

EXTRACT FEATURES AND CLASSIFICATION OF CHEST X-RAY IMAGES

Vo Thi Mot*, Vo Duy Nguyen, Nguyen Tan Tran Minh Khang

Vietnam National University HCMC - University of Information Technology

ARTICLE INFO	ABSTRACT
Received: 30/01/2021	COVID-19 causes an epidemic of acute respiratory infections, with more than 90 million infections and more than 2 million deaths worldwide. The disease is transmitted through the respiratory tract, each day there are more than 300,000 new infections. In this study, we examine deep learning features on chest X-ray images and use traditional machine learning methods including k-Nearest-Neighbors (k-NN), Support Vector Machines (SVM), Logistic Regression for the problem of classifying X-ray images into three classes: COVID-19, PNEUMONIA, NORMAL. Evaluation results on a data set of 3423 chest X-ray images compiled from four datasets COVID-19 Radiography Database, Covid-19 Image Dataset, COVID-19 PatientsLungs X-Ray Images 10000, COVID19 High-quality images published in 2020, the detailed experimental results, analysis, and assessment will be the basis for the next researches.
Revised: 27/5/2021	
Published: 27/5/2021	
KEYWORDS	
COVID-19	
k-Nearest-Neighbours (k-NN)	
Logistic Regression	
Neural network	
SVM	

TRÍCH CHỌN ĐẶC TRƯNG VÀ PHÂN LOẠI ẢNH X-QUANG PHỔI

Võ Thị Một*, Võ Duy Nguyên, Nguyễn Tấn Trần Minh Khang

Trường Đại học Công nghệ Thông tin – ĐH Quốc gia Thành phố Hồ Chí Minh

THÔNG TIN BÀI BÁO	TÓM TẮT
Ngày nhận bài: 30/01/2021	COVID-19 gây ra dịch viêm đường hô hấp cấp, có hơn 90 triệu ca lây nhiễm và hơn 2 triệu người chết trên toàn thế giới. Bệnh lây qua đường hô hấp, mỗi ngày có hơn 300 ngàn ca nhiễm mới. Trong nghiên cứu này, chúng tôi khảo sát các đặc trưng học sâu trên ảnh X-Quang phổi và sử dụng các phương pháp máy học truyền thống bao gồm k-Nearest-Neighbours (k-NN), Support Vector Machines (SVM), Logistic Regression cho bài toán phân loại ảnh X-Quang vào 3 lớp covid-19, pneumonia, normal. Kết quả đánh giá trên bộ dữ liệu gồm 3423 ảnh X-quang phổi được tổng hợp từ 4 bộ dữ liệu COVID-19 Radiography Database, Covid-19 Image Dataset, COVID-19 PatientsLungs X Ray Images 10000, COVID19 High quality images công bố năm 2020, các kết quả thực nghiệm, phân tích đánh giá được chỉ ra chi tiết là cơ sở cho các nghiên cứu tiếp theo.
Ngày hoàn thiện: 27/5/2021	
Ngày đăng: 27/5/2021	
TỪ KHÓA	
COVID-19	
k-Nearest-Neighbours (k-NN)	
Logistic Regression	
Neural network	
SVM	


DOI: <https://doi.org/10.34238/tnu-jst.3974>

* Corresponding author. Email: 16520756@gm.uit.edu.vn

1. Giới thiệu

COVID-19 [1] là một bệnh đường hô hấp cấp tính ở người được phát hiện vào năm 2019, gây ra bởi vi-rút SARS-CoV-2 chưa từng được xác định trước đây. Coronavirus là một họ virus lớn gây bệnh ở bệnh nhân từ cảm lạnh thông thường đến các hội chứng hô hấp tiến triển như Middle East Respiratory Syndrome (MERS-COV) và Severe Acute Respiratory Syndrome (SARS-COV).

Người nhiễm sẽ xuất hiện nhiều tổn thương ở phổi, số lượng ca nhiễm mới ngày càng nhiều. Một giải pháp hữu hiệu được đề xuất giúp các bác sĩ có thể sàng lọc lâm sàng các trường hợp nhiễm bệnh là chẩn đoán bệnh thông qua sàng lọc ảnh chụp X-quang phổi. Có nhiều nghiên cứu phát hiện COVID-19 trên ảnh X-quang với kết quả cao. Tuy nhiên hầu hết được thực nghiệm trên bộ dữ liệu khá nhỏ. Điều này đã thúc đẩy chúng tôi thu thập các bộ dữ liệu chụp X-quang ngực (Hình 1) với mong muốn tăng tính đa dạng dữ liệu và độ chính xác cho quá trình dự đoán kết quả phân loại hình ảnh.



Hình 1. Dữ liệu ảnh X-quang được gán nhãn với kết quả chẩn đoán bệnh

Trong nghiên cứu này, chúng tôi khảo sát các phương pháp máy học truyền thống k-NN [2], SVM [3], Logistic Regression [4] cho bài toán phân loại ảnh X-quang ngực để phân loại ba lớp đối tượng: COVID19, viêm phổi thông thường và người thường (không nhiễm bệnh về phổi). Để cung cấp nhiều thông tin về mặt thị giác, nhiều đặc trưng học sâu được sử dụng cho quá trình huấn luyện và kiểm tra: VGG19 [5], Densenet121 [6], EfficientB1 [7]. Các thực nghiệm được tiến hành trên bộ dữ liệu gồm 3423 ảnh X-quang ngực, được chúng tôi tổng hợp từ các công bố khoa học trên thế giới.


2. Phương pháp nghiên cứu

2.1. Bài toán phân lớp

Bài toán phân lớp thuộc loại học giám sát (super-vised learning). Ở bài toán này ta thực hiện phân loại một tập dữ liệu (có cấu trúc hoặc không có cấu trúc) thành một hoặc nhiều lớp nhất định nhờ vào một mô hình phân loại. Mô hình này xây dựng trước trên một tập dữ liệu có nhãn (còn được gọi là tập huấn luyện).

2.2. Đặc trưng học sâu

2.2.1 Mạng VGG19



Hình 2. Kiến trúc mạng VGG19 [8] đạt “state of the art” tại cuộc thi ILSVRC-2014 trên bộ dữ liệu về phân loại ảnh ImageNet

Mô hình VGG-19 (Hình 2) có kiến trúc mạng sâu hơn VGG-16 với 16 lớp tích chập, 3 lớp fully connected, 5 lớp max pooling và 1 lớp Softmax để phân loại. Kiến trúc mạng này với có khoảng 143 triệu tham số, trong đó các tham số được học từ bộ dữ liệu ImageNet chứa 1,2 triệu đối tượng chung của 1.000 loại đối tượng khác nhau để đào tạo. Ước tính chập được cố định 1 pixel cho đệm không gian (spatial padding) của đầu vào lớp tích chập sao cho độ phân giải không gian được bảo toàn sau khi tích chập. Đệm không gian được thực hiện bởi năm lớp tổng hợp tối đa (max pooling) theo sau một số lớp tích chập. Max-pooling được thực hiện trên cửa sổ 2x2 pixel với bước trượt (stride) là 2. Tiếp theo là đơn vị tuyến tính chỉnh lưu (Rectified linear unit (ReLU)) để làm cho mô hình phân loại tốt hơn và cải thiện thời gian tính toán vì các mô hình trước đó sử dụng các hàm tanh hoặc sigmoid.


2.2.2. Mạng Densenet201

Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112 × 112	7 × 7 conv, stride 2			
Pooling	56 × 56	3 × 3 max pool, stride 2			
Dense Block (1)	56 × 56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56 × 56	1 × 1 conv			
	28 × 28	2 × 2 average pool, stride 2			
Dense Block (2)	28 × 28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28 × 28	1 × 1 conv			
	14 × 14	2 × 2 average pool, stride 2			
Dense Block (3)	14 × 14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	14 × 14	1 × 1 conv			
	7 × 7	2 × 2 average pool, stride 2			
Dense Block (4)	7 × 7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Classification Layer	1 × 1	7 × 7 global average pool			
		1000D fully-connected, softmax			

Hình 3. Kiến trúc mạng DenseNet [9] với 4 cấu trúc: DenseNet121, DenseNet169, DenseNet201, DenseNet264 gồm các lớp tích chập, Pooling, Transaction và các Dense block

DenseNet (hình 3) là một trong những biến thể mở rộng của Resnet và là một kiến trúc mạng, trong đó mỗi lớp được kết nối trực tiếp với mỗi lớp khác nhau theo kiểu chuyển tiếp (trong mỗi khối dense block). Đối với mỗi lớp, các bản đồ đặc trưng (feature map) của tất cả các lớp ở phần trước được coi là các đầu vào riêng biệt và ở đó các bản đồ tính năng lại tiếp tục làm đầu vào cho tất cả các lớp tiếp theo. Cấu trúc mạng này mang lại độ chính xác “state of the art” trên CIFAR. Trên bộ dữ liệu ILSVRC 2012 (ImageNet), DensetNet đạt được độ chính xác tương tự như ResNet, nhưng sử dụng ít hơn một nửa số lượng tham số.

DenseNet có cấu trúc gồm các dense block và các transaction layers. Trong kiến trúc CNN truyền thống, nếu có L Layer thì có L connection, trong densenet sẽ có $L(L+1)/2$ connection.




Hình 4. Kiến trúc Block DenseNet201 [10]

Trong bài toán phân loại COVID-19 này chúng tôi thực nghiệm với kiến trúc mạng DenseNet-201 (hình 4) là một mạng neural network gồm 201 lớp, thuộc nhóm mô hình DenseNet được huấn luyện trên bộ dữ liệu Image-Net. Densenet-201 có kích thước là 77MB lớn hơn gấp đôi so với kích thước của DenseNet-121. Đầu vào của kiến trúc mạng là ảnh có kích thước 224x224.

2.2.3. Mạng EfficientnetB1

EfficientNet được giới thiệu lần đầu tiên về 2 kỹ sư Google là Mingxing Tan và Quoc V. Le vào tháng 5, năm 2019. Kiến trúc mạng EfficientNet là một mạng convolutional neural network đạt state-of-the-art về độ chính xác với số lượng tham số và FLOPS ít hơn nhưng đạt hiệu quả và nhanh hơn các kiến trúc mạng khác. EfficientNets được dựa trên AutoML và kết hợp scaling để đạt được hiệu suất cao mà không ảnh hưởng đến hiệu quả tài nguyên. Kiến trúc AutoML Mobile đã giúp việc phát triển một mạng mobile-size là Efficient-B0. Từ mạng Efficient-B0 ban đầu sau khi được cải thiện bằng phương pháp kết hợp scaling thành các kiến trúc mạng từ Efficient B1-B7.

Trong nghiên cứu này, chúng tôi đã sử dụng kiến trúc mạng EfficientNetB1 (hình 5) để thực hiện việc rút trích đặc trưng và dùng các phương pháp truyền thống để phân loại.



Hình 5. Kiến trúc mạng EfficientNet B1 [11] được scale-up trên kiến trúc mạng cơ sở EfficientNet B0. Các mô hình EfficientNet được chia tỷ lệ liên tục giảm các thông số và FLOPS.

2.3. Các phương pháp máy học

2.3.1. Logistic Regression

Hồi quy logistic là một thuật toán phân loại được sử dụng để gán các quan sát cho một tập hợp các lớp rời rạc. Không giống như hồi quy tuyến tính với đầu ra là các giá trị số liên tục, hồi quy logistic biến đổi đầu ra của nó bằng cách sử dụng hàm Logistic Sigmoid để trả về một giá trị xác suất mà sau đó có thể được ánh xạ tới hai hoặc nhiều lớp rời rạc. Hồi quy tuyến tính có thể giúp chúng ta dự đoán các giá trị liên tục. Hồi quy logistic dự đoán các giá trị rời rạc.

2.3.2. k-NN

k-NN là một phương pháp phân loại không tham số được sử dụng để phân loại và hồi quy. Trong quá trình huấn luyện, thuật toán này không học từ dữ liệu huấn luyện nên nó được xếp vào loại lười học (lazylearning). Mọi tính toán được thực hiện khi cần dự đoán kết quả của dữ liệu mới. k-NN hoạt động bằng cách tìm khoảng cách giữa truy vấn và tất cả các mẫu (sample) trong tập dữ liệu, sau đó chọn số k điểm dữ liệu gần với truy vấn nhất. Tiến hành bỏ phiếu cho nhãn xuất hiện nhiều nhất (trong trường hợp phân loại) hoặc số trung bình các nhãn (trong trường hợp hồi quy).

2.3.3. SVM


SVM là một thuật toán học giám sát có thể được sử dụng cho cả phân loại hoặc hồi quy. Một cách cụ thể, SVM hỗ trợ việc tạo ra một siêu phẳng hoặc tập hợp các siêu phẳng trong một không gian có số chiều hữu hạn hoặc vô hạn. Kết quả phân loại đạt kết quả tốt nhất khi siêu phẳng có khoảng cách lớn nhất đến điểm dữ liệu huấn luyện gần nhất của bất kỳ lớp nào (khoảng cách biên). Mục đích của phương pháp SVM là tìm ra khoảng cách biên lớn nhất.

2.4. Kiến trúc thực nghiệm

Trong kiến trúc phân loại ở hình 6 dữ liệu COVID-19 được thu thập đa dạng ở nhiều nguồn khác nhau và Kaggle. Sau đó tiến hành phân bổ dữ liệu theo Bảng 1. Chúng tôi thực hiện chuẩn hóa dữ liệu đầu vào bằng cách tinh chỉnh kích thước của hình ảnh trong bộ dữ liệu, chuyển đổi về ảnh xám để thích hợp với đầu vào từng phương pháp rút trích đặc trưng.

Bảng 1. Tổ chức dữ liệu thực nghiệm

Label/Class	Tổng số lượng ảnh X-quang/class	Ảnh sử dụng	Tập training/folder	Tập test/folder
COVID-19	439	439	351	88
NORMAL	1517	439	351	88
PNEUMONIA	1465	439	351	88



Hình 6. Kiến trúc hệ thống phân loại hình ảnh COVID 19

Tiếp đến, chúng tôi đưa dữ liệu vào các mô hình học sâu, tiến hành rút trích đặc trưng từ các mô hình này. Sau đó, sử dụng 3 phương pháp máy học truyền thống chính là k-NN, SVM và Logistic Regression để phân lớp. Ở phương pháp k-NN, chúng tôi lựa chọn các giá trị k tương ứng là 1, 3, 5, 7, 9 trên hai độ đo khoảng cách Cosine và Minkowski. Sau khi có được các mô hình từ việc huấn luyện, chúng tôi đánh giá kết quả phân loại dựa vào đặc trưng ở phần kiểm tra (test). Kết quả phân loại được thống kê chi tiết ở phần thực nghiệm và đánh giá.

3. Kết quả và bàn luận

3.1. Bộ dữ liệu

Các ảnh từ các bộ dữ liệu này được thu thập và cập nhật thông tin của ảnh các bệnh nhân được xác nhận tình trạng bệnh bởi các bác sĩ có chuyên môn. Sau khi thu thập chúng tôi đã chọn lọc, kiểm tra và gộp thành một bộ dữ liệu lớn hơn với mỗi trường hợp ảnh được gán nhãn đầy đủ gồm 1517 ảnh NORMAL (tình trạng không bị nhiễm bệnh), 1467 ảnh PNEUMONIA (tình trạng bệnh viêm phổi thông thường), 439 ảnh COVID (tình trạng đã mắc COVID-19). Bộ dữ liệu là một tập hợp gồm bốn bộ dữ liệu:

COVID-19 Radiography Database [12]: Bộ dữ liệu gồm ba thư mục chứa ảnh chính và file excel chứa thông tin hình ảnh: COVID-19 (219 ảnh), NORMAL (1341 ảnh), Viral Pneumonia (1345 ảnh).

Covid-19 Image Dataset [13] : Bộ dữ liệu gồm có 317 ảnh phổi được chia thành hai thư mục train và test. Ở mỗi thư mục chứa các thư mục con đã được gán nhãn. Trong đó thư mục train: COVID-19 (111 ảnh), NORMAL (70 ảnh), Viral Pneumonia (70 ảnh). Thư mục test: COVID-19 (26 ảnh), NORMAL (20 ảnh), Viral Pneumonia (20 ảnh).

COVID-19 Patients Lungs X Ray Images 10000 [14]: Bộ dữ liệu là sự kết hợp của 2 bộ dữ liệu Covid: Trường hợp COVID-19 được lấy từ IEEE COVID-chest X-ray-dataset [15]. Các trường hợp còn lại gồm NORMAL và PNEUMONIA được thu thập từ bộ dữ liệu Chest X-Ray Images (Pneumonia) [17] được công bố trên Kaggle.

COVID19 High quality images [16] gồm 337 ảnh phổi được cấu trúc như sau: Covid (120 ảnh, gồm 7 ảnh chụp X-quang não và 103 ảnh phổi); Normal (148 ảnh phổi) và Viral Pneumonia (120 ảnh phổi).


3.2. Kết quả - Thảo luận

3.2.1. Tiền xử lý cơ sở dữ liệu

Ảnh chụp X-quang được thay đổi kích thước trước khi thực hiện tính toán bằng các thuật toán rút trích đặc trưng và làm đầu vào cho các mô hình được huấn luyện trước đó. Cụ thể bao gồm ba kiến trúc mạng học sâu: VGG19 (224x224), Densenet201 (224x224), EffcientnetB1 (224x224). Tất cả các hình ảnh đã được chuẩn hóa theo các tiêu chuẩn kích thước đầu vào tương ứng với yêu cầu đầu vào từng mô hình kiến trúc mạng.

3.2.2. Kết quả thực nghiệm

Với bộ dữ liệu COVID-19 sau khi đã tổng hợp và sau bước tiền xử lý dữ liệu, theo kiến trúc ở Hình 6. Chúng tôi tiếp tục đưa dữ liệu qua các kiến trúc mạng học sâu, sau đó tiến hành cấu hình để rút trích đặc trưng. Với sự đa dạng của việc khảo sát trên nhiều kiến trúc mạng khác nhau, chúng tôi thu được ba đặc trưng khác nhau được biểu thị thông qua các feature map ở Hình 7 dưới đây.



Thông qua các feature map biểu diễn các đặc trưng hình ảnh của kiến trúc mạng đã có sự khác biệt rất nhiều so với ảnh gốc. Ứng với mỗi kiến trúc mạng qua các lớp filter đã cho ra đặc trưng ảnh với cấu trúc khác nhau.

Kế tiếp bước rút trích đặc trưng, chúng tôi sử dụng các đặc trưng này làm đầu vào cho việc phân loại hình ảnh với ba phương pháp phân loại SVM, logistic regression và k-NN. Sau khi huấn luyện, chúng tôi thực hiện kết quả thực nghiệm trên tập kiểm tra (test) của bộ dữ liệu COVID-19. Kết quả thực nghiệm được chúng tôi thống kê khi sử dụng ba phương pháp phân loại SVM, logistic regression và k-NN lần lượt ở Bảng 1 và 2 với kết quả trung bình trên ba class: COVID19, NORMAL và PNEUMONIA.

Bảng 2. Kết quả thực nghiệm sử dụng phương pháp SVM và Logistic regression cùng các đặc trưng học sâu

Đặc trưng	SVM				Logistic regression			
	Precision	Recall	Accuracy	F1-score	Precision	Recall	Accuracy	F1-score
VGG19	0,98	0,97	0,97	0,97	0,98	0,97	0,97	0,97
Densenet201	0,97	0,96	0,96	0,96	0,96	0,96	0,96	0,96
EffcientnetB1	0,96	0,96	0,96	0,96	0,95	0,95	0,95	0,95

Bảng 3. Kết quả thực nghiệm sử dụng phương pháp KNN sử dụng độ đo khoảng cách Cosine và Minkowski cùng các đặc trưng học sâu

Đặc trưng	k	Cosine				Minkowski			
		Precision	Recall	Accuracy	F1-score	Precision	Recall	Accuracy	F1-score
VGG19	1	0,95	0,92	0,92	0,93	0,95	0,92	0,92	0,92
	3	0,96	0,95	0,95	0,95	0,96	0,91	0,91	0,91
	5	0,96	0,94	0,94	0,95	0,96	0,92	0,92	0,92
	7	0,95	0,94	0,94	0,95	0,95	0,91	0,91	0,91
	9	0,95	0,94	0,93	0,95	0,95	0,90	0,90	0,90
Densenet201	1	0,94	0,92	0,92	0,93	0,95	0,94	0,93	0,94
	3	0,96	0,94	0,94	0,95	0,95	0,93	0,93	0,94
	5	0,96	0,94	0,94	0,95	0,95	0,94	0,94	0,94
	7	0,95	0,94	0,94	0,95	0,96	0,94	0,94	0,95
	9	0,95	0,94	0,94	0,95	0,95	0,94	0,94	0,94
Efficientnet-B1	1	0,94	0,91	0,91	0,92	0,94	0,91	0,91	0,92
	3	0,95	0,95	0,95	0,96	0,95	0,92	0,92	0,94
	5	0,95	0,92	0,92	0,94	0,95	0,92	0,92	0,93
	7	0,95	0,93	0,93	0,94	0,95	0,93	0,93	0,94
	9	0,94	0,92	0,92	0,93	0,95	0,93	0,93	0,94

Dựa vào các kết quả ở Bảng 1 và 2 ta nhận định được rằng:

Khi thực nghiệm phương pháp k-NN cùng với độ đo khoảng cách Cosine, kết quả bài toán đạt độ chính xác cao nhất ở hai trường hợp. Trường hợp đầu tiên là khi chọn k=3 với đặc trưng rút trích từ mạng học sâu VGG19 (precision=0,96, recall=0,95, accuracy=0,95, f1-score=0,95). Trường hợp thứ hai, khi chọn k=3, và sử dụng đặc trưng EfficientnetB1 (precision=0,96, recall=0,95, accuracy=0,95, f1-score=0,96). Khi sử dụng độ đo Minkowski kết quả bài toán đạt độ chính xác cao nhất khi chọn k=7 và đặc trưng được rút trích từ kiến trúc Densenet201.

Khi thực nghiệm phương pháp SVM và Logistic regression đạt độ chính xác cao ở trường hợp sử dụng đặc trưng VGG19. Cụ thể: SVM (precision=0,98, recall=0,97, accuracy=0,97, f1-score=0,97), Logistic regression (precision=0,98, recall = 0,97, accuracy=0,97, f1-score=0,97).

Trong nghiên cứu này, chúng tôi đã khảo sát việc phân loại bệnh COVID19 sử dụng các phương pháp truyền thống kết hợp việc rút trích đặc trưng của ba kiến trúc học sâu đã được đánh giá cao ở các cuộc thi phân loại trên bộ dữ liệu nổi tiếng ImageNet. Ở phương pháp k-NN việc khảo sát trên các giá trị k, độ đo khoảng cách khác nhau cùng với ba đặc trưng học sâu đã cho thấy được sự ảnh hưởng không nhỏ của các yếu tố này đến kết quả phân loại. Việc sử dụng các kiến trúc mạng học sâu đã được đào tạo trước là “state of the art” đã mang lại kết quả cao cho bài toán phân loại COVID-19. Điều này phần nào đã phần nào giúp tiết kiệm thời gian và chi phí trong quá trình huấn luyện dữ liệu, bởi việc huấn luyện một mô hình học sâu mất nhiều thời gian, ngoài ra còn đòi hỏi các yêu cầu khác về cấu hình phần cứng. Đồng thời sự đa dạng của các kiến trúc mạng học sâu mang lại một góc nhìn tổng quan hơn khi đánh giá các phương pháp phân loại. Thông qua các kết quả thực nghiệm, chúng tôi đã có cơ sở để có những lựa chọn phù hợp trong những nghiên cứu về phân loại trên bộ dữ liệu COVID-19.

4. Kết luận

COVID-19 hiện nay là một đại dịch có mức ảnh hưởng nguy hiểm đến toàn cầu. Thông qua các nghiên cứu này đã thể hiện sự quan tâm và ứng dụng nghiên cứu khoa học vào việc hỗ trợ quá trình chẩn đoán và phát hiện bệnh. Chúng tôi đã thực hiện việc thu thập và tổng hợp dữ liệu COVID-19 từ nhiều nguồn khác nhau. Khảo sát các phương pháp máy học truyền thống k-Nearest-Neighbor, Support Vector Machines, Logistic Regression sử dụng đặc trưng ảnh được rút trích từ ba kiến trúc mạng học sâu, nhằm tạo ra hệ thống phân loại COVID-19 trên ảnh X-quang phổi.

TÀI LIỆU THAM KHẢO/ REFERENCES

- [1] "Global research on coronavirus disease (COVID-19)," Who.int, 2021. [Online]. Available: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/global-research-on-novel-coronavirus-2019-ncov>. [Accessed Jan. 24, 2021].
- [2] P. Cunningham and S. Delany, "k-Nearest Neighbour Classifiers: 2nd Edition (with Python examples)," arXiv.org, 2021. [Online]. Available: <https://arxiv.org/abs/2004.04523>. [Accessed Jan. 24, 2021].
- [3] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273-297, 1995, doi: 10.1007/bf00994018.
- [4] R. E. Wright, "Logistic regression," in L. G. Grimm & P. R. Yarnold (Eds.), *Reading and understanding multivariate statistics*, American Psychological Association, 1995, pp. 217-244.
- [5] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, pp. 1097-1105, 2012.
- [6] J. Jaworek-Korjakowska, P. Kleczek and M. Gorgon, "Melanoma Thickness Prediction Based on Convolutional Neural Network With VGG-19 Model Transfer Learning," 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2019, pp. 2748-2756, doi: 10.1109/CVPRW.2019.00333.
- [7] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 4700-4708.
- [8] Zheng, Yufeng & Yang, Clifford & Merkulov, Aleksey. (2018). Breast cancer screening using convolutional neural network and follow-up digital mammography. 4. 10.1117/12.2304564. Available from: https://www.researchgate.net/figure/illustration-of-the-network-architecture-of-VGG-19-model-conv-means-convolution-FC-means_fig2_325137356 [Accessed May 17, 2021].
- [9] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko W., Wang, T. Weyand, and H. Adam, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," arXiv preprint arXiv:1704.04861, 2017.
- [10] Semi-Supervised Learning for Cancer Detection of Lymph Node Metastases - Scientific Figure on ResearchGate. Available from: https://www.researchgate.net/figure/DenseNet201-Block-Architecture_fig1_333993812 [Accessed May 17, 2021].
- [11] M. Tan and Q. V. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," arXiv preprint arXiv:1905.11946, 2019.
- [12] "COVID-19 Open Research Dataset Challenge (CORD-19)," Kaggle.com, 2021. [Online]. Available: <https://www.kaggle.com/allen-institute-for-ai/CORD-19-research-challenge>. [Accessed Jan. 24, 2021].
- [13] "Covid-19 Image Dataset," Kaggle.com, 2021. [Online]. Available: <https://www.kaggle.com/pranavraikokte/covid19-image-dataset>. [Accessed Jan. 24, 2021].
- [14] "COVID-19 Patients Lungs X Ray Images 10000," Kaggle.com, 2021. [Online]. Available: <https://www.kaggle.com/nabeelsajid917/covid-19-x-ray-10000-images>. [Accessed Jan. 24, 2021].
- [15] "ieee8023/covid-chestxray-dataset," GitHub, 2021. [Online]. Available: <https://github.com/ieee8023/covid-chestxray-dataset>. [Accessed Jan. 24, 2021].
- [16] "Chest X-Ray Images (Pneumonia)," Kaggle.com, 2021. [Online]. Available: <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>. [Accessed Jan. 24, 2021].