



Cải tiến kiến trúc của mô hình học sâu cho bài toán phân loại u não trên ảnh cộng hưởng từ

Nguyễn Thị Bích Ngọc¹, Phạm Thị Loan², Nguyễn Văn Khởi³, Mai Đức Vinh³

¹ Khoa Công nghệ thông tin, Trường Đại học Sao Đỏ, Hải Dương

² Khoa Công nghệ thông tin, Trường Đại học Công nghệ Đông Á

³ Khoa Công nghệ thông tin, Trường Đại học Giao thông Vận tải

Email: loanpt@eaut.edu.vn

Tóm tắt

U não là bệnh lý não bộ nguy hiểm, có thể gây ra biến chứng nặng và tử vong. Hiện nay, ảnh chụp cộng hưởng từ (MRI) được sử dụng rộng rãi để phát hiện và chuẩn đoán u não. Bài báo này nghiên cứu mô hình học sâu VGG16, từ đó tinh chỉnh kiến trúc nhằm phù hợp với tính chất của hình ảnh MRI, giúp cải thiện tốc độ huấn luyện và độ chính xác. Mô hình thực hiện thay đổi số lượng các lớp tích chập, Dropout và bộ lọc trước khi đưa ra dự đoán cuối cùng. Kết quả thực nghiệm cho thấy, mô hình cải tiến có độ chính xác cao hơn VGG16 trên cùng bộ dữ liệu ảnh cộng hưởng từ trong việc phân loại bốn bệnh lý gồm não bình thường, u thần kinh đệm, u màng não và u tuyến yên với độ chính xác đạt 96.68%, tốc độ huấn luyện trung bình trên cấu hình máy của chúng tôi với VGG16 là 1200s, mô hình cải tiến là 80s trên 1 epoch.

Từ khoá: MRI, U não, VGG16.

Abstract

Brain tumors are a serious neurological condition that can lead to severe complications and death. Currently, Magnetic Resonance Imaging (MRI) is widely used for the detection and diagnosis of brain tumors. This paper investigates the VGG16 deep learning model and proposes architectural modifications to better suit the characteristics of MRI images, thereby improving training speed and accuracy. The model adjusts the number of convolutional layers, incorporates Dropout, and refines filters before producing the final prediction. Experimental results show that the improved model outperforms the original VGG16 on the same MRI dataset in classifying four conditions: normal brain, glioma, meningioma, and pituitary tumor, achieving an accuracy of 96.68%. The average training time on our system configuration is 1200 seconds per epoch for VGG16, compared to 80 seconds per epoch for the improved model.

Keywords: MRI, brain tumor, VGG16

1. Mở đầu

Bệnh lý u não là một bệnh lý có độ nguy hiểm cao, do sự tăng trưởng bất thường của các tế bào não gây ra. Việc phát hiện sớm có ý nghĩa lớn cho quá trình điều trị, đòi hỏi thực hiện tầm soát thường xuyên. Tuy nhiên, nhu cầu này dẫn đến sự gia tăng số lượng dữ liệu cần kiểm tra, có thể kể tới ảnh chụp cộng hưởng từ, một trong những nguồn thông tin quan trọng trong



quá trình chẩn đoán. Điều này gây áp lực lớn đến các y bác sĩ, ảnh hưởng đến tốc độ và độ chính xác của các chẩn đoán quan trọng. Việc ứng dụng công nghệ thị giác máy tính vào xử lý các hình ảnh này giúp giảm tải gánh nặng, bằng cách tiền xử lý phân loại các hình ảnh cần chú ý, giúp tăng tốc quá trình kiểm tra, chuyển hướng tập trung vào các hình ảnh cần chẩn đoán.

Những năm gần đây, giải pháp ứng dụng học sâu đã được sử dụng nhiều trong các nghiên cứu về phát hiện bệnh lý não bộ. Bài báo [1] đề xuất một mô hình học sâu mô-đun cải tiến từ kỹ thuật học chuyển tiếp của các mô hình mạng nơ-ron tiền nhiệm. Mô hình sử dụng kỹ thuật xác thực chéo 10 lớp nhằm đảm bảo kết quả mô hình cho ra trong quá trình huấn luyện. Quá trình thử nghiệm của mô hình cho ra kết quả tốt, đạt độ chính xác 96%, tuy nhiên có sự gia tăng về thời gian huấn luyện. Các tác giả của bài báo [2] xây dựng 2 mô hình 4 phần và một mô hình 8 phần bằng phương pháp học sâu nhằm chẩn đoán người mắc chứng tự kỉ bằng ảnh chụp MRI. Các mô hình kết hợp sử dụng dữ liệu gồm tuổi, giới tính vào quá trình phân loại, cung cấp một đánh giá về sự ảnh hưởng của các yếu tố này đến chứng bệnh. Thuật toán Canny Edge Detection (CED), kỹ thuật tăng cường dữ liệu và thuật toán tối ưu hoá tìm kiếm lưới (GSO) đã được áp dụng để tăng tính chính xác của mô hình. Mô hình đạt độ chính xác cao nhất là mô hình sử dụng hình ảnh MRI và thông tin độ tuổi với tỉ lệ 85.42%. Các tác giả của bài báo [3] xây dựng và thử nghiệm hai mô hình hỗ trợ chẩn đoán máy học (CAD) sử dụng thuật toán học sâu trên dữ liệu ảnh chụp cộng hưởng từ với khả năng lần lượt là phân loại 2 nhãn (bình thường và bất thường) và 3 nhãn (u thần kinh đệm, u màng não, u tuyến yên). Mô hình đầu tiên được xây dựng với 23 lớp nơ-ron tích chập, được huấn luyện bởi bộ dữ liệu gồm 3064 hình ảnh MRI. Mô hình thứ hai sử dụng kỹ thuật học chuyển tiếp trên mô hình VGG16 với một phần kỹ thuật từ mô hình 23 lớp đầu tiên. Qua quá trình thử nghiệm, hai mô hình đạt lần lượt 97.8% và 100% độ chính xác trên bộ dữ liệu được sử dụng. Bài báo [4] đề xuất mô hình học chuyển tiếp trên kiến trúc của ResNet34 nhằm phát hiện bất thường trên hình ảnh MRI não bộ. Các tác giả thực hiện các kỹ thuật như làm giàu dữ liệu, tối ưu giá trị học và tinh chỉnh tham số để thực hiện huấn luyện mô hình. Với sự đánh giá của kỹ thuật xác thực chéo 5 lớp, mô hình đạt độ chính xác 100% trên bộ dữ liệu MRI 613 hình ảnh. Bài báo [5] đề xuất mô hình phân loại u não từ hình ảnh MRI ứng dụng phương pháp học chuyển đổi, kết hợp VGG16 với khối “23 lớp CNN” nhằm cải thiện độ chính xác. Mô hình đề xuất đạt độ chính xác 97.8%. Các tác giả của bài báo [6] đề xuất mô hình kết hợp mạng CNN và LSTM nhằm trích xuất đặc trưng ảnh MRI và phát hiện u não, sử dụng bộ dữ liệu Kaggle với 3264 hình ảnh MRI, kết quả thu được đạt độ chính xác cao hơn các mô hình CNN và RNN thuần túy. Nhóm tác giả bài báo [7] đề xuất hệ thống



chẩn đoán u não qua hình ảnh MRI ứng dụng mạng CNN cùng phương thức tối ưu ADAS. Hình ảnh đầu vào sẽ được tiền xử lý và trích chọn đặc trưng, sau đó huấn luyện CNN có tối ưu ADAS để phân loại và nhận diện các chi tiết nguy hiểm. Mô hình đạt độ chính xác 94%. Nhóm tác giả bài báo [8] đề xuất mô hình mạng nơ-ron tích chập sâu kết hợp với lượng lớn các lớp và tham số, áp dụng cùng các kết nối tắt nhằm đạt được hiệu suất tốt, giảm lượng tính toán và cải thiện chất lượng ảnh đầu ra sau phân tích. Áp dụng trên 2 mô hình UnetResNet-50 và Unet gốc, UnetResNet-50, mô hình cho ra độ chính xác 99.7% và điểm DICE là 0.9573. Bài báo [9] trình bày kỹ thuật học chuyển tiếp từ VGG16, ResNet50, MobileNetV2, DenseNet201, EfficientNetB3 và InceptionV3. Quá trình huấn luyện bắt đầu từ việc tiền xử lý, làm giàu dữ liệu, áp dụng hàm tối ưu Adam/AdaMax cũng như các kỹ thuật tinh chỉnh thông số nhằm khắc phục một số vấn đề tồn đọng. Qua thử nghiệm với bộ dữ liệu 2 nhãn, 4 nhãn, mô hình MobileNetV2 đạt độ chính xác cao nhất. Bài báo [10] ứng dụng các mô hình VGG16 và ResNet50 phân loại ảnh MRI não bộ với các lớp bình thường, Đột quy, U thần kinh cấp thấp và U thần kinh cấp cao. Nhóm tác giả sử dụng nhiều bộ phân loại khác nhau như SoftMax, SVM-RBF và SVM-Cubic để so sánh kết quả giữa chúng.


Nhiều nghiên cứu đã tập trung cải tiến mô hình học sâu nhằm nâng cao hiệu quả phân loại hình ảnh MRI có dấu hiệu u não. Trong bài báo này, chúng tôi nghiên cứu mô hình học sâu VGG16 và đề xuất một số điều chỉnh trong cấu trúc của mô hình gốc trên hình ảnh MRI. Ảnh MRI cung cấp độ tương phản mô mềm cao, giúp phân biệt rõ ràng các loại mô khác nhau trong não, hỗ trợ tốt hơn trong việc phát hiện và phân loại u não. Những đặc điểm này khiến ảnh MRI trở thành lựa chọn tốt hơn cho bài toán chẩn đoán u não, nhưng cũng đặt ra thách thức trong việc thiết kế mô hình học sâu phù hợp để khai thác triệt để thông tin từ ảnh MRI. Các thử nghiệm thực tế được tiến hành để đánh giá hiệu suất của mô hình đã cải tiến, đồng thời so sánh kết quả với mô hình ban đầu.

2. Phương pháp nghiên cứu

2.1. Bộ dữ liệu

Bài báo sử dụng bộ dữ liệu hình ảnh MRI “Brain Tumor MRI Dataset” của tác giả Masoud Nickparvar, tổng số 6726 hình ảnh chia thành lớp gồm: 1731 ảnh não bộ bình thường, 1620 ảnh não bộ có u thần kinh đệm, 1635 ảnh não bộ có u màng não và 1740 ảnh não bộ có u tuyến yên [11]. Bộ dữ liệu phân bố lượng hình ảnh theo tỉ lệ lần lượt là 25.75%, 24.09%, 24.31% và 25.85%. Tỉ lệ phân phối này cho thấy bộ dữ liệu có độ cân đối tốt với số lượng ảnh mỗi nhãn không chênh lệch lớn với phân phối trung bình là 25% cho mỗi nhãn. Một số hình ảnh trong bộ

dữ liệu được thể hiện trong Hình 1. Theo đó, các hình ảnh Não Bình thường, U thần kinh đệm, U màng não, U tuyến yên được thể hiện lần lượt từ hàng 1 tới hàng 4.




Hình 1. Một số hình ảnh từ bộ dữ liệu.

Bộ dữ liệu được chia làm 2 phần gồm dữ liệu huấn luyện và dữ liệu kiểm thử. Chi tiết được thể hiện trong Bảng 1.

Bảng 1. Phân bố dữ liệu trong bài báo

Dữ liệu	Bình thường	U thần kinh đệm	U màng não	U tuyến yên	Tổng
Huấn luyện	1422	1321	1333	1445	5521
Kiểm thử	309	299	302	295	1205
Tổng	1731	1620	1635	1740	6726


Bộ dữ liệu được tổng hợp từ nhiều nguồn khác nhau, bao gồm figshare, SARTAJ và Br35H, nhằm phục vụ mục đích phân tích hình ảnh MRI. Tuy nhiên, do sự khác biệt về kích thước giữa các hình ảnh, chúng tôi thực hiện tiền xử lý là cần thiết trước khi đưa vào huấn luyện. Cụ thể, các hình ảnh được chuẩn hóa về kích thước 128x128 và áp dụng kỹ thuật làm giàu dữ liệu với các thao tác: xoay ngẫu nhiên 40 độ, dịch chuyển 20%, biến dạng hình thang 20%, lật ảnh và nhân bản ảnh. Quá trình này giúp tăng cường số lượng dữ liệu đầu vào, hỗ trợ mô hình học sâu đạt hiệu suất cao hơn. Một số hình ảnh sau khi làm giàu dữ liệu được thể hiện trong Hình 2.



Hình 2. Một số hình ảnh là kết quả của quá trình làm giàu dữ liệu.

2.2. Mô hình VGG16

VGG16 là một trong những kiến trúc mạng nơ-ron tích chập (CNN) phổ biến, được đề xuất bởi Simonyan và Zisserman trong bài báo "Very Deep Convolutional Networks for Large-Scale Image Recognition" năm 2014 [12]. Mô hình này được phát triển để cải thiện hiệu suất trên tập dữ liệu ImageNet, với thiết kế tập trung vào việc sử dụng các kernel nhỏ (3×3) nhưng xếp chồng nhiều tầng để học các đặc trưng phức tạp hơn. Mô hình VGG16 bao gồm 16 lớp với 13 lớp tích chập (Conv2D) và 3 lớp kết nối đầy đủ (Fully Connected - FC). Các tầng tích chập trong VGG16 đều sử dụng kernel 3×3 , kết hợp với hàm kích hoạt ReLU giúp mô hình có thể học được các đặc trưng tốt hơn mà không làm tăng quá nhiều số tham số. Các lớp tích chập được nhóm thành từng khối, sau mỗi khối là một lớp MaxPooling 2×2 để giảm kích thước không gian của đặc trưng. Cuối cùng, ba lớp fully connected với kích thước lần lượt 4096 - 4096 - 1000 (trong bài toán ImageNet [13]) giúp tổng hợp và phân loại đầu ra. Hình 3 mô tả kiến trúc của VGG16.




Hình 3. Kiến trúc mô hình VGG16



VGG16 có tính tổng quát hóa mạnh trong các bài toán thị giác máy tính, đặc biệt khi sử dụng transfer learning. Tuy nhiên, mô hình có số lượng tham số rất lớn (~138 triệu), làm tăng thời gian huấn luyện và yêu cầu tài nguyên tính toán cao. Trong các bài toán phân loại ảnh y khoa như MRI não bộ, VGG16 có thể đạt độ chính xác cao khi được huấn luyện với đủ dữ liệu và áp dụng kỹ thuật điều chỉnh tham số phù hợp.

2.3. Mô hình cải tiến từ kiến trúc VGG16

Dựa trên kiến trúc của mô hình VGG16, mô hình cải tiến được thiết kế với các điều chỉnh đơn giản hơn để phù hợp với kích thước ảnh đầu vào 128×128 và tối ưu hóa cho bài toán phân loại hình ảnh MRI có dấu hiệu u não. Kiến trúc gốc của VGG16 có 16 lớp tích chập với khoảng 138 triệu tham số, được thiết kế để nhận diện 1000 lớp trên bộ dữ liệu ImageNet. Tuy nhiên, trong bài báo này, chúng tôi phân loại bốn nhãn ảnh MRI, do đó, số lượng lớp Conv2D được giảm xuống nhằm tối ưu số tham số, giúp giảm yêu cầu phần cứng mà vẫn đảm bảo hiệu quả trích xuất đặc trưng. Sau khi tiến hành thử nghiệm với các bộ tham số khác nhau, chúng tôi đã tối ưu và lựa chọn thông số huấn luyện phù hợp nhất. Mô hình gồm một chuỗi các lớp Conv2D để học đặc trưng, xen kẽ với các lớp Max-Pooling2D nhằm giảm kích thước không gian và giảm số lượng tham số cần huấn luyện. Cụ thể, tầng đầu vào sử dụng một lớp Conv2D với 32 bộ lọc kích thước 3×3 và hàm kích hoạt ReLU để giữ lại các đặc trưng phi tuyến tính, tiếp theo là các lớp tích chập với số lượng bộ lọc lần lượt là 64, 128, 256 và 512, giúp mô hình học đặc trưng theo mức độ trừu tượng tăng dần. Các lớp Conv2D được thiết lập padding='same' để duy trì kích thước đầu vào. Sau khi trích xuất đặc trưng, mô hình sử dụng một lớp Flatten để chuyển đổi dữ liệu từ dạng ma trận thành vector một chiều, trước khi đi qua hai lớp Fully Connected với 4096 nơ-ron mỗi lớp. Xen kẽ giữa các lớp này là lớp Dropout(0.5) giúp giảm overfitting, tăng khả năng tổng quát hóa. Cuối cùng, lớp Softmax với 4 đầu ra được sử dụng để phân loại hình ảnh vào bốn nhóm. Hình 4 minh họa quá trình dữ liệu được xử lý qua từng tầng, từ trích xuất đặc trưng, giảm chiều dữ liệu đến giai đoạn phân loại, thể hiện cách mô hình tinh chỉnh giúp nâng cao hiệu suất nhận diện u não.



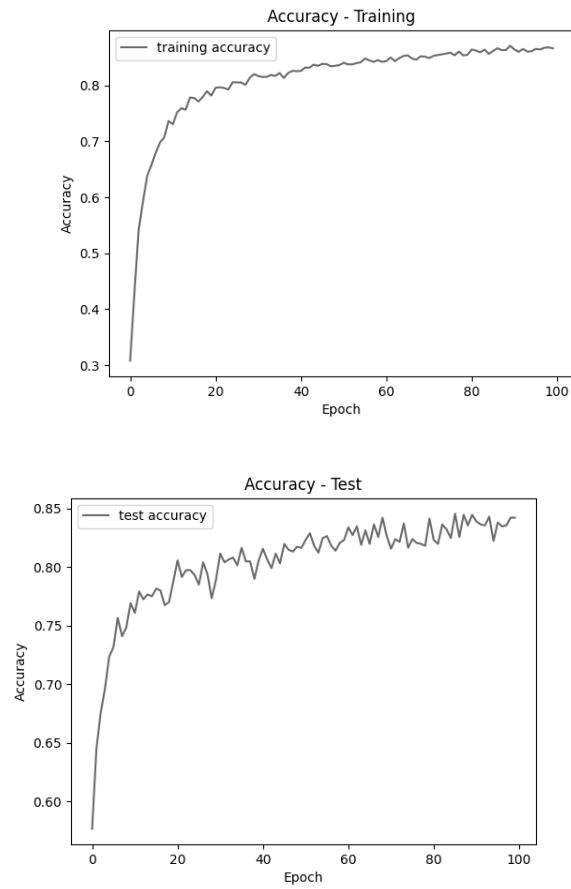
Hình 4. Kiến trúc mô hình cải tiến từ VGG16

Các tham số và giá trị được sử dụng để tinh chỉnh mô hình gồm: batch_size = 64, Hàm kích hoạt: ReLU, Hàm tối ưu: Adam.


3. Thử nghiệm và đánh giá

Hai mô hình thực hiện huấn luyện và thử nghiệm đánh giá gồm VGG16 và mô hình cải tiến từ VGG16 được đề xuất. Môi trường huấn luyện là máy tính có cấu hình Intel Xeon CPU 2.20GHz, NVIDIA Tesla T4 GPU 16GB VRAM, 16GB RAM, Python 3.6.

Qua quá trình huấn luyện và kiểm thử, chúng tôi nhận thấy mô hình VGG16 được tinh chỉnh đạt độ chính xác cao là 96.68% trong việc phân loại u não. Mô hình so sánh là VGG16 gốc đạt độ chính xác là 84.56%, thấp hơn 12.12% về độ chính xác so với phiên bản VGG16 được tinh chỉnh. Hình 5 và Hình 6 mô tả độ chính xác trong huấn luyện và kiểm thử của mô hình VGG16 gốc. Quan sát quá trình hội tụ, mô hình khởi động tốt khi độ chính xác trên cả tập huấn luyện và kiểm thử tăng nhanh trong 20 epoch đầu. Ở các epoch sau, VGG16 tiếp tục cải thiện độ chính xác huấn luyện ổn định, độ chính xác kiểm thử duy trì, không có sự dao động lớn. Kết quả cuối cùng, mô hình đạt mức chính xác 84.56%. Hình 7 và Hình 8 thể hiện đồ thị của mô hình VGG16 cải tiến, cho thấy hiệu suất được cải thiện đáng kể. Trong 20 epoch đầu, mô hình thể hiện tốc độ học tốt khi độ chính xác tăng mạnh, vượt qua ngưỡng 90%. Từ epoch 20 đến 60, mô hình tiếp tục duy trì trạng thái học ổn định, nâng cao hiệu suất phân loại. Giai đoạn từ epoch 60 đến 100, quá trình hội tụ diễn ra với tốc độ chậm hơn, nhưng mô hình vẫn đảm bảo độ chính xác cao. Mặc dù có một số biến thiên nhẹ trong quá trình kiểm thử, nhưng xu hướng chung của đồ thị kiểm thử và huấn luyện không có sự chênh lệch đáng kể.




Hình 5, 6. Đồ thị độ chính xác trong huấn luyện và kiểm thử của VGG16




Hình 7, 8. Đồ thị độ chính xác trong huấn luyện và kiểm thử của mô hình đề xuất

Để hiển thị trực quan kết quả của hai mô hình, chúng tôi sử dụng ma trận Confusion với trục tung là các nhãn thực tế và trục hoành là các nhãn dự đoán. Ma trận có kích thước 4x4 với 4 nhãn lần lượt là u thần kinh đệm (glioma), u màng não (meningioma), u tuyến yên (pituitary) và bình thường (notumor). Ma trận của mô hình VGG16 và mô hình đề xuất được thể hiện tại Hình 9 và Hình 10.



Hình 9. Ma trận Confusion của mô hình VGG16



Hình 10. Ma trận Confusion của mô hình CustomVGG



Ma trận Confusion của mô hình VGG16 được minh họa trong Hình 9, cho thấy hiệu suất phân loại của mô hình trên các lớp u não. Mô hình đạt kết quả tốt trong việc nhận diện hai nhãn pituitary và notumor, nhưng vẫn tồn tại một số nhầm lẫn đáng kể giữa các lớp còn lại, đặc biệt là giữa hai lớp glioma và meningioma, với 53 trường hợp glioma bị nhầm thành meningioma. Mô hình cũng ghi nhận 47 trường hợp meningioma bị dán nhãn nhầm thành notumor, cho thấy khả năng phân tách giữa các nhóm này chưa thực sự tối ưu. Hình 10 thể hiện ma trận Confusion của mô hình đề xuất sau khi tinh chỉnh. Kết quả cho thấy hiệu suất phân loại được cải thiện rõ rệt khi số lượng nhầm lẫn giữa các lớp giảm. Mô hình cải tiến đã khắc phục phần lớn những nhầm lẫn mà VGG16 gặp phải, giúp tăng cường khả năng nhận diện chính xác giữa các cặp nhãn khó phân biệt như glioma – meningioma và meningioma – notumor.

Để so sánh chi tiết hai mô hình, chúng tôi thực hiện thống kê và so sánh bốn giá trị gồm Precision, Recall, F1 Score và Accuracy. Trong đó, Accuracy là tỉ lệ giữa tổng số ảnh được dán nhãn đúng trên tổng số ảnh trong bộ dữ liệu kiểm thử, được tính theo công thức (1). Precision là tỉ lệ giữa số ảnh được dán nhãn đúng trong một lớp trên tổng số những ảnh được dán nhãn vào lớp đó, được tính theo công thức (2). Giá trị Recall là tỉ lệ giữa số ảnh được dán nhãn đúng trong một lớp trên tổng số ảnh của lớp đó, được tính theo công thức (3). Đại lượng F1-score là trung bình điều hoà được xác định dựa trên hai độ đo precision và recall, được tính theo công thức (4). Kết quả so sánh trung bình các giá trị của bốn lớp được thể hiện trong Bảng 2.

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

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (4)$$

Bảng 2. So sánh các thông số giữa 2 mô hình

Mô hình	Precision	Recall	F1 Score	Accuracy
---------	-----------	--------	----------	----------



VGG16	85.02%	84.56%	84.10%	84.56%
Mô hình đề xuất	96.8%	96.68%	96.69%	96.68%

Mô hình VGG16 đạt Precision 85.02%, Recall 84.56%, F1 Score 84.10% và Accuracy 84.56%, thể hiện khả năng phân loại tương đối. Mô hình đề xuất đạt Precision 96.8%, Recall 96.68%, F1 Score 96.69% và Accuracy 96.68%, cho thấy sự cải thiện đáng kể trên toàn bộ chỉ số đánh giá. Kết quả này khẳng định các điều chỉnh kiến trúc mô hình giúp nâng cao hiệu suất tổng thể, cải thiện khả năng phân biệt giữa các loại u não và tăng độ tin cậy khi áp dụng trong thực tế.

4. Kết luận

Phát hiện sớm u não là vấn đề cấp thiết. Trong bài báo này, chúng tôi đã thực hiện cải tiến mô hình VGG16 nhằm tối ưu hóa cho bài toán phân loại hình ảnh MRI có dấu hiệu u não. Thay vì giữ nguyên kiến trúc gốc, chúng tôi điều chỉnh số lượng lớp Conv2D và các thông số liên quan để giảm tải yêu cầu phần cứng mà vẫn đảm bảo hiệu quả trích xuất đặc trưng. Mô hình sau khi tinh chỉnh vẫn duy trì khả năng học đặc trưng theo mức độ trừu tượng tăng dần, nhờ sự sắp xếp hợp lý các lớp Conv2D, Max-Pooling2D và Fully Connected. Việc tinh chỉnh VGG16 giúp mô hình phù hợp hơn với đặc thù của dữ liệu hình ảnh y tế, tăng tốc độ huấn luyện, mở ra hướng nghiên cứu mới trong việc áp dụng các mô hình học sâu vào chẩn đoán hỗ trợ y khoa. Trong tương lai, chúng tôi sẽ thử nghiệm thêm các kỹ thuật tối ưu hóa khác, thử nghiệm với kiến trúc CNN hiện đại, kết hợp mô hình với kỹ thuật học chuyển giao để tiếp tục nâng cao hiệu suất phân loại.

Tài liệu tham khảo

- [1]. O. Özkaraca, O. İ. Bağrıaçık, H. Gürüler, F. Khan, J. Hussain, J. Khan, U. Laila, “Multiple brain tumor classification with dense CNN architecture using brain MRI images,” *Life*, vol. 13, no. 2, 2023. DOI:10.3390/life13020349.
- [2]. H. S. Nogay, H. Adeli, “Multiple classification of brain MRI autism spectrum disorder by age and gender using deep learning,” *J. Med. Syst.*, vol. 48, no. 15, 2024. DOI: 10.1007/s10916-023-02032-0.
- [3]. Md. Saikat Islam Khan, Anichur Rahman, Tanoy Debnath, Md. Razaul Karim, Mostofa Kamal Nasir, Shahab S. Band, Amir Mosavi, Iman Dehzangi, “Accurate brain tumor detection using deep convolutional neural network”, *Computational and Structural*



- Biotechnology Journal, 2022, 20, 4733-4745, ISSN 2001-0370, <https://doi.org/10.1016/j.csbj.2022.08.039>.
- [4]. Muhammed Talo, Ulas Baran Baloglu, Özal Yıldırım, U Rajendra Acharya, “Application of deep transfer learning for automated brain abnormality classification using MR images”, Cognitive Systems Research, 2019, 54, 176-188, ISSN 1389-0417, <https://doi.org/10.1016/j.cogsys.2018.12.007>.
- [5]. Md. Saikat Islam Khan, Anichur Rahman, Tanoy Debnath, Md. Razaul Karim, Mostofa Kamal Nasir, Shahab S. Band, Amir Mosavi, Iman Dehzangi, “Accurate brain tumor detection using deep convolutional neural network”, Computational and Structural Biotechnology Journal, 2022, 20, 4733-4745, ISSN 2001-0370, <https://doi.org/10.1016/j.csbj.2022.08.039>.
- [6]. Ramdas Vankdothu, Mohd Abdul Hameed, Husnah Fatima, “A Brain Tumor Identification and Classification Using Deep Learning based on CNN-LSTM Method”, Computers and Electrical Engineering, Volume 101, 2022, 107960, ISSN 0045-7906, <https://doi.org/10.1016/j.compeleceng.2022.107960>.
- [7]. Thanh Han-Trong, Hinh Nguyen Van, Huong Nguyen Thi Thanh, Vu Tran Anh, Dung Nguyen Tuan, Luu Vu Dang, "An Efficient Method for Diagnosing Brain Tumors Based on MRI Images Using Deep Convolutional Neural Networks", Applied Computational Intelligence and Soft Computing, 2022, 2022, Article ID 2092985, 18. <https://doi.org/10.1155/2022/2092985>
- [8]. Hari Mohan Rai, Kalyan Chatterjee, Sergey Dashkevich, "Automatic and accurate abnormality detection from brain MR images using a novel hybrid UnetResNext-50 deep CNN model," Biomedical Signal Processing and Control, 2021, 66, 102477, ISSN 1746-8094, <https://doi.org/10.1016/j.bspc.2021.102477>.
- [9]. Rasa SM, Islam MdM, Talukder MdA, và các cộng sự. “Brain tumor classification using fine-tuned transfer learning models on magnetic resonance imaging (MRI) images”, DIGITAL HEALTH. 2024. 10. doi:10.1177/20552076241286140
- [10]. S. Kadry, Y. Nam, H. T. Rauf, V. Rajinikanth và I. A. Lawal, "Automated Detection of Brain Abnormality using Deep-Learning-Scheme: A Study," 2021 Seventh International conference on Bio Signals, Images, and Instrumentation (ICBSII), Chennai, India, 2021, 1-5, doi: 10.1109/ICBSII51839.2021.9445122



- [11]. Msoud Nickparvar, “Brain Tumor MRI Dataset”, <https://www.kaggle.com/dsv/2645886>, Kaggle, 2021, 10.34740/KAGGLE/DSV/2645886.
- [12]. Karen Simonyan, Andrew Zisserman. “Very Deep Convolutional Networks for Large-Scale Image Recognition”, arXiv, 2015. <https://arxiv.org/abs/1409.1556>.
- [13]. Olga Russakovsky, Jia Deng, Hao Su, Jonathan Krause, Sanjeev Satheesh, Sean Ma, Zhiheng Huang, Andrej Karpathy, Aditya Khosla, Michael Bernstein, Alexander C. Berg, Li Fei-Fei. “ImageNet Large Scale Visual Recognition Challenge”, arXiv, 2015. <https://arxiv.org/abs/1409.0575>.