

# PHÁT HIỆN VÀ PHÂN LOẠI MỘT SỐ BỆNH TIM SỬ DỤNG KỸ THUẬT HỌC SÂU TRONG MÔI TRƯỜNG DỮ LIỆU LỚN

## DETECTION AND CLASSIFICATION OF SOME HEART DISEASES USING DEEP LEARNING TECHNIQUES IN BIG DATA ENVIRONMENT

HÀ HOÀI NAM<sup>1a</sup>, PHAN THƯỢNG CANG<sup>2</sup>, PHAN ANH CANG<sup>3</sup>

<sup>1</sup>Học viên cao học, Trường Đại học Sư phạm Kỹ thuật Vĩnh Long,

<sup>2</sup>Trường Công nghệ Thông tin và Truyền thông - Đại học Cần Thơ

<sup>3</sup>Trường Đại học Sư phạm Kỹ thuật Vĩnh Long

<sup>a</sup>Tác giả liên hệ: [hoainam.axn@gmail.com](mailto:hoainam.axn@gmail.com)

*Nhận bài (Received): 29/3/2024; Phản biện (Reviewed): 09/4/2024; Chấp nhận (Accepted): 19/4/2024*

### TÓM TẮT

Bệnh tim hay bệnh tim mạch là nhóm bệnh lý gây tử vong hàng đầu hiện nay. Việc phát hiện và phân loại sớm các bệnh lý về tim mạch để đưa ra phương hướng điều trị là vô cùng cần thiết. Chụp MRI tim có thể xác định được cấu trúc, kích thước các buồng tim, van tim và các mạch máu lớn. Trong bài báo này, chúng tôi đề xuất các kỹ thuật học sâu để phát hiện và phân loại bệnh tim dựa trên kiến trúc mạng InceptionV3, DenseNet121, ResNet-152, Vision Transformer và kết hợp công nghệ xử lý dữ liệu lớn để phân loại ảnh chụp MRI tim bình thường và ảnh MRI tim mắc bệnh. Qua kết quả thực nghiệm cho thấy độ chính xác của mô hình đề xuất lên đến 98.7%.

**Từ khóa:** Vision Transformer, Deep learning, Heart Disease, Cardiac MRI, Mapreduce

### ABSTRACT

*Heart disease or cardiovascular disease is currently a leading cause of death. Early detection and classification of cardiovascular diseases for treatment direction are extremely necessary. Cardiac MRI can determine the structure, size of the heart chambers, heart valves, and major blood vessels. In this paper, we propose deep learning techniques for detecting and classifying heart diseases based on InceptionV3, DenseNet121, ResNet-152, Vision Transformer architectures, and integrate big data processing technology to classify normal heart MRI images and MRI images with heart diseases. Experimental results demonstrate that the proposed model achieves an accuracy of up to 98.7%.*

**Keywords:** Vision Transformer, Deep learning, Heart Disease, Cardiac MRI, Mapreduce

## 1. MỞ ĐẦU

### 1.1. Giới thiệu bài toán

Ở Việt Nam, theo thống kê của Bộ Y tế mỗi năm có khoảng 200.000 người tử vong về bệnh lý tim mạch, chiếm 33% ca tử vong. Theo thống kê của Viện Tim

Mạch, tỷ lệ tăng huyết áp ở người trưởng thành trong độ tuổi từ 18 – 65 chiếm 25%, như vậy cứ 4 người trưởng thành thì có một người tăng huyết áp. Tăng huyết áp làm tăng nguy cơ tử vong do đột quỵ lên gấp 4 lần và tăng nguy cơ tử vong do bệnh lý tim

mạch lên gấp 3 lần so với người không mắc bệnh. Với sự tiến bộ và độ hoàn thiện của các máy chụp MRI cho ra hình ảnh chi tiết, sắc nét hơn, góp phần quan trọng trong hỗ trợ bác sĩ chẩn đoán hình ảnh phát hiện các tổn thương hoặc các bất thường của tim. Tuy vậy, việc phát hiện những bất thường này chủ yếu dựa vào trình độ chuyên môn và kinh nghiệm của Bác sĩ. Với những tổn thương đặc biệt và những bất thường khó nhận thấy đòi hỏi sự tập trung cao độ và thời gian xem xét các dữ liệu ảnh, ngoài ra còn phụ thuộc các yếu tố chủ quan về tâm sinh lý ở thời điểm chẩn đoán bệnh của người bác sĩ. Do đó, việc xây dựng một mô hình ứng dụng, hỗ trợ các Bác sĩ trong chẩn đoán nhanh và chính xác các bệnh lý về tim mạch và đưa ra hướng điều trị kịp thời cho bệnh nhân là vô cùng cần thiết.


### 1.2. Các nghiên cứu liên quan

Lubna Riyaz và các cộng sự [1] đã sử dụng một số kỹ thuật máy học trong dự đoán nguy cơ bệnh tim như: Máy vector hỗ trợ (SVM), cây quyết định (DT), K-láng giềng gần nhất (KNN), mạng thần kinh nhân tạo (ANN) ,... Theo kết quả, ANN đạt được độ chính xác dự đoán trung bình cao nhất với 86,91%. Aniruddha Dutta cùng các tác giả khác [2] đã đề xuất một mạng thần kinh với các lớp tích chập để phân loại dữ liệu bệnh tim. Dữ liệu được tuyển chọn từ Khảo sát Kiểm tra Dinh dưỡng và Sức khỏe Quốc gia (NHANES) với mục tiêu dự đoán sự xuất hiện của Bệnh tim mạch vành với độ chính xác của mô hình đạt 79,5%. Nhóm nghiên cứu của Safial Islam Ayon [3] đã sử dụng các kỹ thuật máy học khác nhau như: Hồi quy logistic (LR), Máy vectơ hỗ trợ (SVM), Mạng thần kinh sâu (DNN), Cây quyết định (DT) trong dự đoán bệnh tim. Nghiên cứu có độ chính xác cao nhất là 98,15% với độ nhạy và độ chính xác lần lượt là 98,67% và 98,01%. Zahra Hoodbhoy cùng các cộng sự [4] đã thực hiện trên 16 nghiên cứu (1217

người tham gia) sử dụng thuật toán máy học để chẩn đoán bệnh tim bẩm sinh. Mạng thần kinh được sử dụng trong bảy nghiên cứu cho độ nhạy tổng thể là 90,9%. Qua tham khảo có thể thấy rằng, đa số các công trình nghiên cứu kể trên chỉ thực hiện các dự đoán về các nguy cơ bệnh tim và thực hiện huấn luyện trên các máy đơn, việc đưa ra một số các kết quả kiểm thử và sử dụng các mô hình xử lý song song trong môi trường dữ liệu lớn sẽ giúp rút ngắn được thời gian huấn luyện và phân loại bệnh tim chưa thấy được sử dụng.

### 1.3. Đặc điểm của bệnh tim

Bệnh tim mạch là các tình trạng liên quan đến sức khỏe của trái tim, sự hoạt động của các mạch máu gây suy yếu khả năng làm việc của tim. Các bệnh tim mạch bao gồm: các bệnh mạch máu như bệnh động mạch vành, bệnh cơ tim, loạn nhịp tim và suy tim. Bệnh tim mạch gây hẹp, xơ cứng và tắc nghẽn mạch máu, làm gián đoạn hoặc không cung cấp đủ oxy đến não và các bộ phận khác trong cơ thể. Từ đó khiến các cơ quan bị ngừng trệ hoạt động, phá hủy từng bộ phận dẫn đến tử vong. Bệnh tim mạch có thể xảy ra ở mọi độ tuổi, giới tính, nghề nghiệp. Bệnh không thể chữa khỏi hoàn toàn, đòi hỏi sự điều trị và theo dõi cẩn thận (thậm chí là suốt đời), tốn kém nhiều chi phí. Có rất nhiều bệnh lý về tim mạch, tuy nhiên đề tài chỉ tập trung nghiên cứu một số bệnh điển hình như sau: Giãn cơ tim (DCM), phì đại cơ tim (HCM), suy tim do nhồi máu (HFI), tâm thất phải bất thường (RV) [5].



Hình 1. Tim bình thường và suy tim

#### 1.4. Các mạng nơ-ron dùng trong trích xuất đặc trưng

a) *Mạng InceptionV3*: InceptionV3 [6] 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 có thể được sử dụng lại cho các tác vụ liên quan đến phân loại hình ảnh khác nhau.

b) *Mạng ResNet-152*: Mô hình ResNet-152 [7] được phát triển bởi Kaiming He, Xiangyu Zhang, Shaoqing Ren và Jian Sun. ResNet (viết tắt của "Residual Network") đã đạt được nhiều thành tựu trong các cuộc thi và ứng dụng trong nhận dạng hình ảnh, phân loại hình ảnh và nhiều tác vụ khác liên quan đến xử lý hình ảnh. Mô hình ResNet-152 là một phiên bản cực kỳ sâu của ResNet, với 152 layers chứa các phần tử mạng nơ-ron.

c) *Mạng DenseNet121*: DenseNet121 [8] là một khung học sâu khác với các khung khác như CNN và RNN. Không giống như các khung này, DenseNet121 sử dụng các phép chập 1x1 cũng như các phép chập 3x3. Điều này cho phép trích xuất nhiều thông tin hơn từ dữ liệu đồng thời giảm số lượng tham số cần được tối ưu hóa.

d) *Mạng Vision Transformer*: Vision Transformer (ViT) [9] là một mô hình học sâu được dùng trong các tác vụ xử lý ảnh. Được giới thiệu lần đầu tiên vào năm 2021 trong bài báo "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale". Mô hình không sử dụng mạng tích chập mà sử dụng kiến trúc Transformer và cơ chế Attention, đây là cơ chế có trong hầu hết các mô hình Transformer cho các tác vụ xử lý ngôn ngữ tự nhiên.

#### 1.5. Công nghệ xử lý dữ liệu lớn

a) *Apache Spark*: Apache Spark [10] là hệ thống xử lý dữ liệu mã nguồn mở được thiết kế để xử lý và phân tích dữ liệu trên quy mô lớn và tính toán song song. Được phát triển sơ khởi vào năm 2009 bởi AMPLab. Sau này, Spark đã được trao lại cho Apache Software Foundation vào năm 2013 và được phát triển cho đến nay. Spark cung cấp một cách tiếp cận hiệu quả hơn cho việc xử lý dữ liệu lớn. Spark cho phép xử lý dữ liệu phân tán trên một cụm máy tính với tính toán song song, đảm bảo rằng các tác vụ xử lý được chia nhỏ và được thực hiện đồng thời trên nhiều máy tính.

b) *BigDL*: BigDL [11] là thư viện DeepLearning phân tán dành cho Apache Spark giúp người dùng có thể viết các ứng dụng máy học dưới dạng chương trình Spark tiêu chuẩn, được phát triển bởi Intel và tổ chức Apache Software Foundation. Thư viện này được xây dựng trên nền tảng Apache Spark, cho phép thực hiện các tác vụ học sâu trên các cụm tính toán phân tán.

c) *Mô hình MapReduce*: Mapreduce [12] là một mô hình lập trình và một cách triển khai các thuật toán xử lý dữ liệu trên môi trường xử lý phân tán, song song, đồng thời phân tán các thuật toán trên cùng một máy tính. Mặc dù Mapreduce ban đầu là một công nghệ độc quyền của Google nhưng trong thời gian gần đây, Mapreduce đang dần trở thành một trong những thuật ngữ tổng quát hoá. Mapreduce sẽ bao gồm hai thủ tục (giai đoạn) chính là Map và Reduce.

#### 1.6. Các độ đo đánh giá mô hình

Accuracy: thường được sử dụng để đánh giá hiệu suất của mô hình trong các bài toán phân loại. Accuracy là tỷ lệ phần trăm giữa số lần dự đoán đúng và tổng số lần dự đoán.

$$Accuracy = \frac{TP + TN}{total\ sample}$$

Precision: đo lường khả năng của mô hình dự đoán chính xác các trường hợp dương tính. Precision tính tỷ lệ phần trăm của số lần dự đoán dương tính đúng so với tổng số lần dự đoán mà mô hình xác định là dương tính.

$$\begin{aligned} \text{Precision} &= \frac{TP}{\text{total predicted positive}} \\ &= \frac{TP}{TP + FP} \end{aligned}$$


## 2. KẾT QUẢ NGHIÊN CỨU

### 2.1. Phương pháp đề xuất

#### 2.1.1. Mô hình đề xuất

Mô hình đề xuất cho việc phát hiện và phân loại bệnh tim gồm 2 giai đoạn huấn luyện và kiểm thử được thể hiện ở Hình 1.

Ở giai đoạn huấn luyện, chúng tôi sử dụng 4 mạng rút trích đặc trưng là: InceptionV3, ResNet152, Densenet121 và Vision Transformer để xây dựng các kịch bản. Tập dữ liệu huấn luyện được thực hiện các bước tiền xử lý, chuẩn hóa kích thước cho phù hợp với từng mô hình với thư viện Keras. Sau đó, từ máy Master sẽ khởi động chương trình điều khiển (Driver program) tạo ra Sparkcontext để phân chia các công việc cần thực hiện, cụ thể là công việc rút trích đặc trưng và huấn luyện đến các máy Worker. Từ tập dữ liệu đầu vào được chia thành các tập nhỏ và các tập nhỏ đó được phân phối vào các máy Worker cho phép Spark cluster có thể xử lý dữ liệu song song và cải thiện hiệu suất. Sau khi hoàn thành công việc các kết quả sẽ được tổng hợp về Driver manager ở máy Master và cho ra kết quả cuối cùng.



Hình 2. Mô hình đề xuất phát hiện và phân loại bệnh tim

#### 2.1.2. Mô hình huấn luyện


Trong giai đoạn huấn luyện, tập dữ liệu được phân chia ngẫu nhiên cho các worker với  $W_1, \dots, W_n$  là các trọng số mạng được liên kết với từng worker 1, ..., worker n.  $W$

là trung bình trọng số (Global Parameter Vector  $W$ ) được thu thập bởi các worker tại máy chủ tham số. Sau khi việc tính trung bình các trọng số được thực hiện các worker 1, ..., worker n sẽ được phân bổ  $W_1, \dots, W_n$



tương ứng với phần cục bộ mạng. Mỗi worker sẽ thực thi huấn luyện cùng lúc song

song nhau. Việc cập nhật trọng số làm giảm thời gian huấn luyện cho mô hình.



Hình 3. Mô hình huấn luyện trong môi trường xử lý song song và phân tán

### 2.1.3. Kiểm thử

Từ model kết quả sau quá trình huấn luyện, chúng tôi sẽ tiến hành bước kiểm thử trên tập dữ liệu Test đã được chuẩn bị sẵn. Ở giai đoạn này cũng tiến hành các tiền xử lý dữ liệu như ở giai đoạn huấn luyện và đưa qua mô hình đã huấn luyện trước đó để phân loại cho ra kết quả một số bệnh tim như: DCM (Dilated Cardiomyopathy), HCM (Hypertrophic Cardiomyopathy),

HFI (Heart Failure with Infarction), RV (Abnormal Right Ventricle), NOR (Normal). Từ quá trình kiểm thử này chúng tôi đánh giá chọn ra mô hình hiệu quả tối ưu nhất cho bước xây dựng mô hình tiếp theo.

## 2.2. Kết quả thực nghiệm

### 2.2.1. Các kịch bản áp dụng

Trong nghiên cứu này, chúng tôi thực hiện 8 kịch bản với các tham số tương ứng như trong Bảng 1:

| Scenarios | Feature Extraction | Environment | Learning rate | Epochs | Batch size | Image size |
|-----------|--------------------|-------------|---------------|--------|------------|------------|
| 1         | InceptionV3        | Local       | 1e-3          | 300    | 128        | 224 x 224  |
| 2         |                    | Cluster     |               |        |            |            |
| 3         | ResNet152          | Local       | 1e-3          | 300    | 128        | 224 x 224  |
| 4         |                    | Cluster     |               |        |            |            |
| 5         | DenseNet121        | Local       | 1e-3          | 300    | 128        | 224 x 224  |
| 6         |                    | Cluster     |               |        |            |            |
| 7         | Vision Transformer | Local       | 1e-3          | 300    | 128        | 224 x 224  |
| 8         |                    | Cluster     |               |        |            |            |

Bảng 1: Bảng tham số huấn luyện theo từng kịch bản

Các mạng rút trích đặt trưng được sử dụng như: InceptionV3, ResNet152, DenseNet121 và Vision Transformer sẽ được cài đặt huấn luyện trên 2 môi trường local và cluster. Ở môi trường local được

cấu hình với một máy, ở cluster được cấu hình với số máy là bốn máy. Bộ tham số dùng cho huấn luyện trên 8 kịch bản với learning rate là 0.001, epochs là 300, batch size là 128 và image size là 224 x 224.

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

a) *Môi trường cài đặt*: Trong nghiên cứu, chúng tôi sẽ thực hiện cài đặt và huấn luyện trên hai môi trường huấn luyện: local và cluster. Ở mỗi máy sẽ có cấu hình RAM 8GB, CPU 4 nhân, hệ điều hành Ubuntu 20.04 LTS, cùng với các thư viện, và môi trường hỗ trợ: Java JDK 8, Python 3.7, Tensorflow 2.11, Apache Spark 2.4.2.

b) *Tập dữ liệu thực nghiệm*: ACDC (ACDC: Automated Cardiac Diagnosis Challenge) [15] là bộ dữ liệu được tạo ra từ các cuộc kiểm tra lâm sàng thực tế thu được tại Bệnh viện Đại học Dijon (Pháp). Bộ dữ liệu được chia thành 5 nhóm nhỏ được phân bổ đều (4 bệnh lý cộng với 1 nhóm đối tượng khỏe mạnh). Tập dữ liệu đào tạo gồm 100 bệnh nhân và tập dữ liệu thử nghiệm có 50 bệnh nhân cùng với các tài liệu tham khảo thủ công tương ứng dựa trên phân tích của một chuyên gia lâm sàng. Tập dữ liệu gốc với định dạng tập tin .nii (Neuroimaging Informatics Technology


Initiative) là một chuẩn định dạng được sử dụng để lưu trữ dữ liệu hình ảnh y tế, với kích thước tập dữ liệu là 2.28GB. Để sử dụng cho việc huấn luyện và kiểm thử, tập dữ liệu đã được chúng tôi chuyển đổi về dạng ảnh số PNG, tăng cường bằng các kỹ thuật lật, xoay ảnh, xử lý loại bỏ các ảnh lỗi, ảnh có kích thước và độ sáng tối bất thường, sau đó được phân bổ vào các thư mục tương ứng với các nhóm bệnh.

*Dữ liệu đào tạo*: Bộ dữ liệu đào tạo gồm 1674 ảnh, trong đó có 340 ảnh bệnh Giãn cơ tim (DCM), 322 ảnh bệnh Phi đại cơ tim (HCM), 311 ảnh bệnh Suy tim do nhồi máu (HFI), 431 ảnh Bất thường tâm thất phải (RV), 270 ảnh tim bình thường (NOR).

*Dữ liệu kiểm thử*: Bộ dữ liệu dùng cho kiểm thử có 300 ảnh, 60 ảnh bệnh Giãn cơ tim, 60 ảnh bệnh Phi đại cơ tim, 60 ảnh bệnh Suy tim do nhồi máu, 60 ảnh Bất thường tâm thất phải và 60 ảnh tim bình thường.

### 2.2.3. Các kết quả thực nghiệm thu được

#### a) Độ chính xác – Accuracy:




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

Trong hình 4 biểu diễn độ chính xác (Accuracy) của các kịch bản huấn luyện trong cả hai môi trường local và cluster. Trong đó kịch bản 1 đạt độ chính xác 88.15%, kịch bản 2 đạt 89.03%, kịch bản 5 đạt 91.66% và kịch bản 6 là 91.22%. Các kịch bản đạt độ chính xác cao nhất là 3, 4 và 7, 8 với độ chính xác lần lượt là 98.64%, 98.46% và 99.10%, 98.72%. Ở kịch bản 1 tới 6 có val\_accuracy thấp hơn nhiều so với

train\_accuracy và không ổn định, điều này cho thấy mô hình huấn luyện chưa thật sự hiệu quả có thể dẫn đến sai lệch trong quá trình dự đoán. Ngược lại ở các kịch bản 7, 8 có val\_accuracy ổn định và gần bằng train\_accuracy do đó mô hình ở kịch bản 7 và 8 có khả năng dự đoán chính xác hơn các kịch bản còn lại.

#### b) Độ mất mát – Loss:













Hình 5. Độ đo Loss của các kịch bản trong giai đoạn huấn luyện

Hình 5 biểu diễn giá trị mất mát (Loss) của các kịch bản được huấn luyện trong hai môi trường local và cluster cho các giá trị lần lượt là kịch bản 1: 0.8690; kịch bản 2: 0.7902; kịch bản 3: 0.0298; kịch bản 4: 0.0431; kịch bản 5: 0.6858; kịch bản 6: 0.6207; kịch bản 7 là 0.0340 và kịch bản 8 là: 0.0611.

#### c) Một số hình ảnh kết quả phân loại:

Trong phần kiểm thử, chúng tôi chia làm hai kịch bản để so sánh hiệu suất giữa mô hình được huấn luyện trong môi trường cục bộ và phân tán, Local– Kiểm

thử mô hình huấn luyện trên môi trường cục bộ, Cluster – Kiểm thử mô hình huấn luyện trên môi trường phân tán. Bảng 2 trình bày các kết quả dự đoán của mô hình được huấn luyện trên hai môi trường, ở Local có giá trị dự đoán chính xác cao hơn Cluster một vài trường hợp và ở một số trường hợp khác Cluster lại cho giá trị cao hơn Local, tuy nhiên cả hai đều cho kết quả chính xác khá cao. Kết quả cho thấy khi được huấn luyện trên môi trường phân tán thì hiệu suất của mô hình vẫn cho kết quả cao và suy giảm rất nhỏ và không đáng kể.


|         | DCM                                                                               | HCM                                                                               | HFI                                                                               | RV                                                                                 | NOR                                                                                 |
|---------|-----------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
| Local   | Predicted class: DCM 100.00%                                                      | Predicted class: HCM 98.00%                                                       | Predicted class: HFI 88.20%                                                       | Predicted class: RV 100.00%                                                        | Predicted class: NOR 95.60%                                                         |
|         |  |  |  |  |  |
| Cluster | Predicted class: DCM 96.45%                                                       | Predicted class: HCM 100.00%                                                      | Predicted class: HFI 86.35%                                                       | Predicted class: RV 97.45%                                                         | Predicted class: NOR 100.00%                                                        |
|         |  |  |  |  |  |

*Bảng 2: Một số kết quả trên tập kiểm thử khi huấn luyện ở 2 môi trường*


Trong Bảng 2 đưa ra các dự đoán về tim mắc các bệnh như: DCM (Dilated Cardiomyopathy: Giãn cơ tim), HCM (Hypertrophic Cardiomyopathy: Phì đại cơ tim), HFI (Heart Failure with Infarction: Suy tim do nhồi máu), RV (Abnormal Right Ventricle: Bất thường tâm thất phải), NOR (Normal: Tim bình thường) với tỉ lệ % dự đoán chính xác trên mỗi ảnh thử nghiệm. Ở kịch bản tim mắc DCM cho thấy thành cơ tim mở rộng, làm tim yếu đi và giảm khả năng bơm máu, ở kịch bản bệnh nhân mắc HCM cho thấy một phần cơ tim phát triển quá mức, làm giảm không gian thành tim và giảm khả năng lưu thông máu, ở kịch bản

bệnh nhân mắc HFI một phần tim bị tổn thương không còn hoạt động bình thường và làm giảm khả năng bơm máu, trong kịch bản bệnh nhân mắc RV tâm thất phải không hoạt động bình thường do dị tật hoặc các nguyên nhân khác nhau cũng làm giảm chức năng của tim, ở kịch bản NOR cho thấy tim bình thường và không ghi nhận các tổn thương bất thường. Ở các kịch bản giữa hai môi trường đều cho kết quả dự đoán cao đến khá cao, việc huấn luyện trên môi trường dữ liệu lớn vẫn đảm bảo được độ chính xác và rút ngắn được thời gian xử lý.


*d) So sánh đánh giá kết quả kiểm thử:*



*a. Độ chính xác trung bình*



*b. Thời gian kiểm thử trung bình*



*c. Thời gian huấn luyện*

**Hình 6. Độ chính xác trung bình, thời gian kiểm thử trung bình và thời gian huấn luyện của các kịch bản**



Trong hình 6.a biểu diễn độ chính xác trung bình của các kịch bản đề xuất lần lượt là kịch bản 1: 88.15%; kịch bản 2: 89.03%; kịch bản 3: 98.64%; kịch bản 4: 98.46%; kịch bản 5: 91.66%; kịch bản 6: 91.22%; kịch bản 7: 99.10%; kịch bản 8: 98.72%. Hình 6.b biểu diễn thời gian kiểm thử trung bình trên tập dữ liệu kiểm thử tính bằng phút với thời gian lần lượt cho các kịch bản từ 1 đến 8 là 1.58 phút; 1.61 phút; 7.14 phút; 7.34 phút; 3.15 phút; 3.22 phút; 3.20 phút; 3.31 phút. Hình 6.c biểu diễn thời gian huấn luyện của bốn mô hình mạng học sâu trên hai môi trường cục bộ và phân tán, với số thời gian tính bằng phút của các kịch bản lần lượt là kịch bản 1: 675 phút; kịch bản 2: 409 phút; kịch bản 3: 1942 phút; kịch bản 4: 993 phút; kịch bản 5: 760 phút; kịch bản 6: 400 phút; kịch bản 7: 667 phút và kịch bản 8: 402 phút. Qua kết quả được biểu diễn trên các biểu đồ ta thấy, kịch bản 7 và 8 có độ chính xác cao nhất, kịch bản 1, 2 có độ chính xác thấp nhất. Thời gian huấn luyện trên kịch bản 3 là lớn nhất và trên kịch bản 6 thời gian huấn luyện là nhỏ nhất. Điều này cho thấy mô hình ở kịch bản 7, 8 là tối ưu về độ chính xác, có khả năng dự đoán tốt hơn các kịch bản còn lại, thời gian của các kịch bản huấn luyện ở môi

trường phân tán sẽ rút ngắn gần phân nửa so với các kịch bản huấn luyện trên môi trường cục bộ.

### 3. KẾT LUẬN

Trong bài báo này, chúng tôi đề xuất phương pháp phát hiện và phân loại một số bệnh tim phổ biến dựa trên các mạng học sâu để rút trích đặc trưng như: InceptionV3, ResNet-152, DenseNet121 và Vision Transformer kết hợp với công nghệ xử lý dữ liệu lớn, đưa quá trình huấn luyện lên môi trường phân tán và xử lý song song nhằm rút ngắn thời gian huấn luyện và tối ưu hóa bài toán. Bên cạnh đó, chúng tôi còn thực hiện các so sánh giữa các mô hình và môi trường huấn luyện, để góp phần đánh giá và lựa chọn phương pháp phù hợp để xây dựng hệ thống phát hiện và phân loại có thể hỗ trợ các bác sĩ đưa ra các chẩn đoán nhanh chóng, góp phần vào việc điều trị kịp thời cho bệnh nhân. Kết quả thực nghiệm cho thấy mô hình phát hiện và phân loại bệnh tim sử dụng mạng học sâu Vision Transformer đạt hiệu suất tốt hơn các mạng khác và tối ưu về mặt thời gian học khi kết hợp với kỹ thuật xử lý dữ liệu lớn. Độ chính xác của mô hình đề xuất đạt độ chính xác lên đến 98,7% trong quá trình đào tạo.

### TÀI LIỆU THAM KHẢO

- [1] Lubna Riyaz, Muheet Ahmed Butt, Majid Zaman & Omeera Ayob (2021). *Heart disease prediction using machine learning techniques: a quantitative review*. International Conference on Innovative Computing and Communications.
- [2] Aniruddha Dutta, Tamal Batabyal, Meheli Basu, Scott T. Acton (2022). *An efficient convolutional neural network for coronary heart disease prediction*. Artificial Intelligence in Medicine, Volume 128, June 2022, 102289
- [3] S.I. Ayon, M.M. Islam, M.R. Hossain (2020). *Coronary artery heart disease prediction: a comparative study of computational intelligence techniques*. IETE Journal of Research, Pages 2488-2507, Published online: 21 Jan 2020

- [4] Zahra Hoodbhoy, Uswa Jiwani, Saima Sattar, Rehana Salam, Babar Hasan, Jai K. Das (2021). *Diagnostic accuracy of machine learning models to identify congenital heart disease: a meta-analysis*. Frontiers in artificial intelligence, volume 4 – 2021
- [5] O. Bernard, A. Lalande, C. Zotti, F. Cervenansky (2018). *Deep Learning Techniques for Automatic MRI Cardiac Multi-structures Segmentation and Diagnosis: Is the Problem Solved*. IEEE Transactions on Medical Imaging, vol. 37, no. 11, pp. 2514-2525.
- [6] 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), pp. 2818-2826.
- [7] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun (2015). *Deep Residual Learning for Image Recognition*. arXiv:1512.03385 (cs.CV).
- [8] G. Huang, Z. Liu, van, và Weinberger, Kilian Q (2016). *Densely Connected Convolutional Networks*. arXiv.org, arXiv.org/abs/1608.06993.
- [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] Eman Shaikh, Iman Ahmed Mohiuddin, Yasmeen Alufaisan, Irum Nahvi (2019). *Apache Spark: A Big Data Processing Engine*. 2019 2nd IEEE Middle East and North Africa COMMUNICATIONS Conference.
- [11] Jason Dai, Yiheng Wang, Xin Qiu, Ding Ding, Yao Zhang, Yanzhang Wang, Xianyan Jia, Cherry Zhang, Yan Wan, Zhichao Li, Jiao Wang, Shengsheng Huang, Zhongyuan Wu, Yang Wang, Yuhao Yang, Bowen She, Dongjie Shi, Qi Lu, Kai Huang, Guoqiong Song (2018). *BigDL: A Distributed Deep Learning Framework for Big Data*. arXiv:1804.05839 [cs.DC].
- [12] Jeffrey Dean, Sanjay Ghemawat (2008). *MapReduce: simplified data processing on large clusters*. Communications of the ACM, Volume 51, Issue 1, pp 107–113.
- [13] Jelmer M. Wolterink, Tim Leiner, Max A. Viergever, Ivana Isgum (2017). *Automatic Segmentation and Disease Classification Using Cardiac Cine MR Images*. arXiv:1708.01141 [cs.CV]