Area of Overlap) của vùng được dự đoán và vùng ground truth (nhãn thực tế), chia cho diện tích hợp (Area of Union) của cả hai vùng.

• Average Precision (AP) là diện tích của đồ thị bao gồm Precisions, Recall và mAP là diện tích trung bình của toàn bộ đồ thị.

Nghiên cứu này đã trình bày một hệ thống nhận dạng nấm dựa trên mô hình học máy Faster R-CNN. Hệ thống này đã được huấn luyện trên một tập dữ liệu ảnh nấm đa dạng và đã thể hiện khả năng phân tích, đánh giá hình ảnh nấm một cách hiệu quả. Kết quả thực nghiệm cho thấy mô hình có thể hỗ trợ mọi người trong việc phân loại nấm ăn được và nấm độc, góp phần giảm thiểu nguy cơ ngộ độc nấm và mang lại lợi ích thiết thực cho sức khỏe cộng đồng.



Hình 5. Mô phỏng khả năng nhận dạng nấm bằng thuật toán Faster R-CNN

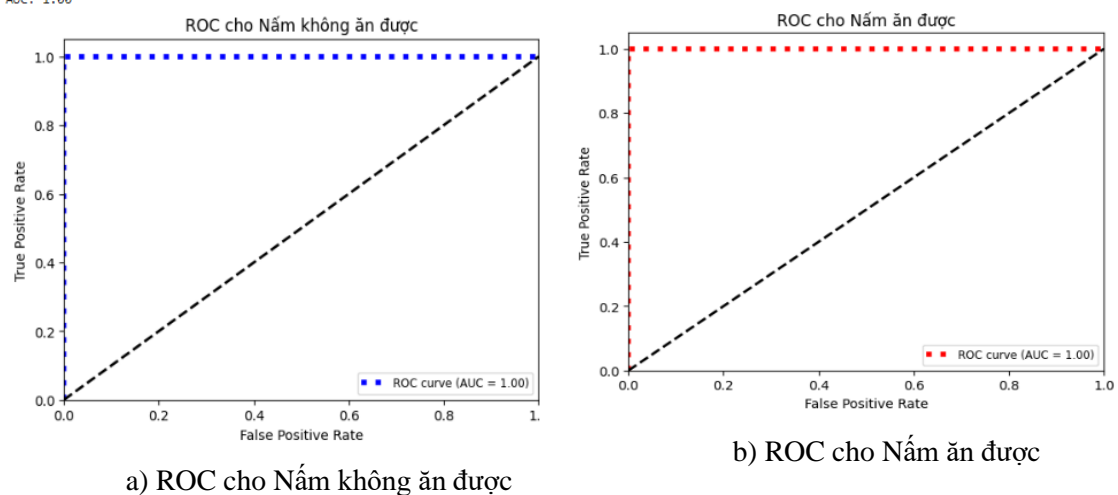
Nghiên cứu này đã chỉ ra rằng quá trình trích xuất đặc trưng có ảnh hưởng đáng kể đến độ chính xác của mô hình nhận dạng nấm. Việc lựa chọn mô hình trích xuất đặc trưng phù hợp là rất quan trọng để đạt được hiệu suất tối ưu. Tuy nhiên, cần lưu ý rằng không phải tất cả các mô hình có độ chính xác cao đều phù hợp để sử dụng trong các ứng dụng thời gian thực, do sự đánh đổi giữa độ chính xác và tốc độ xử lý.

• **Nấm ăn được:**


▪ AP: 51.222

▪ F1-score, Recall, Precision, Specificity, Accuracy, AUC: đều đạt 1.00

Có thể thấy rằng, đây là kết quả đánh giá cho thấy mô hình hoạt động khá tốt trong việc phát hiện các đối tượng thuộc lớp "mushroom-rqSL", đặc biệt là khi yêu cầu về độ chồng lấp (IoU) không quá cao.



Hình 8. Biểu đồ ROC đánh giá hiệu suất của mô hình phân loại



Hình 9. Kết quả hình ảnh nhận dạng bằng thuật toán Faster R-CNN

3.5. So sánh hiệu năng với các mô hình khác

Các kết quả của mô hình đề xuất còn được so sánh với kết quả dự đoán cùng chức năng như nghiên cứu của tác giả Devika và Asha Gowda Karegowda (2021), Norbert Kiss và László Czúni (2021), Orawan haowalit, Fuangfar Pensiri và Porawat Visutsak (2020), Wacharaphol Ketwongsa (2022). Các độ đo hiệu năng của mô hình đề xuất được liệt kê chi tiết ở bảng 2.

Bảng 2. So sánh hiệu năng của mô hình đề xuất với các tác giả khác

| Bộ phân lớp | Kỹ thuật sử dụng | Accuracy | Precision (Specificity) | Recall (Sensitivity) | F1-Score |
|--|--|----------|-------------------------|----------------------|----------|
| Mô hình đề xuất | Faster R-CNN | 1.00 | 1.00 | 1.00 | 1.00 |
| G Devika và Asha Gowda Karegowda | DCNN | 0.973 | 0.90 | - | - |
| Norbert Kiss và László Czúni (2021), | Classification with CNNs | 0.926 | - | - | - |
| Orawan Chaowalit, Fuangfar Pensiri và Porawat Visutsak (2020), | Classification by Convolution Neural Networks. | 0.74 | 0.73 | 0.73 | 0.74 |
| Wacharaphol Ketwongsa (2022). | R-CNN (ResNet-50) | 0.995 | - | - | - |

4. Kết luận

Bằng cách sử dụng và cải tiến mô hình Faster R-CNN, hệ thống đã đạt được độ chính xác cao (99.10%) trong việc phân loại nấm ăn được và nấm độc, đồng thời có tốc độ xử lý nhanh (xấp xỉ 0.1 giây/ảnh). Kết quả này cho thấy tiềm năng ứng dụng thực tiễn của hệ thống trong việc hỗ trợ nông dân và người tiêu dùng nhận biết nấm một cách an toàn và hiệu quả, góp phần giảm thiểu nguy cơ ngộ độc nấm.

Mô hình Faster R-CNN có khả năng vượt trội trong việc phát hiện và phân loại đối tượng với độ chính xác cao, đặc biệt khi được cải tiến để phù hợp với bài toán cụ thể. Tuy nhiên, mô hình này cũng có một số hạn chế như yêu cầu tài nguyên tính toán lớn và có thể gặp khó khăn khi xử lý các hình ảnh có chất lượng thấp hoặc bị nhiễu.

TÀI LIỆU THAM KHẢO

- [1] David S. Hibbett, Manfred Binder, Joseph F. Bischoff et al. (2007). A higher level phylogenetic classification of the Fungi. *Mycol. Res*, 111(5), 509-547. DOI:10.1016/j.mycres.2007.03.004.
- [2] Nguyễn Lâm Dũng (2004). *Công Nghệ nuôi trồng Nấm*. NXB Nông nghiệp.
- [3] Friedman, M. (2015). Chemistry, nutrition, and health-promoting properties of *Hericium erinaceus* (lion’s mane) mushroom fruiting bodies and mycelia and their bioactive compounds. *Journal of agricultural and food chemistry*, 63(32), 7108-7123.
- [4] Votic.T, Veranic.P, Jenoe.P, Plemenitas.A. (2008). Mitochondrial mediation of environmental osmolytes discrimination during osmoadaptation in the extremely halotolerant black yeast *Hortaea werneckii*. *Fungal Genetics and Biology*, 45(6), 994-1007. DOI:10.1016/j.fgb.2008.01.006. PMID 18343697
- [5] Dadachova.E, Bryan. RA, Huang.X, Moadel.T, Schweitzer.AD, Aisen.P, Nosanchuk. JD, Casadevall. A. (2007). Ionizing radiation changes the electronic properties of melanin and enhances the growth of melanized fungi. *PLoS ONE*, 2(5), e457. DOI:10.1371/journal.pone.0000457.

- [6] Raghukumar.C, Raghukumar.S. (1998). Barotolerance of fungi isolated from deep-sea sediments of the Indian Ocean. *Aquatic Microbial Ecology*, 15(2), 153-163. DOI:10.3354/ame015153.
- [7] Hawksworth.DL. (2006). The fungal dimension of biodiversity: magnitude, significance, and conservation. *Mycol. Res*, 95, 641-655.
- [8] Vũ Văn Hùng và cs. (2021). *Khoa học Tự nhiên 6*. NXB Giáo dục.
- [9] Devika. G, Asha Gowda Karegowda (2021). Identification of edible and non-edible mushroom through convolution neural network. *Atlantis Press*, 312-321.
DOI: 10.1109/ISPA52656.2021.9552053.
- [10] Norbert Kiss, László Czùni (2021). Mushroom image classification with CNNs: A case-study of different learning strategies. *IEEE*, 165-170. DOI: 10.1109/ISPA52656.2021.9552053.
- [11] Preechasuk. J, Chaowalit. O, Pensiri. F, Visutsak. P. (2019). Image analysis of mushroom types classification by convolution neural networks. *ACM Digital Library*, 82-88. DOI.org/10.1145/3375959.3375982.
- [12] Wacharaphol Ketwongsa (2022). *Comparing different of deep learning models for classification mushroom morphology* (Luận văn Thạc sĩ). Trường Đại học Khon Kaen, Thái Lan.
- [13] Shaoqing Ren, Kaiming He, Ross Girshik, Jia Sun (2016). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1137-1149. DOI: 10.1109/TPAMI.2016.2577031
- [14] Inkyu Sa, Zongyuan Faculty, Feras Dayoub el at. (2016). Deepfruits: A fruit detection system using deep neural networks. *Sensors*, 16(8), 1222. DOI https:// DOI.org/10.3390/s16081222
- [15] Byoungjun Kim, You Kyoung Han, Jong Han Park, Joonwhoan Lee (2021). Improved vision-based detection of strawberry diseases using a deep neural network. *Frontiers in Plant Science*, 11, 559172. DOI https:// DOI.org/10.3389/fpls.2020.559172
- [16] Jose Luis Rojas-Aranda, Jose Ignacio Nunez-Varela, Cuevas-Tello J.C, Gabriela Rangel-Ramirez (2020). Fruit classification for retail stores using deep learning. *Springer International Publishing*, LNIP, vol 12088, 3-13. https:// DOI.org/10.1007/978-3-030-49076-8_1
- [17] Changqing Cao, Bo Wang, Wenrui Zhang el at. (2019). An improved faster R- CNN for small object detection. *Ieee Access*, 7, 106838-106846. DOI: 10.1109/ACCESS.2019.2932731.
- [18] Yunchao Tang, Mingyou Chen, Chenlin Wang el at. (2020). Recognition and localization methods for vision-based fruit pick robots. *Frontiers in Plant Science*. Vol. 11, 510. https://doi.org/10.3389/fpls.2020.00510
- [19] Horea Muresan, Mihai Oltean (2018). Fruit recognition from images using deep learning. *Acta Universitatis Sapientiae, Informatica*, 10(1), 26-42. DOI: 10.2478/ausi-2018-0002.
- [20] Yiwen Zhang, Kihyuk Sohn, Ruben Villegas, Gang Pan, Honglak Lee (2015). Improving object detection with deep convolutional networks via bayesian optimization and structured prediction. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 249-258.
- [21] Nguyễn Hà Huy Cường, Lương Tuấn Anh, Trịnh Trung Hải, Hồ Hiếu Phan, Phayung Meesad, Nguyễn Thúy Thanh (2021). Intelligent fruit recognition system using deep learning. In *International Conference on Computing and Information Technology*. Vol. 251, 13-22. Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-79757-7_2.
- [22] Marcos Volpato (2021). Edible and Poisonous Fungi.
<<https://www.kaggle.com/datasets/marcosvolpato/edible-and-poisonous-fungi/data>>, Xem 20/06/2024.