

PHƯƠNG PHÁP HỌC CHUYỂN ĐỔI HIỆU QUẢ TRÊN ẢNH TẾ BÀO GAN VÀ RUỘT CỦA TÔM

Khổng Thị Thu Thảo*, Trần Thị Kiều, Lê Văn Thanh Vũ

Khoa Điện, Điện tử & Công nghệ vật liệu, Trường Đại học Khoa học, Đại học Huế

*Email: kttthao@hueuni.edu.vn

Ngày nhận bài: 18/6/2025; ngày hoàn thành phản biện: 15/7/2025; ngày duyệt đăng: 21/7/2025

TÓM TẮT


Trong bài báo này, chúng tôi ứng dụng phương pháp học chuyển đổi với các mô hình mạng nơ-ron tích chập sâu, nhỏ, nhẹ như MobileNet_V2, MobileNet_V3 (Small và Large) để phân loại mức dinh dưỡng của tôm nuôi dựa vào ảnh tế bào gan và ruột. Hai kỹ thuật học chuyển đổi là *Finetuning the ConvNet* và *ConvNet as fixed feature extractor* được thực thi huấn luyện và so sánh hiệu quả. Thí nghiệm được triển khai trên tập dữ liệu gồm 481 ảnh tế bào và kết quả cho thấy phương pháp *Finetuning the ConvNet* đạt được thời gian huấn luyện nhanh hơn và độ chính xác cao hơn. Mô hình MobileNet_V2 huấn luyện với phương pháp *Finetuning the ConvNet* đạt độ chính xác phân loại cao nhất 87,50%. Nghiên cứu này chứng minh tiềm năng của sự ứng dụng kỹ thuật học sâu vào quy trình theo dõi và cung cấp dinh dưỡng cho tôm nuôi nhằm mang lại năng suất cao cho các trang trại nuôi trồng.

Từ khóa: Học chuyển đổi, Mạng nơ-ron tích chập, Phân loại ảnh.

1. MỞ ĐẦU

Nuôi tôm là ngành nuôi trồng thủy sản đóng vai trò quan trọng trong sự phát triển của ngành thủy sản Việt Nam. Năm 2024, xuất khẩu tôm Việt Nam đạt gần 4 tỷ USD, kim ngạch xuất khẩu tôm chiếm 39% tổng kim ngạch xuất khẩu thủy sản với diện tích nuôi trồng cả nước chiếm hơn 700.000 ha. Với chủ trương đẩy mạnh tích hợp công nghệ thông tin và tự động hóa trong sản xuất, sự ứng dụng Internet vạn vật (IoT – Internet of Things) và trí tuệ nhân tạo (AI – Artificial Intelligence) đã và đang làm thay đổi toàn diện nền sản xuất công – nông nghiệp [1]. Trong những năm trở lại đây, việc ứng dụng AI, các kỹ thuật học máy (ML – Machine Learning) và các mô hình học sâu (DL – Deep Learning) vào sản xuất, nuôi trồng thủy sản đã không còn xa lạ với rất nhiều công trình nghiên cứu trên thế giới [2-5].

Trong ngành nuôi tôm, bên cạnh yếu tố môi trường, nguồn thức ăn và quy trình cho ăn, cũng như theo dõi quản lý việc cung cấp dinh dưỡng luôn đóng vai trò quan trọng trong sự phát triển của tôm. Cung cấp dinh dưỡng hợp lý cho từng giai đoạn phát triển của tôm sẽ mang lại năng suất cao. Ngược lại, cho tôm ăn thừa hay thiếu dinh dưỡng đều ảnh hưởng đến môi trường nuôi, sức khỏe của tôm và gây thiệt hại về năng suất nuôi trồng [6]. Để nhận biết tôm được cung cấp đủ, thừa hay thiếu dinh dưỡng, người nuôi thường dựa vào cơ quan tiêu hóa, cụ thể là gan và đường ruột, nơi hấp thu và tích trữ dinh dưỡng cho tôm phát triển [7]. Với kinh nghiệm nuôi trồng, người nuôi thường quan sát màu sắc của gan để phán đoán dinh dưỡng tôm nuôi. Tuy nhiên, phương pháp này có độ chính xác không cao, nên các trang trại ứng dụng công nghệ tiên tiến hiện nay thường giải phẫu gan và đường ruột, phân tích tế bào gan và ruột dưới kính hiển vi để các kỹ sư có thể nhận biết chính xác mức độ dinh dưỡng của tôm. Dựa vào ảnh tế bào gan và ruột (Hình 1), kỹ sư nuôi trồng có thể phân loại tôm đủ/thừa/thiếu dinh dưỡng [8], từ đó kiểm soát lượng thức ăn, đảm bảo tôm phát triển tốt.



Hình 1. Ảnh tế bào gan (a) và ảnh tế bào ruột giữa (b) được chụp dưới kính hiển vi, của tôm thẻ chân trắng được cho ăn đầy đủ và phát triển bình thường ở trang trại nuôi.

Sự ứng dụng các mô hình học sâu, cụ thể là các mạng nơ-ron tích chập (Convolutional Neural Network – CNN) vào bài toán phân loại các giống tôm đã được nghiên cứu rộng rãi như các mô hình ShrimpNet [5], Deep-ShrimpNet [4]. Ở Việt Nam, nhiều công trình đã nghiên cứu các thuật toán học máy, các mô hình CNN [9], và kỹ thuật học chuyển đổi [10] vào vấn đề phân loại bệnh tôm. Theo sự khảo sát của chúng tôi, cho đến nay, vẫn chưa có công trình nào ứng dụng CNN cho sự phân loại ảnh tế bào gan và ruột tôm bằng phương pháp học chuyển đổi.

Trong bài báo này, chúng tôi sử dụng phương pháp học chuyển đổi cho các mô hình CNN hiện đại để phân loại ảnh tế bào gan và ruột tôm trong việc nhận biết mức độ dinh dưỡng cho sự phát triển của tôm. Điều này có thể giúp các trang trại nuôi theo dõi, quản lý việc cho ăn phù hợp với từng giai đoạn phát triển của tôm, kịp thời phát hiện sự cung cấp dinh dưỡng thừa hoặc thiếu để điều chỉnh cho cả hồ nuôi. Phần còn lại của bài báo được tổ chức như sau. Chúng tôi giới thiệu các mô hình CNN được sử dụng để học

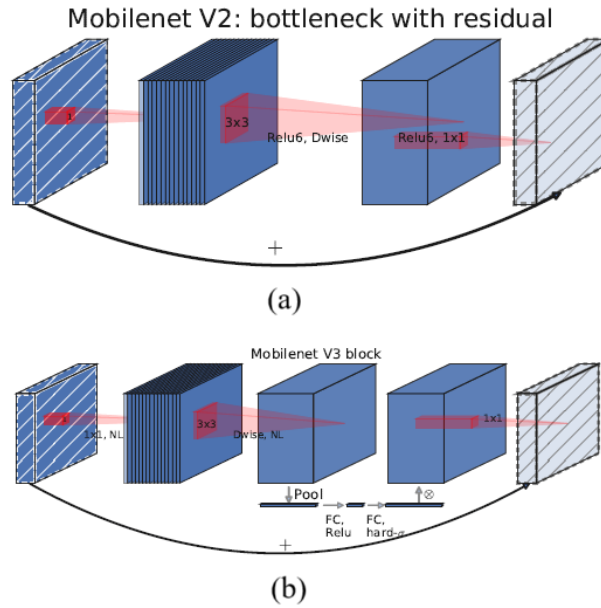
chuyển đổi trong phần 2. Thu thập và tổng hợp bộ dữ liệu ảnh tế bào gan và ruột tôm được trình bày cụ thể ở phần 3. Kết quả huấn luyện và phân loại được thảo luận trong phần 4. Phần 5 là kết luận.

2. MÔ HÌNH CNN VÀ PHƯƠNG PHÁP HỌC CHUYỂN ĐỔI

Chúng tôi lựa chọn các mô hình CNN đã được huấn luyện tốt trên tập ảnh ImageNet [11] để áp dụng kỹ thuật học chuyển đổi. ImageNet là bộ dữ liệu ảnh lớn nhất trên thế giới (hơn 14 triệu ảnh) chuyên dùng trong lĩnh vực thị giác máy tính và học sâu tăng cường hiện nay. Thêm vào đó, để áp dụng cho các trang trại nuôi tôm mà yêu cầu các thiết bị linh hoạt, nhỏ, nhẹ, chúng tôi ưu tiên các mô hình CNN có kích thước nhỏ, nhưng đạt độ chính xác cao trên ImageNet. Mô hình mà chúng tôi lựa chọn là MobileNet đã được huấn luyện trên ImageNet và sử dụng kỹ thuật học chuyển đổi để huấn luyện mô hình trên tập ảnh tế bào gan và ruột tôm.

2.1. Mô hình MobileNet

MobileNet là mô hình nhỏ gọn được thiết kế cho thiết bị biên, với các phiên bản V1, V2, V3_Small, V3_Large. Mô hình MobileNet_V2 và V3 cải tiến rất nhiều so với V1 và đạt độ chính xác tương đối cao trên ImageNet trong khi số lượng thông số và phép toán khá nhỏ. Vì vậy, chúng tôi tập trung vào 3 mô hình MobileNet_V2 [12], V3_Small, và V3_Large [13]. MobileNet_V2 sử dụng các kỹ thuật *linear bottleneck* và *inverted residual block* làm tăng hiệu quả các lớp chập và tối ưu thực thi bộ nhớ, do đó nó đạt tiến trình suy luận (inference) hiệu quả trên các ứng dụng di động. MobileNet_V3 bổ sung kỹ thuật *squeeze* và *excitation* vào cấu trúc MobileNet_V2 (Hình 2) giúp chọn lọc kênh có tính năng quan trọng, từ đó có thể làm gọn mô hình nhưng vẫn duy trì độ chính xác cao. MobileNet_V3 phát hành hai cấu trúc, đó là Small và Large, hướng đến các tác vụ sử dụng tài nguyên thấp và cao.



Hình 2. (a) MobileNet_V2 với kỹ thuật *linear bottleneck* và *inverted residual*. (b) *Squeeze* và *excitation* kết hợp với cấu trúc của MobileNet_V2 để tạo ra MobileNet_V3 [16].

Để áp dụng kỹ thuật học chuyển đổi, chúng tôi sử dụng các mô hình đã được huấn luyện tốt trên tập ImageNet với độ chính xác phân loại ảnh và số lượng tham số được mô tả trong Bảng 1.

Bảng 1. Độ chính xác Top-1 và Top-5, tổng số tham số (Params), tổng số phép toán trên giây (Giga floating point operations per second – GFLOPs) của mô hình MobileNet được huấn luyện trên tập ảnh ImageNet1K_V1 [14].

Mô hình	Top-1 (%)	Top-5 (%)	Params (triệu)	GFLOPs (tỷ)
MobileNet_V2	71,878	90,286	3,5	0,30
MobileNet_V3_Small	67,668	87,402	2,5	0,06
MobileNet_V3_Large	74,042	91,340	5,5	0,22

2.2. Phương pháp học chuyển đổi

Ngày nay, phương pháp học chuyển đổi giúp chúng ta huấn luyện các mô hình CNN nhanh hơn, ít tiêu tốn tài nguyên và kết quả huấn luyện tốt hơn. Chúng ta thường sử dụng CNN đã được huấn luyện tốt trên các tập dữ liệu lớn như ImageNet, các tham số đã được huấn luyện của các mô hình này sẽ dùng như bộ khai thác đặc tính cố định (fixed feature extractor) hoặc là tham số khởi tạo (initialization) cho dữ liệu mới [18]. Có hai phương pháp học chuyển đổi phổ biến, đó là:

- *Finetuning the ConvNet*: phương pháp này sẽ khởi tạo CNN với các tham số học đã được huấn luyện trên tập dữ liệu thông dụng, như ImageNet, và sau đó huấn luyện mô hình trên tập dữ liệu mới.

- *ConvNet as fixed feature extractor*: tất cả tham số học của mô hình được đóng băng (*freeze*) ngoại trừ lớp kết nối đầy đủ FC (*fully connected layer*) cuối, chỉ lớp này được khởi tạo ngẫu nhiên và huấn luyện trên tập dữ liệu mới.

Theo [15], phương pháp *Finetuning the ConvNet* phù hợp với tập dữ liệu mới có kích thước lớn, và ngược lại, phương pháp *ConvNet as fixed feature extractor* tương thích với tập dữ liệu nhỏ. Tập dữ liệu ảnh tế bào gan và ruột tôm của chúng tôi thu thập được có kích thước nhỏ, nhưng chúng rất khác so với tập ảnh ImageNet. Chúng tôi sử dụng các mô hình MobileNet đã được huấn luyện tốt trên ImageNet, do đó để kết luận phương pháp nào là phù hợp cho tập dữ liệu ảnh tế bào gan này, chúng tôi triển khai học chuyển đổi bằng cả hai phương pháp. Kết quả được thảo luận ở phần 4 của bài báo.

3. BỘ DỮ LIỆU ẢNH TẾ BÀO GAN VÀ RUỘT TÔM

Để thu thập ảnh tế bào cơ quan tiêu hóa của tôm, các kỹ sư ở trang trại sẽ tiến hành phân vùng hồ nuôi và chọn ngẫu nhiên các mẫu tôm, sau đó tiến hành phẫu thuật tách gan và đường ruột. Các kỹ sư nuôi trồng sẽ lấy mẫu gan và phần ruột giữa để phân tích ảnh tế bào dưới kính hiển vi. 30 ngày là dấu mốc quan trọng của quá trình nuôi tôm, đây là thời điểm cơ quan tiêu hóa phát triển hoàn chỉnh, cũng là giai đoạn tôm dễ nhiễm bệnh nhất. Do đó, các kỹ sư cần theo dõi chặt chẽ, phân phối lượng thức ăn phù hợp vì cho ăn thừa hay thiếu đều ảnh hưởng đến môi trường nuôi và sức khỏe của tôm. Các mẫu tôm được lựa chọn để phân tích ảnh tế bào có độ tuổi trên và dưới 30 ngày. Dựa vào kinh nghiệm của chuyên gia nuôi trồng, ảnh tế bào gan và ruột giữa sẽ được phân loại, và sau đó được chúng tôi tiền xử lý, loại bỏ phần thông nền thừa trên ảnh. Sau tiền xử lý, chúng tôi gán nhãn dữ liệu như sau:

- *over30_lack_liver*, *under30_lack_liver*: ảnh tế bào gan trên/dưới 30 ngày thiếu dinh dưỡng được gán nhãn.
- *over30_normal_liver*, *under30_normal_liver*: ảnh tế bào gan trên/dưới 30 ngày đủ dinh dưỡng, phát triển bình thường.
- *over30_redundant_liver*, *under30_redundant_liver*: ảnh tế bào gan trên/dưới 30 ngày thừa dinh dưỡng.
- *over30_normal_intestine*, *under30_normal_intestine*: ảnh tế bào ruột giữa trên/dưới 30 ngày đủ dinh dưỡng, phát triển bình thường.
- *over30_abnormal_intestine*, *under30_abnormal_intestine*: ảnh tế bào ruột giữa trên/dưới 30 ngày phát triển bất thường.

Bảng 2. Gán nhãn 481 ảnh tế bào gan và ruột giữa của tôm được thu thập từ trang trại.

Nhãn	Số lượng ảnh	Nhãn	Số lượng ảnh
over30_abnormal_intestine	23	under30_abnormal_intestine	73
over30_normal_intestine	25	under30_normal_intestine	69
over30_lack_liver	37	under30_lack_liver	54
over30_normal_liver	69	under30_normal_liver	78
over30_redundant_liver	31	under30_redundant_liver	22

Bộ dữ liệu ảnh tế bào gan và ruột giữa mà chúng tôi thu thập được từ trang trại là 481 ảnh và được gán nhãn như Bảng 2. Từ bộ dữ liệu đã được gán nhãn này, chúng tôi phân chia ngẫu nhiên thành 2 tập gồm tập huấn luyện (train) và tập kiểm tra (test) theo tỷ lệ 80/20 (%) tương ứng. Đây là tỷ lệ phân chia thông thường trong các ứng dụng của học máy, học sâu.

4. THÍ NGHIỆM VÀ KẾT QUẢ

4.1. Thiết lập thí nghiệm

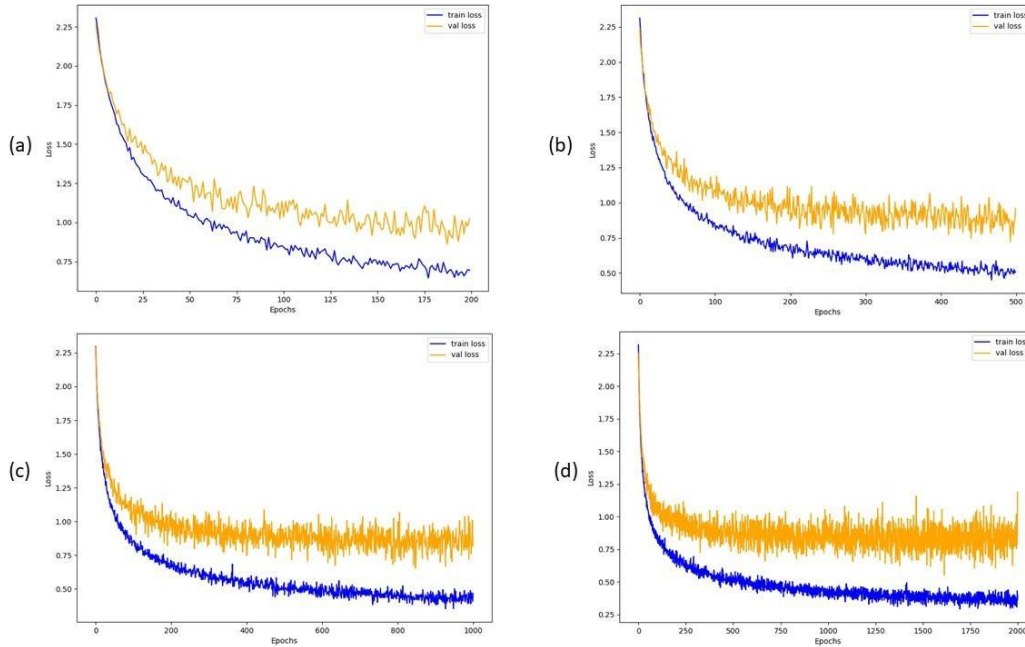
Chương trình được lập trình bởi ngôn ngữ Python, và thực thi trên Pytorch framework. Quá trình huấn luyện và kiểm tra được thực hiện trên thiết bị Intel® Core™ i9-10940 CPU và Quadro RTX8000 GPU.

Để áp dụng kỹ thuật học chuyển đổi, chúng tôi sử dụng các mô hình MobileNet_V2, V3_Small, và V3_Large đã được huấn luyện (*pre-trained*) trên tập ảnh ImageNet1K_V1. Các mô hình và tham số huấn luyện *pre-trained* được tải trực tiếp từ website [17]. Bộ dữ liệu ImageNet1K_V1 có 1000 nhãn nên các mô hình được huấn luyện trên nó sẽ có kích thước đầu ra của lớp FC cuối là 1000 nhãn phân loại. Tuy nhiên, bộ dữ liệu ảnh tế bào của chúng tôi chỉ có 10 nhãn phân loại như Bảng 2, vì vậy, chúng tôi thay đổi kích thước đầu ra của lớp FC cuối của cả ba mô hình là 10.

Chúng tôi tiến hành huấn luyện từng mô hình với hai phương pháp học chuyển đổi là *Finetuning the ConvNet* và *ConvNet as fixed feature extractor*, được đề cập ở mục 2.2. Chúng tôi giữ nguyên thuật toán tối ưu *Stochastic Gradient Descent* – *SGD* mà các mô hình đã huấn luyện trên ImageNet1K_V1.

4.2. Kết quả

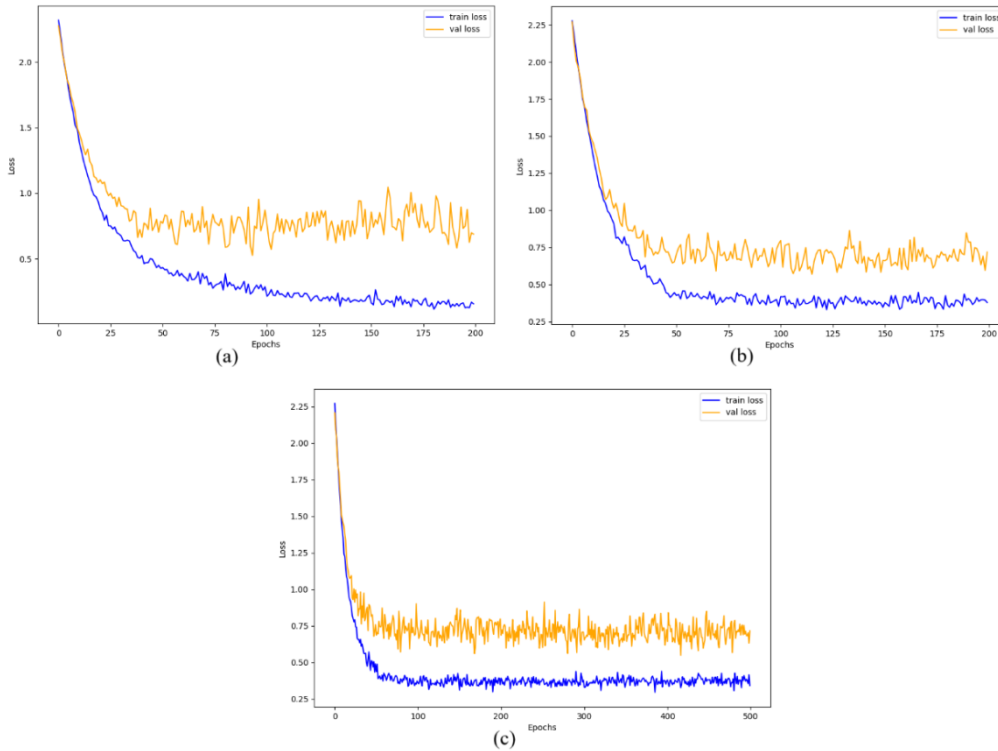
4.2.1. Tham số huấn luyện của phương pháp *ConvNet as fixed feature extractor*



Hình 3. Hàm mất mát của sự huấn luyện cho mô hình MobileNet_V2 với phương pháp *ConvNet as fixed feature extractor*. Các tham số huấn luyện được điều chỉnh như sau: Tốc độ học $lr=0,001$; Số vòng huấn luyện (epochs): (a) $epochs=200$, (b) $epochs=500$, (c) $epochs=1000$, (d) $epochs=2000$.

Chúng tôi thực hiện tiến trình huấn luyện cho mô hình MobileNet_V2 với tốc độ học khởi tạo $lr = 0,001$ và số vòng huấn luyện $epochs = 200; 500; 1000; 2000$. Kết quả hàm mất mát của sự huấn luyện và điều chỉnh tham số được minh họa trong Hình 3. Chúng ta có thể thấy tốc độ học $lr=0,001$ đảm bảo hàm mất mát hội tụ tốt đến giá trị tối ưu khi số vòng huấn luyện tăng lên. Với 2000 vòng huấn luyện thì hàm mất mát gần như bão hòa với độ chính xác huấn luyện & kiểm tra lần lượt là 87,53% và 83,93%. Với kết quả hội tụ của hàm mất mát và độ chính xác đạt được, chúng tôi chọn $lr=0,001$ và $epochs=2000$ là các tham số huấn luyện cho mô hình MobileNet_V2 với phương pháp *ConvNet as fixed feature extractor*. Chúng tôi cũng thực hiện sự huấn luyện và điều chỉnh tham số cho MobileNet_V3_Small/Large như MobileNet_V2. Kết quả hàm mất mát của MobileNet_V3_Small/Large hội tụ tốt và cũng đạt bão hòa với các tham số huấn luyện $lr=0,001$ và $epochs=2000$. Chúng tôi cố định các tham số này cho 3 mô hình huấn luyện với phương pháp *ConvNet as fixed feature extractor*.

4.2.2. Tham số huấn luyện của phương pháp *Finetuning the ConvNet*



Hình 4. Hàm mất mát của sự huấn luyện cho mô hình MobileNet_V2 với phương pháp *Finetuning the ConvNet*. Các tham số huấn luyện gồm tốc độ học (lr) và số vòng huấn luyện ($epochs$) được điều chỉnh như sau: (a) $lr=0,001$ và $epochs=200$. (b) $lr=0,001$ với 100epochs đầu và $lr=0,0001$ với 100epochs cuối. (c) $lr=0,001$ với $epochs$ 0-99; $lr=0,0001$ với $epochs$ 100-199 và $lr=0,00001$ với $epochs$ 200-500.

Sự huấn luyện của MobileNet_V2 với phương pháp *Finetuning the ConvNet* để tìm ra các tham số huấn luyện phù hợp được minh họa trong Hình 4. Ở Hình 4(a), mô hình được cố định với tốc độ học $lr=0,001$ và số vòng huấn luyện $epochs=200$, hàm mất mát lúc đầu giảm đều, nhưng sau 100 epochs thì nó có xu hướng tăng, đây là hiện tượng *overfitting* và làm cho hàm mất mát không thể hội tụ. Để tránh hiện tượng này, chúng tôi điều chỉnh tốc độ học giảm 0,1 lần sau 100 epochs đầu tiên như Hình 4(b). Sau đó, số vòng huấn luyện được tăng lên 500 epochs và tốc độ học được điều chỉnh giảm 0,1 lần sau mỗi 100 epochs và giữ $lr=0,00001$ cho đến hết 500 epochs. Với cách điều chỉnh tham số huấn luyện này, hàm mất mát hội tụ và đạt bão hòa như Hình 4(c). Tiến trình huấn luyện ở Hình 4(c) đạt độ chính xác trên tập huấn luyện và tập kiểm tra lần lượt là 94,43% và 87,50%. Độ chính xác trên tập kiểm tra của MobileNet_V2 huấn luyện với phương pháp *Finetuning the ConvNet* lớn hơn phương pháp *ConvNet as fixed feature extractor* là 3,57% trong khi chỉ cần số vòng huấn luyện bằng $\frac{1}{4}$. Với kết quả này có thể thấy rằng, phương

pháp *Finetuning the ConvNet* huấn luyện cho MobileNet_V2 mang lại hiệu quả tốt hơn trên tập ảnh tế bào gan và ruột giữa của tôm.

Chúng tôi tiến hành thí nghiệm tương tự cho MobileNet_V3_Small/Large. Hàm mất mát của mô hình MobileNet_V3_Small hội tụ và bão hòa với tốc độ học khởi tạo $lr=0,001$ và giảm $0,1$ lần sau 50 epochs. Mô hình MobileNet_V3_Small được huấn luyện với 500 epochs, tốc độ học giảm đến $lr=0,00001$ và giữ nguyên cho đến hết số vòng huấn luyện. Tham số huấn luyện của MobileNet_V3_Large được xác định như sau: tốc độ học khởi tạo $lr=0,001$ và giảm $0,1$ lần sau 100 epochs, và giữ $lr=0,00001$ cho đến hết 500 epochs.

4.2.3. Độ chính xác phân loại ảnh tế bào gan và ruột tôm

Sau khi huấn luyện các mô hình với tham số huấn luyện được mô tả trong mục 4.2.1 và 4.2.2, chúng tôi đạt được độ chính xác trên tập huấn luyện và tập kiểm tra như Bảng 3. Nhìn vào bảng, chúng ta có thể thấy kỹ thuật học chuyển đổi là hiệu quả trên tập ảnh tế bào gan và ruột của tôm khi sử dụng các mô hình đã được huấn luyện trước trên tập ảnh ImageNet.

Bảng 3. Độ chính xác cao nhất trên tập huấn luyện (*Train*) và tập kiểm tra (*Test*), và thời gian huấn luyện của các mô hình

Mô hình	<i>ConvNet as fixed feature extractor</i>			<i>Finetuning the ConvNet</i>		
	Thời gian huấn luyện (giây)	Độ chính xác (%)		Thời gian huấn luyện (giây)	Độ chính xác (%)	
		<i>Train</i>	<i>Test</i>		<i>Train</i>	<i>Test</i>
MobileNet_V2	11282,19	87,53	83,93	2881,45	94,43	87,50
MobileNet_V3_Small	11005,79	87,00	83,93	2858,43	96,02	85,71
MobileNet_V3_Large	12164,83	85,94	82,14	3143,89	95,23	85,71

Trên cả 3 mô hình áp dụng học chuyển đổi, phương pháp *Finetuning the ConvNet* vượt trội hơn so với *ConvNet as fixed feature extractor*. Bảng 3 chỉ ra rằng, với phương pháp *finetuning*, các mô hình chỉ cần sử dụng ít vòng huấn luyện với thời gian huấn luyện chỉ bằng $\frac{1}{4}$ so với phương pháp *fixed feature extractor* nhưng độ chính xác phân loại cao hơn trung bình 8% trên tập huấn luyện và 3,5% trên tập kiểm tra. Điều này giúp chúng tôi kết luận, *Finetuning the ConvNet* là phương pháp học chuyển đổi hiệu quả trên tập ảnh tế bào gan và ruột của tôm khi sử dụng các mô hình đã được *pre-trained* trên tập dữ liệu ảnh ImageNet.

Với phương pháp *Finetuning the ConvNet*, mô hình MobileNet_V3_Small có cấu trúc nhỏ nên thời gian huấn luyện của mô hình này là nhanh nhất và đạt độ chính xác

trên tập kiểm tra bằng với MobileNet_V3_Large. Trong khi đó, MobileNet_V2 có số lượng tham số và số phép toán ở mức trung bình (Bảng 1) nhưng đạt hiệu quả phân loại trên tập ảnh tế bào gan và ruột tôm với độ chính xác cao nhất trên tập kiểm tra 87,50%.

5. KẾT LUẬN

Chúng tôi đã thành công khi áp dụng kỹ thuật học chuyển đổi cho bài toán phân loại ảnh tế bào gan và ruột của tôm nuôi khi sử dụng các mô hình *pre-trained* trên tập dữ liệu ảnh ImageNet. Hai phương pháp học chuyển đổi là *Finetuning the ConvNet* và *ConvNet as fixed feature extractor* được chúng tôi triển khai và so sánh trên tập dữ liệu mới. Dựa vào kết quả huấn luyện và kiểm tra, phương pháp *Finetuning the ConvNet* là phù hợp với tập ảnh tế bào gan và ruột tôm mà chúng tôi thu thập được. Các mô hình CNN nhỏ, nhẹ là MobileNet_V2, V3_Small/Large được lựa chọn cho ứng dụng của chúng tôi với độ chính xác phân loại ảnh tế bào tốt nhất đạt được là 87,50% của mô hình MobileNet_V2 trên tập kiểm tra. Đây là sự thành công bước đầu cho việc triển khai ứng dụng các mô hình học sâu vào sự tự động hóa quy trình theo dõi dinh dưỡng tôm nuôi trong các trang trại, kịp thời phát hiện và phân loại tôm có dấu hiệu dinh dưỡng bất thường, từ đó có thể hạn chế sự ảnh hưởng trên cả hồ nuôi. Kết quả của bài báo chỉ được thực hiện trên tập dữ liệu nhỏ với các mô hình CNN nhỏ nên độ chính xác vẫn còn hạn chế. Nghiên cứu này sẽ được tiếp tục mở rộng với bộ dữ liệu thu thập lớn hơn và triển khai trên các mô hình vượt trội hơn để đạt kết quả tốt khi ứng dụng thực tế vào các trang trại nuôi tôm.

LỜI CẢM ƠN

Kết quả của nghiên cứu này được hỗ trợ từ đề tài khoa học – công nghệ cấp Đại học Huế, mã số DHH2025-01-227.

TÀI LIỆU THAM KHẢO

- [1]. Hồ Quế Hậu (2019). Cách mạng công nghiệp 4.0 ở Việt Nam: Tiềm năng, rào cản và vai trò của Nhà nước, *Kinh Tế & Phát triển*, tháng 2/2019, số 260, tr. 1-10.
- [2]. M. Sun, X. Yang, and Y. Xie (2020). Deep learning in aquaculture: A review, *J. Comput.*, Vol. 31, no. 1, pp. 294–319.
- [3]. H. Liu, X. Ma, Y. Yu, L. Wang, and L. Hao (2023). Application of deep learning-based object detection techniques in fish aquaculture: A review, *Journal of Marine Science and Engineering*, Vol. 11, no. 4, pp. 867.
- [4]. Z. Liu (2020). Soft-shell shrimp recognition based on an improved alexnet for quality evaluations, *Journal of Food Engineering*, Vol. 266, pp. 109698.

- [5]. W. C. Hu, H. T. Wu, Y. F. Zhang, S. H. Zhang, and C. H. Lo (2020). Shrimp recognition using shrimpnet based on convolutional neural network, *Journal of Ambient Intelligence and Humanized Computing*, pp. 1-8.
- [6]. T. N. H và cộng sự (2021). Nuôi tôm thẻ chân trắng siêu thâm canh ứng dụng công nghệ biofloc, *NXB. Nông nghiệp*, pp. 1-24.
- [7]. P. Hải (2021). Để gan tụy tôm không bị tổn thương. [Online]. Website: <https://thuysanvietnam.com.vn/de-gan-tuy-tom-khong-bi-ton-thuong/>.
- [8]. K. T. T. Thảo, H. Đ. Long, và P. H. Phong (2024). Phân loại dinh dưỡng tôm dựa vào ảnh tế bào gan và ruột sử dụng kỹ thuật học chuyển đổi, *Kỷ yếu Hội nghị quốc gia lần thứ XXVII về điện tử, truyền thông và công nghệ thông tin REV-ECIT*, Hà Nội, pp. 500-505.
- [9]. L. D. Quach, L. Q. Hoang, N. Trung, and C. N. Nguyen (2020). Towards machine learning approaches to identify shrimp diseases based on description, *Kỷ yếu Hội nghị KHCN quốc gia lần thứ XII về nghiên cứu cơ bản và ứng dụng công nghệ thông tin FAIR*, Huế, pp. 494-501.
- [10]. N. Duong-Trung, L. D. Quach, C. N. Nguyen (2020). Towards classification of shrimp diseases using transferred convolutional neural networks, *Advances in Science, Technology and Engineering Systems Journal*, Vol. 5, no. 4, pp. 724-732.
- [11]. ImageNet. [Online]. Website: <https://image-net.org/index.php>
- [12]. M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4510-4520.
- [13]. A. Howard, M. Sandler, G. Chu, L. C. Chen, B. Chen, M. Tan, W. Wang, Y. Zhu, R. Pang, V. Vasudevan et al (2019). Searching for mobilenetv3. *Proceedings of the IEEE/CVF international conference on computer vision*, pp. 1314-1324.
- [14]. Pytorch. Models and pre-trained weights. [Online]. Website: <https://pytorch.org/vision/stable/models.html>.
- [15]. Stanford. CS231n Convolutional Neural Networks for Visual Recognition. [Online]. Website: <https://cs231n.github.io/transfer-learning/>.

EFFICIENT TRANSFER LEARNING METHOD ON IMAGES OF LIVER AND INTESTINE CELLS OF SHRIMPS

Khong Thi Thu Thao*, Tran Thi Kieu, Le Van Thanh Vu

Faculty of Electronics, Electrical Engineering and Material Technology,

University of Sciences, Hue University

*Email: kttthao@hueuni.edu.vn

ABSTRACT

In this paper, we apply transfer learning with deep and lightweight convolutional neural networks, such as MobileNet_V2 and MobileNet_V3 (Small and Large), to classify the nutritional levels of farmed shrimp using microscopic images of liver and intestinal cells. Two transfer learning methods that are *Finetuning the ConvNet* and *ConvNet as a fixed feature extractor* are implemented to train models. The experiment results, conducted on a labeled dataset of 481 microscopic images, show that the *Finetuning* approach achieves higher accuracy with significantly shorter training time. The MobileNet_V2 model trained using *Finetuning the ConvNet* reaches the highest test accuracy of 87,50%. These findings demonstrate the potential of applying deep learning techniques to the monitoring and nutritional supply processes for farmed shrimp in order to achieve high farm productivity.

Keywords: Transfer learning, Convolutional neural networks, Image classification.