

PHÂN LOẠI UNG THƯ VÚ TRÊN ẢNH NHŨ SỬ DỤNG KỸ THUẬT HỌC SÂU VÀ MẠNG VISION TRANSFORMER

CLASSIFICATION OF BREAST CANCER ON MAMMOGRAM IMAGES USING DEEP LEARNING MODELS AND VISION TRANSFORMER

PHAN ANH CANG¹, VÕ ĐÌNH NGHĨA^{2a}

¹Trường Đại học Sư phạm Kỹ thuật Vĩnh Long

²Học viên cao học, Trường Đại học Sư phạm Kỹ thuật Vĩnh Long,

^aTác giả liên hệ: nghiavd121@gmail.com

Nhận bài(Received): 22/6/2023; Phản biện (Reviewed): 28/6/2023; Chấp nhận (Accepted): 30/7/2023

TÓM TẮT

Ung thư vú là loại ung thư được chẩn đoán phổ biến nhất và là nguyên nhân thứ năm gây tử vong ở phụ nữ. Việc phát hiện sớm căn bệnh này không chỉ tăng tỷ lệ sống sót mà còn giảm chi phí điều trị. Chụp nhũ ảnh là phương pháp chẩn đoán hình ảnh hiện nay để xác định và chẩn đoán sớm khối u ác tính ở vú. Trong bài báo này, chúng tôi đề xuất kỹ thuật phân loại dựa trên kiến trúc mạng NasNetLarge, MobileNetV2, InceptionV3, DenseNet121 và Vision Transformer để phân loại ảnh nhũ tuyến vú là bình thường, lành tính hoặc ác tính. Qua kết quả thực nghiệm cho thấy độ chính xác của mô hình đề xuất lên đến 99%.

Từ khóa: Vision Transformer, Mammography, Deep learning, Breast Cancer

ABSTRACT

Breast Cancer is the most commonly diagnosed cancer and the fifth leading cause of death in women. Early detection of this disease not only increases the survival rate but also reduces the cost of treatment. Mammography (X-ray mammography) is the current imaging method to identify and diagnose breast malignancies early. In this paper, we propose a classification technique based on network architecture NasNetLarge, MobileNetV2, InceptionV3, DenseNet and Vision Transformer to classify mammograms as normal, benign or malignant. Experimental results show that the accuracy of the proposed model is up to 99%.

Keywords: Vision Transformer, Mammography, Deep learning, Breast Cancer

1. MỞ ĐẦU

1.1. Giới thiệu bài toán

Ung thư vú đã trở thành một trong những dạng ung thư thường xảy ra ở phụ nữ. Người ta ước tính rằng 43.700 ca tử vong (43.170 phụ nữ và 530 nam giới) do ung thư vú sẽ xảy ra ở Hoa Kỳ vào năm 2023. Trên toàn thế giới, ung thư vú ở phụ

nữ là nguyên nhân gây tử vong đứng hàng thứ năm. Năm 2020, ước tính có khoảng 684.996 phụ nữ trên toàn thế giới chết vì ung thư vú.[2]. Để phát hiện và chẩn đoán chính xác ung thư vú, các bác sĩ phải đối mặt với những thách thức do họ phải kiểm tra số lượng lớn hình ảnh vú hàng ngày và khó đọc hình ảnh [1]. Việc xây dựng một

hệ thống hỗ trợ việc chẩn đoán ung thư vú nhằm tạo nhiều thuận lợi hơn cho các bác sĩ trong quá trình phân tích và chẩn đoán thông qua hình ảnh nhũ để có giải pháp điều trị kịp thời vô cùng cần thiết.

1.2. Những nghiên cứu liên quan

Dheeb Albashish và cộng sự [12] đề xuất một mô hình học chuyển đổi dựa trên mạng VGG16 được sử dụng để trích xuất các tính năng từ bộ dữ liệu hình ảnh mô bệnh học của BreakHis. Độ chính xác của mô hình đề xuất là 89%. Gayathri Girish và cộng sự [13] đề xuất mô hình phát hiện ung thư vú dựa trên hình ảnh microwave với 7 kiến trúc mạng học sâu khác nhau; kết quả của phương pháp đề xuất đạt được độ chính xác là 88.41%. Md Ishtyaq Mahmud và cộng sự [14] trình bày phương pháp phát hiện ung thư vú sử dụng các hình ảnh mô bệnh học sử dụng phương pháp học chuyển giao dựa trên các mạng học sâu như ResNet50, ResNet101, VGG16 và VGG19 với độ chính xác đạt được là 90,2%. Bitu Asadi và cộng sự [15] đề xuất mô hình phát hiện ung thư vú dựa trên kiến trúc mạng Unet với backbone ResNet sử dụng tập dữ liệu Image Retrieval trong Medical Application với 736 mẫu sinh thiết của 344 bệnh nhân. Kết quả của phương pháp đề xuất đạt được độ chính xác là 98.61%. Nhìn chung có thể thấy rằng, đa số các nghiên cứu chỉ thực hiện phân loại là ung thư hoặc không ung thư, bên cạnh đó, việc đưa ra một số kết quả kiểm thử là vô cùng cần thiết nhưng các nghiên cứu liên quan lại chưa thấy trình bày.

1.3. Đặc điểm của ung thư vú

Ung thư vú [18] là một căn bệnh về tế bào ung thư phát triển từ tế bào trong tuyến vú. Có hai loại ung thư vú chính là ung thư vú lành tính và ung thư vú ác tính. Khối u lành tính [18] dùng để chỉ một khối u nằm yên và không lan sang các bộ phận khác

của cơ thể. Khối u ác tính [18] là một khối u phát triển trong tuyến vú, có khả năng xâm lấn vào các mô xung quanh.

1.4. Các mạng nơ-ron trích xuất đặc trưng

a) *MobileNetV2*: MobileNetV2 [4] là một trong những mạng neural network được phát triển để có thể thực hiện trên các thiết bị có tài nguyên hạn chế với số lượng tham số nhỏ, điều này giúp giảm tải tài nguyên tính toán và bộ nhớ. MobileNetV2 có thể thực hiện tốc độ cao trên các thiết bị có tài nguyên hạn chế và cho phép điều chỉnh kích thước của mô hình để phù hợp với các nhu cầu ứng dụng khác nhau.

b) *Mạng InceptionV3*: InceptionV3 [3] được thiết kế để tối ưu hoá hiệu quả tính toán, giúp giảm thiểu số lượng tham số cần thiết và giảm độ phức tạp tính toán. Điều này giúp tăng tốc độ xử lý và giảm thời gian đào tạo mạng. Ngoài ra, InceptionV3 có khả năng tái sử dụng đặc trưng, tức là các trọng số học được có thể được sử dụng lại cho các tác vụ liên quan đến phân loại hình ảnh khác nhau.

c) *Mạng NASNetLarge*: NASNetLarge [5] được huấn luyện trên tập dữ liệu lớn và có khả năng tổng hợp và hiểu các đặc trưng hình ảnh phức tạp. NASNetLarge sử dụng một kiến trúc block chồng mà điều chỉnh cấu trúc mạng và các siêu tham số tự động thông qua quá trình tìm kiếm kiến trúc. Kiến trúc này cho phép mô hình học cách xây dựng các đặc trưng phân loại tốt và tối ưu hóa các siêu tham số để đạt được hiệu suất tốt nhất trên tập dữ liệu huấn luyện.

d) *Mạng DenseNet*: Dense Convolutional Network (DenseNet) [6] có mật độ kết nối dày đặc so với các mô hình khác như VGG [8] và Resnet [7]. Mỗi lớp trong DenseNet nhận thêm thông tin đầu vào từ tất cả các cấp trước đó và chuyển các bản đồ đặc

trung của chính nó cho tất cả các lớp sau. Điều này cho phép mạng mỏng hơn và nhỏ gọn hơn, dẫn đến ít kênh hơn. DenseNet có thể giảm bớt vấn đề biến mất độ dốc, nâng cao khả năng lan truyền của bản đồ đặc trưng và giảm số lượng tham số.

e) *Mạng Vision Transformer*: Vision Transformer [9] là một mạng nơ-ron được sử dụng để xử lý và phân loại hình ảnh dựa trên cơ chế tự chú ý; cho phép xử lý hình ảnh bằng cách chia ảnh thành các patch nhỏ. Điều này giúp mô hình nhận biết các đặc trưng không gian trong ảnh và mối quan hệ giữa các patch; quá trình xử lý thông tin được thực hiện dựa trên các phép chuyển đổi tuyến tính và cơ chế tự chú ý mà không yêu cầu các phép tích chập như các mạng CNN. Ngoài ra, Vision Transformer có thể mở rộng để xử lý ảnh có kích thước lớn hơn bằng cách tăng số lượng patch [10].

1.5. Các độ đo đánh giá mô hình

Accuracy [16] được đánh giá dựa trên các giá trị như true positives (TP), false positives (FP), true negatives (TN) và false negatives (FN) được mô tả theo phương trình (1). Hàm categorical cross-entropy loss $L(C,P)$ [17] với i là nhãn dữ liệu, C là giá trị thực tế và P là giá trị dự đoán. Hàm $L(C,P)$ được mô tả theo phương trình (2).

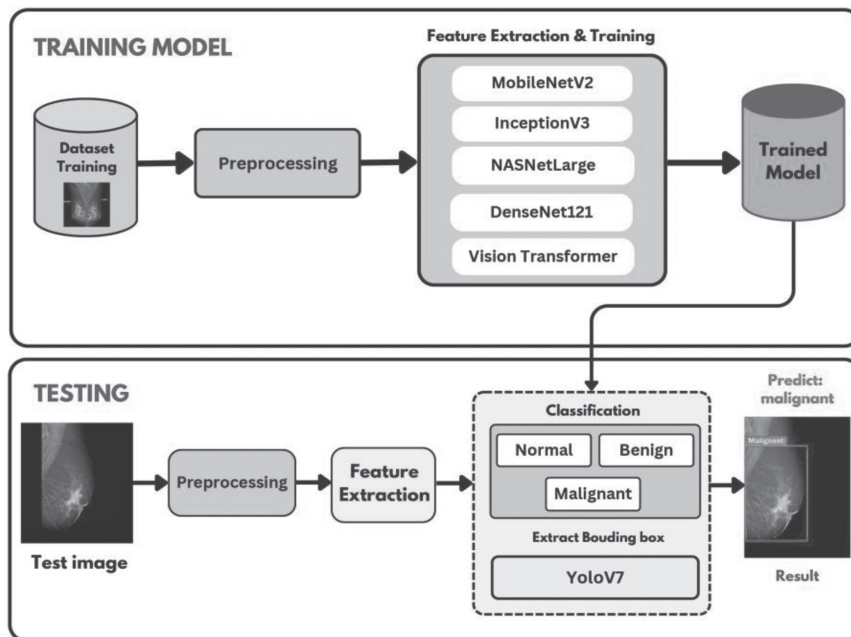
$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$L(C, P) = - \sum_i C_i \log(P_i) \quad (2)$$

2. KẾT QUẢ NGHIÊN CỨU

2.1. Phương pháp đề xuất

Mô hình đề xuất gồm 2 giai đoạn là huấn luyện và kiểm thử được thể hiện ở hình 2:



Hình 2. Mô hình đề xuất phát hiện và phân loại ung thư vú.

2.1.1. Đào tạo mô hình

a) *Tiền xử lý và chuẩn bị dữ liệu*: Chúng tôi thực hiện chuẩn hoá tất cả hình ảnh thành kích thước 224×224 pixel, đây

là kích thước phù hợp để tạo bản vá từ hình ảnh đầu vào. Sau đó, chúng tôi tiến hành tăng cường dữ liệu bằng cách thay đổi góc quay hình ảnh (xoay ảnh) và lật ảnh.

b) *Rút trích đặc trưng và huấn luyện:* Chúng tôi tiến hành rút trích đặc trưng các đặc điểm của các loại ung thư vú dựa trên ảnh nhũ sau khi được tiền xử lý và tiến hành huấn luyện bằng phương pháp học sâu sử dụng các kiến trúc mạng như NASNetLarge, MobileNetV2, InceptionV3, DenseNet121 và Vision Transformer. Đối với mô hình Vision Transformer, hình ảnh đầu vào sau khi được tiền xử lý sẽ được cắt thành cách patch đưa qua tầng liner projection với kích thước cho mỗi patch là 16×16 do tính ổn định của nó đối với sự suy giảm hiệu suất và tính phức tạp tính toán [10], mỗi patch sẽ được gán vị trí và nhãn cụ thể đảm bảo ảnh sau khi rút trích các đặc trưng sẽ không bị xáo trộn. Sau đó đưa qua transform encoder để tiến hành rút trích đặc trưng mã

hóa, phân loại và khoanh vùng lành tính và ác tính. Kết quả của quá trình này sẽ là ảnh được phân loại thuộc vào nhãn nào.

2.1.2 Kiểm thử

Ở giai đoạn kiểm thử, hình ảnh đầu vào sẽ được chuẩn hoá thành kích thích 224×224 , sau đó tiến hành đưa qua YOLOV7 để xác định vùng nhũ, vùng nhũ khi được xác định sẽ tiến hành đưa qua mô hình đã được huấn luyện để tiến hành dự đoán. Kết quả kiểm thử sẽ đưa ra một trong ba kết luận là Bình thường, Lành tính hoặc Ác tính.

2.2 Kết quả thực nghiệm

2.2.1. Các kịch bản áp dụng

Trong nghiên cứu này, chúng tôi thực hiện 5 kịch bản với các tham số trong **Bảng 1**

Bảng 1. Các kịch bản được đề xuất và các tham số huấn luyện

Kịch bản	Kiến trúc mạng	Mạng rút trích đặc trưng và phân loại	Số bước huấn luyện	Tốc độ học	Kích thước ảnh
1	MobileNetV2	Default	100	1e-3	224 x 224
2	InceptionV3	Default	100	1e-3	224 x 224
3	NasNetLarge	Default	100	1e-3	224 x 224
4	DenseNet121	Default	100	1e-3	224 x 224
5	Vision Transformer	Default	100	1e-3	224 x 224

2.2.2. Môi trường cài đặt và tập dữ liệu thực nghiệm

a. *Môi trường cài đặt:* Phương pháp đề xuất được cài đặt trên nền tảng Kaggle với thư viện hỗ trợ đào tạo mô hình mạng sử dụng là Tensorflow và Keras với ngôn ngữ lập trình Python.

b. Tập dữ liệu thử nghiệm

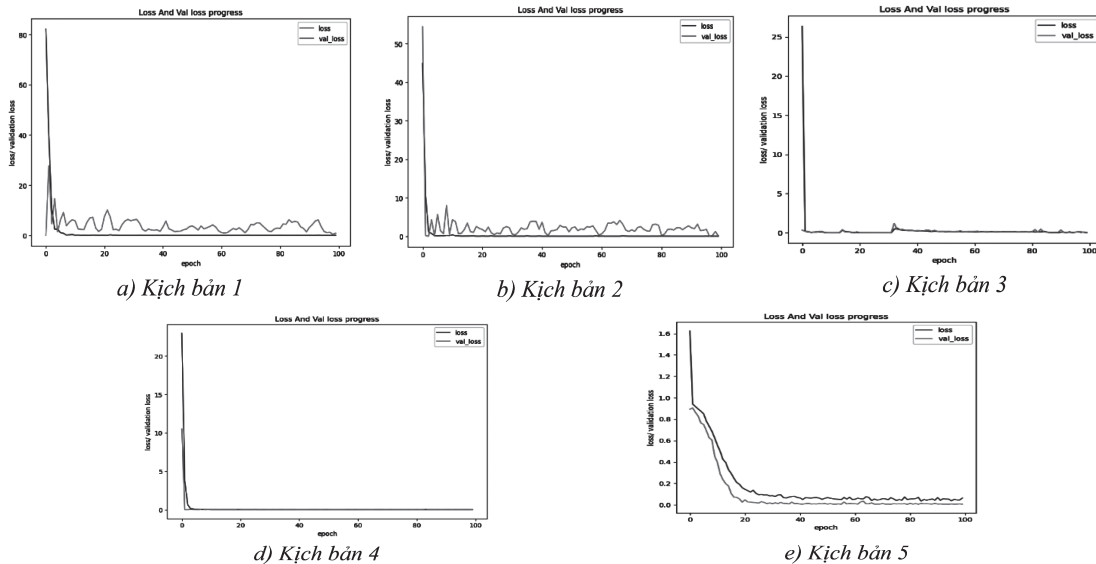
Dữ liệu đào tạo: Bộ dữ liệu sử dụng trong nghiên cứu này được lấy từ Mini-MIAS [11] bao gồm 322 hình ảnh chứa hình ảnh vú trái và phải của 161 bệnh nhân

thuộc ba loại như bình thường, lành tính và ác tính. Có 208 hình ảnh bình thường, 63 lành tính và 51 hình ảnh ác tính.

Dữ liệu kiểm thử: Để tiến hành kiểm thử độ chính xác của mô hình đào tạo chúng tôi xây dựng một tập dữ liệu kiểm thử được lấy từ Bệnh viện Phụ sản TP. Cần Thơ với 150 bệnh nhân gồm 300 hình ảnh của các loại khối u gồm 100 ảnh bình thường, 100 lành tính và 100 ác tính.

2.2.3. Các kết quả thu được

a. Độ đo Loss và Accuracy

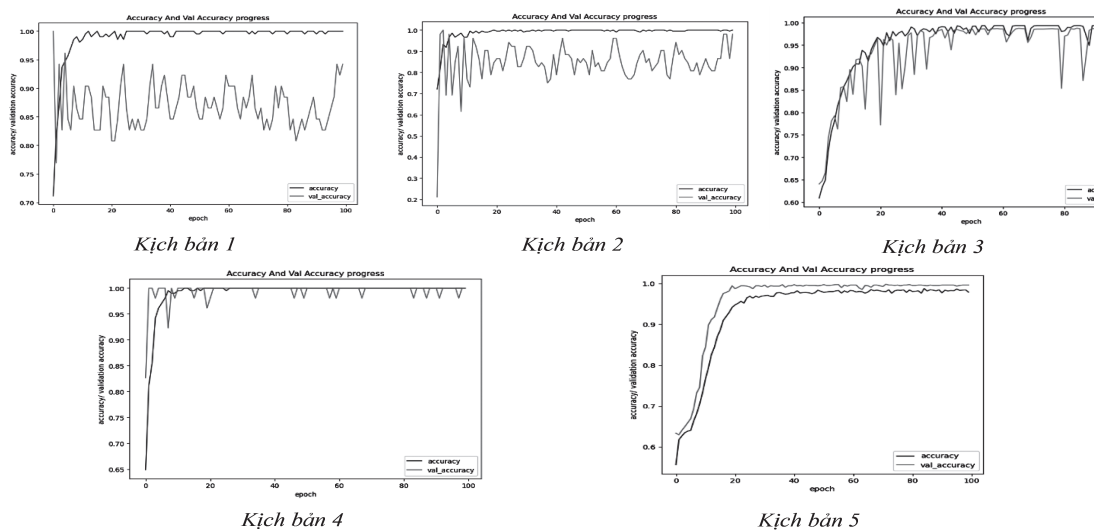


Hình 3. Độ đo Loss của các kịch bản trong giai đoạn huấn luyện

Hình 3 biểu diễn giá trị mất mát (loss) của các kịch bản trong giai đoạn huấn luyện. Giá trị val loss của các kịch bản lần lượt là kịch bản 1 là 0.8354, kịch bản 2 là 0.0836, kịch bản 3 là 0.0059, kịch bản 4 là 0.0062 và kịch bản 5 là 0.0054. Ở kịch bản 1, 2 và 3, giá trị val_loss cho kết quả cao hơn giá trị train loss và không ổn định, điều này cho thấy mô hình huấn luyện chưa tối ưu và có thể dẫn đến sai lệch trong quá trình dự đoán. Ngược lại, kịch bản 4 và 5 lại cho kết quả tối ưu hơn so với các kịch

bản trên khi giá trị val loss bằng với giá trị train loss đối với kịch bản 4 và giá trị val loss thấp hơn so với giá trị train loss đối với kịch bản 5. Tuy nhiên, giá trị val loss trùng với train loss cũng có thể là do vấn đề underfitting, trong khi đó kịch bản 5 lại có giá trị val loss thấp hơn so với giá trị train loss. Điều này cho thấy mô hình trong kịch bản 5 cho kết quả tốt hơn các mô hình trong các kịch bản còn lại.

b. Độ đo Accuracy của các kịch bản



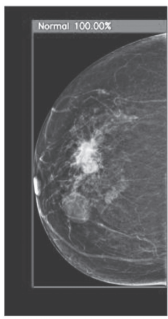
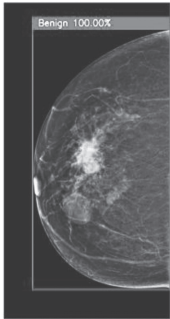
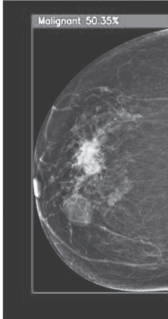
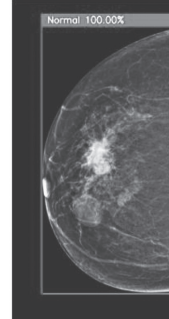
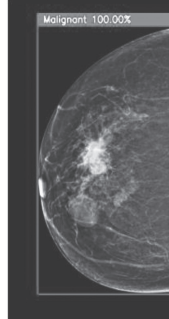
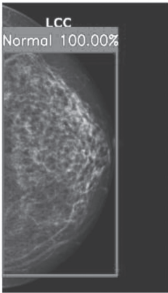
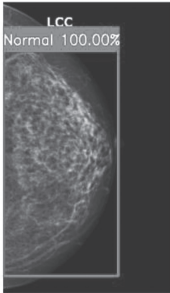
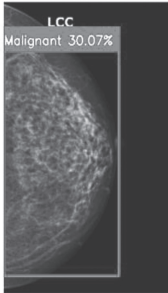
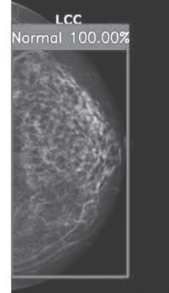
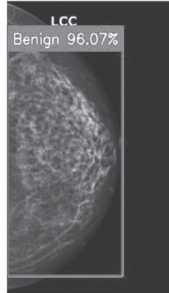
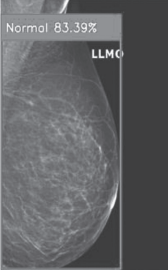
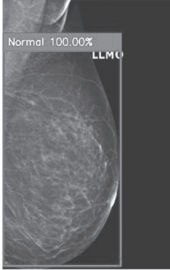
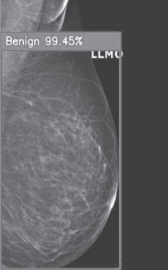
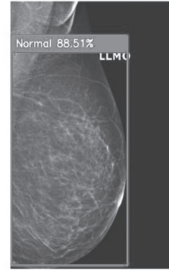
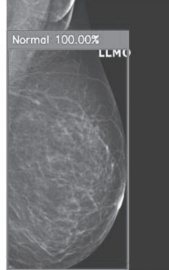
Hình 4. Độ đo Accuracy của các kịch bản trong giai đoạn huấn luyện.

Hình 4 biểu diễn độ chính xác (accuracy) của các kịch bản trong giai đoạn huấn luyện. Kịch bản 1 đạt độ chính xác 96%, kịch bản 2 có độ chính xác là 96.5%. Kịch bản 3, 4 và 5, độ chính xác vượt trội hơn hẳn so với các kịch bản còn lại với độ chính xác là 99%. Mặt khác, khi quan sát kịch bản 1, 2 và 3 ta thấy rằng, giá trị val_accuracy cho kết quả thấp hơn giá trị train_accuracy và không ổn định, điều này cho thấy mô hình huấn luyện chưa thật sự

hiệu quả và có thể dẫn đến sai lệch trong quá trình dự đoán. Ngược lại, kịch bản 4 và 5 lại cho kết quả tối ưu hơn so với các kịch bản trên khi giá trị val_accuracy bằng với giá trị train_accuracy đối với kịch bản 4 và giá trị val_accuracy cao hơn so với giá trị train_accuracy đối với kịch bản 5. Điều này cho thấy hai mô hình trong hai kịch bản 4 và 5 có khả năng dự đoán tốt hơn các mô hình trong ba kịch bản còn lại

c) Một số hình ảnh kết quả phân loại

Bảng 2. Một số kết quả trên tập dữ liệu kiểm thử

	Kịch bản 1	Kịch bản 2	Kịch bản 3	Kịch bản 4	Kịch bản 5
Malignant					
Benign					
Normal					

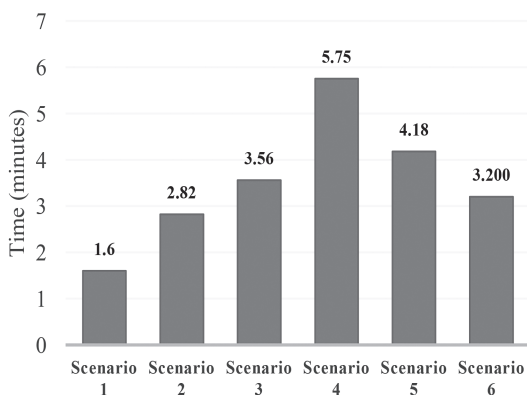
Bảng 2 trình bày một số kết quả thực nghiệm của các kịch bản. Ở trường hợp Malignant (ác tính), khối u được hiện rõ

trên ảnh nhũ; kịch bản 1 – 4 cho kết quả là Normal, kịch bản 2 cho kết quả là Benign, kịch bản 3 và 5 cho kết quả là Malignant. Ở

trường hợp Benign (lành tính), ta thấy rằng các điểm khối u được phân bố nhỏ trên khắp vùng nhũ, kết quả dự đoán ở kịch bản 1 – 2 và 4 cho kết quả dự đoán là Normal, kịch bản 3 là Malignant trong khi kịch bản 5 cho kết quả là Benign (lành tính); đúng với kết quả thực tế. Ở trường hợp Normal, quan sát bảng 2 ta thích kịch bản 1 – 2 – 4 và 5 cho kết quả dự đoán chính xác so với thực tế trong khi kịch bản 3 đưa ra giá trị dự đoán là Benign. Kết quả cho thấy, kịch bản 5 hoạt động tốt hơn so với các kịch bản 1, 2, 3 và 4.

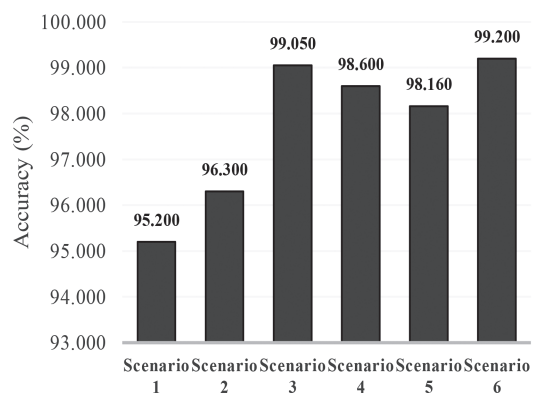
d) So sánh, đánh giá kết quả kiểm thử giữa các mô hình

Hình 5a biểu diễn thời gian dự đoán trên tập kiểm thử của các kịch bản đề xuất



a) Thời gian dự đoán trung bình

lần lượt là kịch bản 1 là 1.65 phút, kịch bản 2 là 2.82 phút, kịch bản 3 là 3.56 phút, kịch bản 4 là 5.75 phút, kịch bản 4 là 4.18 phút và kịch bản 6 là 3.2 phút. Hình 5b biểu diễn độ chính xác dự đoán trên tập kiểm thử của các kịch bản đề xuất lần lượt là kịch bản 1 là 95.2%, kịch bản 2 là 96.3%, kịch bản 3 là 99.05%, kịch bản 4 là 98,6%, kịch bản 5 là 98.16% và kịch bản 6 là 99.2%. Qua kết quả trên, có thể thấy mô hình 5 cho kết quả huấn kiểm thử nhanh hơn so với kịch bản 1 và 4 và chậm hơn so với kịch bản 2 và 3 về mặt thời gian, trái lại, độ chính xác kịch bản 5 mang lại cao hơn so với các kịch bản còn lại. Điều này cho thấy, kịch bản 5 mang lại kết quả dự đoán tốt hơn so với các kịch bản còn lại.



b) Độ chính xác trung bình

Hình 5. Thời gian dự đoán và độ chính xác của các kịch bản trên tập dữ liệu kiểm thử

3. KẾT LUẬN

Trong bài báo này, chúng tôi đề xuất phương pháp phát hiện và phân loại ung thư vú dựa trên các mạng rút trích đặc trưng như MobileNetV2, InceptionV3, NASNetLarge, DenseNet121 và Vision Transformer. Ngoài ra, chúng tôi cũng mang lại một số kết quả so sánh giữa các mô hình, điều này góp phần trong việc đánh giá và lựa chọn được phương pháp phù hợp để có thể xây dựng

hệ thống phát hiện và phân loại nhằm hỗ trợ bác sĩ có thể đưa ra chẩn đoán một cách nhanh chóng để có thể tiến hành điều trị kịp thời cho bệnh nhân. Kết quả thực nghiệm cho thấy mô hình phát hiện ung thư vú dựa trên mạng Vision Transformer đạt hiệu suất tốt hơn về mặt thời gian dự đoán với độ chính xác cao so với các mạng học sâu khác. Mặc khác, độ chính xác của mô hình đề xuất trong quá trình đào tạo lên đến 99%.

TÀI LIỆU THAM KHẢO

- [1]. Z. Jiao, X. Gao, Y. Wang, and J. Li (2016). A deep feature based framework for breast masses classification. *Journal of Neurocomputing*, vol. 197, pp. 221-231.
- [2] The American Cancer Society's publications, *Cancer Facts & Figures 2023* and *Cancer Facts & Figures 2020*; the ACS website; the International Agency for Research on Cancer website; and the National Cancer Institute's Surveillance, Epidemiology, and End Results (SEER) Program.
- [3]. C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens and Z. Wojna (2016), "Rethinking the Inception Architecture for Computer Vision," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 2818-2826, doi: 10.1109/CVPR.2016.308.
- [4]. M. Sandler, A. Howard, M. Zhu, A. Zhmoginov and L.-C. Chen (2018), "MobileNetV2: Inverted Residuals and Linear Bottlenecks," *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, 2018, pp. 4510-4520, doi: 10.1109/CVPR.2018.00474.
- [5] Zoph, Barret & Vasudevan, Vijay & Shlens, Jonathon & Le, Quoc. (2018), "Learning Transferable Architectures for Scalable Image Recognition", 8697-8710. 10.1109/CVPR.2018.00907.
- [6] Huang, Gao & Liu, Zhuang & van der Maaten, Laurens & Weinberger, Kilian. (2017), "Densely Connected Convolutional Networks," 10.1109/CVPR.2017.243.
- [7]. Simonyan, K.; Zisserman, A. (2014), "Very deep convolutional networks for large-scale image recognition," *arXiv 2014*, arXiv:1409.1556.
- [8]. Shuyue, G.; Murray, L. (2017), "Breast cancer detection using transfer learning in convolutional neural networks," In *Proceedings of the 2017 IEEE Applied Imagery Pattern Recognition Workshop (AIPR)*, Washington, DC, USA, 10–12 October 2017; pp. 1–8.
- [9] Kai Han, Yunhe Wang, Hanting Chen, Xinghao Chen, Jianyuan Guo, Zhenhua Liu, Yehui Tang, An Xiao, Chunjing Xu, Yixing Xu, Zhaohui Yang, Yiman Zhang, and Dacheng Tao Fellow (2023), "A Survey on Vision Transformer", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Jan. 2023, pp. 87-110, vol. 45
- [10] Dosovitskiy, A.; Beyer, L.; Kolesnikov, A.; Weissenborn, D.; Zhai, X.; Unterthiner, T.; Dehghani, M.; Minderer, M.; Heigold, G.; Gelly, S.; et al. An Image Is Worth 16x16 Words: Transformers for Image Recognition at Scale. *arXiv 2020*, arXiv:2010.11929.
- [11]. Suckling, J., Parker, J., Dance, D., Astley, S., Hutt, I., Boggis, C., Ricketts, I., et al. (2015). "Mammographic Image Analysis Society (MIAS)", database v1.21 [Dataset].
- [12]. D. Albashish, R. Al-Sayyed, A. Abdullah, M. H. Ryalat and N. Ahmad Almansour (2021), "Deep CNN Model based on VGG16 for Breast Cancer Classification," *2021 International Conference on Information Technology (ICIT)*, Amman, Jordan, 2021, pp. 805-810.

- [13]. Girish, Gayathri, Ponnathota Spandana, and Badrish Vasu (2023), “Breast cancer detection using deep learning”, arXiv preprint arXiv:2304.10386
- [14]. Md Ishtyaq Mahmud, Muntasir Mamun, Ahmed Abdelgawad (2023), “A Deep Analysis of Transfer Learning Based Breast Cancer Detection Using Histopathology Images” ,11 Apr 2023
- [15]. Bitu Asadi, Qurban Memon (2023), “Efficient breast cancer detection via cascade deep learning network,” International Journal of Intelligent Networks, Volume 4, 2023, Pages 46-52
- [16] Iqbal Z, Luo D, Henry P, Kazemifar S, Rozario T, Yan Y, Westover K, Lu W, Nguyen D, Long T, Wang J, Choy H, Jiang S. (2018) , “Accurate real time localization tracking in a clinical environment using Bluetooth Low Energy and deep learning”, PLoS One. 2018 Oct 11;13(10):e0205392. doi: 10.1371/journal.pone.0205392. PMID: 30307999; PMCID: PMC6181345.
- [17] Gulli, A.; Kapoor, A.; Pal, S. (2019), “Deep Learning with TensorFlow 2 and Keras: Regression, ConvNets, GANs, RNNs, NLP, and More with TensorFlow 2 and the Keras API”, Packt Publishing Ltd.: Birmingham, UK, 2019.
- [18] American Cancer Society. Breast Cancer Facts & Figures 2019-2020 (2019), “Atlanta: American Cancer Society,” Inc. 2019.