

# MÔ HÌNH HỌC SÂU KẾT HỢP MỜ TRONG VIỆC PHÂN LOẠI KHỐI U NÃO TRÊN ẢNH MRI

## FUZZY ENSEMBLE DEEP LEARNING FOR BRAINS TUMOR CLASSIFICATION ON MRI

HỒ CHẤN KHOA<sup>a</sup>, LÊ THỊ HẠNH HIỀN,  
NGUYỄN THỊ HỒNG YẾN, PHAN ANH CANG  
Trường Đại học Sư phạm Kỹ thuật Vĩnh Long  
<sup>a</sup>Tác giả liên hệ: khoa hc@vlute.edu.vn

Nhận bài(Received): 9/7/2025; Phản biện (Reviewed): 2/8/2025; Chấp nhận (Accepted): 19/9/2025

### TÓM TẮT

Khối u não là một bệnh lý nghiêm trọng, ảnh hưởng đến hệ thần kinh trung ương và đe dọa đến chức năng sống của con người. Mặc dù chụp cộng hưởng từ (MRI) là công cụ chính trong phát hiện và phân loại khối u não, việc chẩn đoán dựa trên hình ảnh vẫn gặp nhiều thách thức do sự tương đồng hình thái giữa các loại khối u và sự không đồng nhất trong chất lượng ảnh, làm giảm độ chính xác. Các mô hình học sâu đã được ứng dụng và mang lại nhiều kết quả tích cực trong phân loại ảnh MRI. Tuy nhiên, phần lớn vẫn dựa trên các mô hình đơn lẻ, dẫn đến hiệu suất chưa ổn định trong các trường hợp phức tạp. Nhằm khắc phục hạn chế này, bài báo đề xuất một phương pháp học sâu kết hợp Fuzzy-EDTrans, kết hợp ba mô hình mạng là EfficientNet, Vision Transformer và DenseNet bằng phương pháp Fuzzy Sugeno Integral. Phương pháp này giúp tận dụng ưu điểm của từng mô hình và cải thiện độ chính xác trong phân loại. Thử nghiệm trên tập dữ liệu BrTC2020 cho thấy Fuzzy-EDTrans đạt độ chính xác ấn tượng 97,91%.

**Từ khóa:** U não, Học sâu, Fuzzy Sugeno Integral, Học tổng hợp.

### ABSTRACT

*Brain tumors are serious medical conditions that affect the central nervous system and pose a threat to vital human functions. Although Magnetic Resonance Imaging (MRI) is the primary tool for detecting and classifying brain tumors, image-based diagnosis still faces many challenges due to morphological similarities among tumor types and inconsistencies in image quality, leading to reduced accuracy. Deep learning models have been applied and have shown promising results in brain MRI classification. However, most approaches still rely on individual models, which often produce unstable performance in complex cases. To address this limitation, this paper proposes a hybrid deep learning approach named Fuzzy-EDTrans, which integrates three neural network architectures-EfficientNet, Vision Transformer, and DenseNet-using the Fuzzy Sugeno Integral. This method leverages the strengths of each model to enhance classification accuracy. Experiments conducted on the BrTC2020 dataset demonstrate that Fuzzy-EDTrans achieves an impressive accuracy of 97.91%.*

**Keywords:** Brain Tumor, Deep Learning, Fuzzy Sugeno Integral, Ensemble Learning.

## 1. GIỚI THIỆU

### 1.1. Giới thiệu bài toán

U não và các bệnh lý liên quan đến hệ thần kinh trung ương đang là mối quan ngại nghiêm trọng về sức khỏe toàn cầu, với khoảng 347.992 ca mắc mới và 246.253 ca tử vong được ghi nhận mỗi năm trên toàn thế giới [1]. Tại Việt Nam, ung thư não xếp thứ 14 trong số các loại ung thư phổ biến nhất, với khoảng 2.829 ca mắc mới hàng năm và tỷ lệ tử vong lên đến 48%, chủ yếu do việc phát hiện và chẩn đoán muộn [2]. Mặc dù chỉ chiếm khoảng 1,6% tổng số các loại ung thư, u não có tỷ lệ tử vong bất thường cao, với chỉ 13% bệnh nhân sống sót sau năm năm kể từ thời điểm chẩn đoán tại Vương quốc Anh [1]. Đáng chú ý, 38,9% số ca được phát hiện tại Anh thông qua nhập viện cấp cứu, cho thấy những hạn chế đáng kể trong khả năng phát hiện sớm [1]. U não cũng là một trong những nguyên nhân tử vong hàng đầu do ung thư ở trẻ em và thanh thiếu niên tại nhiều quốc gia, bao gồm cả Việt Nam. Hiện nay, chụp cộng hưởng từ (MRI) là công cụ chẩn đoán chính nhờ khả năng cung cấp hình ảnh giải phẫu chi tiết [3]; tuy nhiên, quá trình giải thích ảnh MRI vẫn phụ thuộc nhiều vào kinh nghiệm chuyên gia và mất nhiều thời gian. Nhằm nâng cao độ chính xác và tính ổn định trong phân loại khối u não, bài báo này đề xuất Fuzzy-EDTrans - một mô hình học sâu tích hợp ba kiến trúc hiện đại gồm EfficientNet, DenseNet và Vision Transformer, kết hợp thông qua phương pháp Fuzzy Sugeno Integral.

### 1.2. Các nghiên cứu liên quan

Trong những năm gần đây, việc ứng dụng học sâu vào phân loại khối u não từ hình ảnh MRI đã thu hút sự quan tâm đáng


kể, phản ánh nhu cầu cấp thiết trong việc nâng cao độ chính xác chẩn đoán. Nhiều nghiên cứu đã hướng đến cải tiến hiệu quả mô hình, đơn cử như J. Cheng và cộng sự [4] với phương pháp tăng cường vùng quan tâm (ROI) kết hợp biểu đồ cường độ, GLCM và BoW, đạt độ chính xác 91,28% trên dữ liệu MRI T1. V. Sajja và Kalluri [5] sử dụng Fuzzy C-Means kết hợp VGG16, đạt độ chính xác 96,70% trên tập BRATS. Các nghiên cứu sử dụng học chuyển giao với EfficientNet cũng ghi nhận hiệu quả cao: Sameh Samir [6] đạt 97,98%, Medina và Sánchez [7] đạt 97,5%, và Sharma và Shukla [8] đạt 98,00% trên tập dữ liệu Kaggle SARTAJ BrTC2020. Muhannad Alanazi và cộng sự [9] đã ứng dụng học chuyển giao bằng cách sử dụng một mạng nơ-ron sâu gồm 22 lớp, được huấn luyện trên tập dữ liệu khối u não Figshare, và đạt được độ chính xác 96,89%. W. Chen và cộng sự [10] đã thiết kế một khung hợp nhất đặc trưng lai bằng cách kết hợp các đặc trưng sâu từ ResNet101, DenseNet121 và EfficientNetB0, đạt độ chính xác phân loại lần lượt là 99,18% và 97,24% trên hai tập dữ liệu khác nhau. Jaeyong Kang và cộng sự [11] đã đề xuất một phương pháp tổng hợp các đặc trưng sâu được trích xuất từ DenseNet-169, ShuffleNet V2 và MnasNet, sau đó phân loại bằng Máy Vector Hỗ trợ (SVM), đạt độ chính xác 93,72% trên tập dữ liệu MRI. Những kết quả này cho thấy tiềm năng của học sâu trong chẩn đoán khối u não, tuy nhiên đa số vẫn dựa trên các mô hình đơn lẻ. Điều này làm nổi bật nhu cầu về các phương pháp tích hợp nhằm cải thiện tính ổn định và khả năng khái quát hóa-mục tiêu chính của nghiên cứu này

## 2. CƠ SỞ LÝ THUYẾT

### 2.1. Các loại khối u não và chẩn đoán MRI.

Các triệu chứng phổ biến của khối u não bao gồm đau đầu, buồn nôn, các vấn đề về thị lực, co giật và suy giảm nhận thức [12], [13]. Đau đầu vào buổi sáng và

nôn không rõ nguyên nhân có thể báo hiệu tăng áp lực nội sọ. Phát hiện sớm là điều cần thiết để điều trị. Hình 1a–1c cho thấy các loại khối u điển hình: u thần kinh đệm (hung hăng, tiên lượng xấu), u màng não (chủ yếu lành tính) và u tuyến yên (liên quan đến hormone). Hình 1d cho thấy MRI não bình thường để so sánh.



Hình 1. Hình ảnh MRI về các loại khối u từ tập dữ liệu BrTC [6][7][8]

### 2.2. Học chuyển giao - Transfer learning

Học chuyển giao-Transfer learning [14] khai thác các mô hình đã được huấn luyện trước để giải quyết các tác vụ mới với dữ liệu giới hạn, điều này đặc biệt phù hợp trong xử lý ảnh y tế, nơi dữ liệu gắn nhãn thường khan hiếm. Trong nghiên cứu này, ba kiến trúc nổi bật được sử dụng trong mô hình phân loại khối u não bao gồm: EfficientNet [15], Vision Transformer [16], và DenseNet [17].

### 2.3. Học tổng hợp – Ensemble learning

Soft Voting [18] là một phương pháp tổng hợp, trong đó xác suất dự đoán của từng lớp từ các mô hình thành phần được tính trung bình để đưa ra quyết định cuối cùng. Cụ thể, đối với mỗi lớp  $c$ , giả sử  $p_i$  là xác suất mà mô hình thứ  $i$  gán cho lớp đó. Khi đó, xác suất voting tổng hợp cho lớp  $c$ , ký hiệu là  $P_{voting}(c)$ , được tính theo công thức:

$$P_{voting}(c) = \frac{1}{n} \sum_{i=1}^n p_i^{(c)} \quad (1)$$

Hard Voting [19] là một phương pháp

tổng hợp, trong đó lớp đầu ra cuối cùng được xác định dựa trên nguyên tắc biểu quyết đa số giữa các mô hình thành phần. Cụ thể, mỗi mô hình đưa ra một phiếu cho lớp mà nó dự đoán có xác suất cao nhất. Với một lớp  $c$  bất kỳ, điểm biểu quyết  $P_{voting}(c)$  được xác định theo công thức:

$$P_{voting}(c) = \sum_{i=1}^n (p_i^{(c)} > p_i^{(k)}, \forall k \neq c) \quad (2)$$

Fuzzy Voting [20] là một phương pháp tổng hợp mô hình dựa trên logic mờ. Thay vì coi các mô hình là độc lập như trong Hard Voting hoặc Soft Voting, Fuzzy Voting sử dụng fuzzy measure để mô tả mức độ đóng góp của từng mô hình, cũng như các tổ hợp mô hình, vào quyết định phân loại cuối cùng.

Trong nghiên cứu này, chúng tôi áp dụng Fuzzy Sugeno Integral [20][21] – một kỹ thuật tích phân mờ có khả năng tổng hợp các giá trị đầu ra từ nhiều mô hình. Cụ thể, Sugeno Integral sử dụng một độ đo mờ (fuzzy measure), nhằm thể hiện mức độ ảnh hưởng của từng con mô hình trong

quá trình tổng hợp để đưa ra dự đoán cuối cùng thay vì giả định tất cả có đóng góp như nhau. Giả sử tập hợp các mô hình là  $X = \{x_1, x_2, \dots, x_n\}$ , trong đó mỗi mô hình  $x_i$  đưa ra một giá trị dự đoán  $p(x_i) \in [0, 1]$ , độ đo mờ  $\mu$  thỏa mãn:

$$\mu(X) = \sum_{x_i \in A} \mu(x_i) \quad (3)$$

Sau đó,  $P_{voting}(c)$  được xác định theo công thức Fuzzy Sugeno Integral như sau:

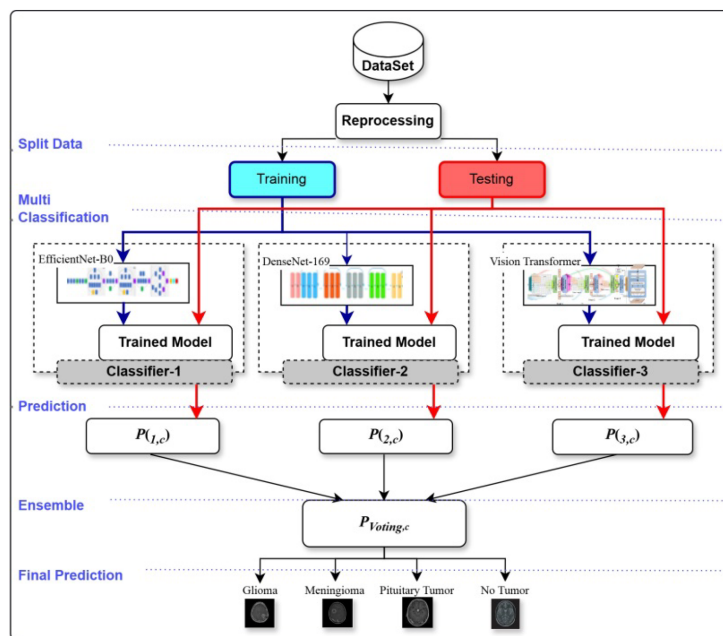
$$P_{Voting}(c) = \max \left[ \min \left( P(x_{\sigma(i)}), \sum_{j=i}^n \mu(x_{\sigma(j)}) \right) \right] \quad (4)$$

Tại đây,  $\sigma$  là một hoán vị của các chỉ số sao cho:  $p(x_{\sigma(1)}) \leq p(x_{\sigma(2)}) \leq \dots \leq p(x_{\sigma(n)})$ , và các giá trị phép đo mờ tương ứng  $\mu_{(x_{\sigma(j)})}$  được sắp xếp theo đó

### 3. PHƯƠNG PHÁP ĐỀ XUẤT

Hình 2 minh họa quy trình phân loại khối u não đề xuất, kết hợp học sâu và phương pháp tổng hợp Fuzzy Sugeno Integral (FSI). Quy trình gồm các giai đoạn: tiền xử lý dữ liệu, trích xuất đặc trưng và

huấn luyện mô hình, học kết hợp, và dự đoán phân loại. Đầu tiên, dữ liệu MRI được chuẩn hóa để đồng nhất kích thước, định dạng và chất lượng, rồi chia thành tập huấn luyện và kiểm thử. Ba mô hình transfer learning: EfficientNet-B0, DenseNet-169, ResNet-101 được huấn luyện riêng biệt để trích xuất đặc trưng và dự đoán bốn lớp: Glioma, Meningioma, Pituitary Tumor, No Tumor. Thay vì chọn lớp có giá trị cao nhất, tất cả dự đoán từ các mô hình được giữ lại để tổng hợp. Cụ thể, với một mẫu ảnh và một lớp  $c$ , đầu ra xác suất dự đoán từ ba mô hình lần lượt là:  $P_{(1,c)}$ ;  $P_{(2,c)}$ ;  $P_{(3,c)}$ . Đồng thời, mỗi mô hình cũng được gán một trọng số  $\mu(1)$ ;  $\mu(2)$ ;  $\mu(3)$ , các giá trị này được sử dụng làm đầu vào FSI. Quá trình tổng hợp giúp tính toán lại xác suất dự đoán  $P_{voting}(c)$  theo công thức (4) từng lớp  $c$  và chọn lớp có xác suất dự đoán cao nhất để đưa ra quyết định cuối cùng. Trong nghiên cứu này các giá trị  $\mu(1)$ ;  $\mu(2)$ ;  $\mu(3)$  được lựa chọn trong quá trình thực nghiệm. Chúng tôi thực nghiệm nhiều tổ hợp khác nhau của bộ  $\mu$ .



Hình 2. Mô hình tổng quát cho phương pháp đề xuất.

## 4. THỰC NGHIỆM VÀ ĐÁNH GIÁ

### 4.1. Tập dữ liệu

Nghiên cứu này sử dụng tập dữ liệu phân loại u não từ ảnh MRI BrTC2020 [7] [8], bao gồm 3.264 ảnh MRI não được chia thành bốn lớp: u thần kinh đệm (glioma), u màng não (meningioma), u tuyến yên

(pituitary tumor) và không có khối u. Tập dữ liệu được gán nhãn thủ công và chia theo tỷ lệ: 70% để huấn luyện, 15% để xác thực, và 15% để kiểm tra. Bảng 1 trình bày phân bố số lượng mẫu theo từng lớp được sử dụng trong quá trình xây dựng và đánh giá mô hình.

Bảng 1. Bảng thống kê số lượng ảnh MRI trong hai tập dữ liệu thực nghiệm

Dataset	Class	Training	Validation	Testing
BrTC2020	Glioma	648	138	140
	No Tumor	277	59	60
	Meningioma	655	140	142
	Pituitary	630	135	136

### 4.2. Các kịch bản huấn luyện áp dụng

Nghiên cứu này được triển khai với sáu kịch bản, bao gồm ba mô hình huấn luyện và ba phương pháp học tổng hợp. Bảng 2 tóm tắt cấu hình của từng kịch bản. Trong đó, Kịch bản 1 đến 3 là các mô hình được huấn luyện độc lập với cùng một

tham số huấn luyện. Kịch bản 4 đến 6 áp dụng lần lượt ba phương pháp tổng hợp: Soft Voting, Hard Voting và Fuzzy Voting, được thực hiện trong giai đoạn kiểm thử. Tất cả các mô hình đều thực hiện phân loại 4 lớp: Glioma, meningioma, Pituitary và No Tumor.

Bảng 2. Các kịch bản và tham số huấn luyện

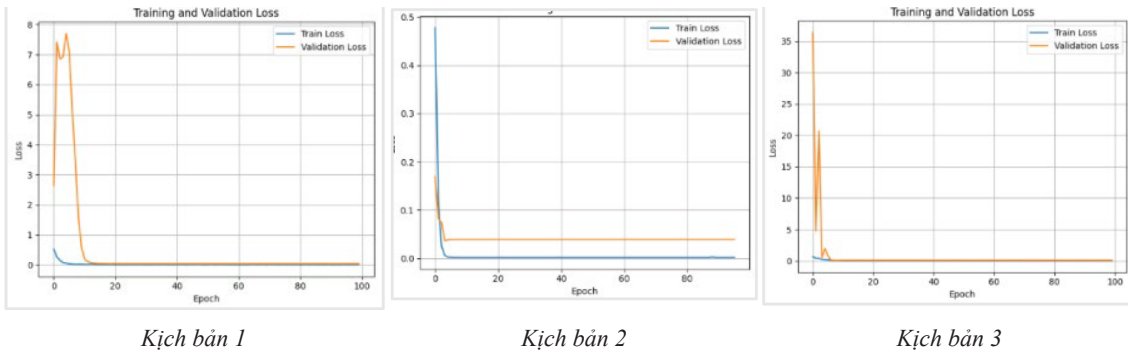
Kịch bản	Mô hình	Batch Size	Num Classes	Learning Rate	Epochs
1	EfficientNet-B0	32	4	1e-4	100
2	Vision Transformer	32	4	1e-4	100
3	DenseNet-169	32	4	1e-4	100
4	Soft-EDTrans	–	4	–	–
5	Hard-EDTrans	–	4	–	–
6	Fuzzy-EDTrans	–	4	–	–

### 4.3. Kết quả huấn luyện

*Độ đo Loss của các kịch bản huấn luyện*


Hình 3 trình bày đồ thị loss huấn luyện và loss validation của ba kịch bản. Kịch bản 2 hội tụ nhanh và ổn định nhất, với loss xác thực dừng lại ở mức 0,0391. Kịch bản

1 cũng cho thấy hiệu suất ổn định với loss validation cuối cùng đạt 0,0386. Trong khi đó, Kịch bản 3 ghi nhận loss validation cao hơn, ở mức 0,0989, cho thấy khả năng khái quát hóa kém hơn. Nhìn chung, Kịch bản 1 và 2 thể hiện khả năng hội tụ tốt hơn so với Kịch bản 3.



**Hình 3. Biểu đồ Loss của các kịch bản**

*Độ đo Accuracy của các kịch bản huấn luyện*




**Hình 4. Biểu đồ Accuracy của các kịch bản**

Hình 4 biểu đồ thể hiện độ đo Accuracy trên tập huấn luyện và validation. Kịch bản 1 và 2 cho thấy hiệu suất cao và ổn định, với độ chính xác validation đạt khoảng 0,9873. Đáng chú ý, Kịch bản 2 đạt độ chính xác huấn luyện cao nhất là 0,9995. Trong khi đó, Kịch bản 3 mặc dù có độ chính xác huấn luyện cao nhưng chỉ đạt 0,9661 trên tập validation, cho thấy dấu

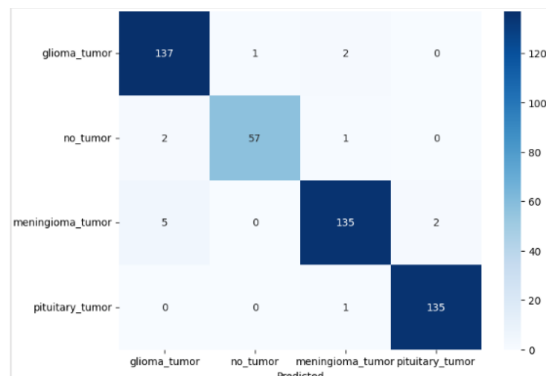
hiệu overfitting.

**4.4. Kết quả kiểm thử**


Để áp dụng phương pháp Fuzzy Voting với tích phân Fuzzy Sugeno, chúng tôi cần xác định  $\mu$  cho từng mô hình. Chúng tôi xác định được  $\mu$  của từng mô hình trên tập dữ liệu là  $[\mu_1=0.7; \mu_2=0.9; \mu_3=0.6]$  do đạt độ chính xác cao nhất thông qua một số lần thử nghiệm.



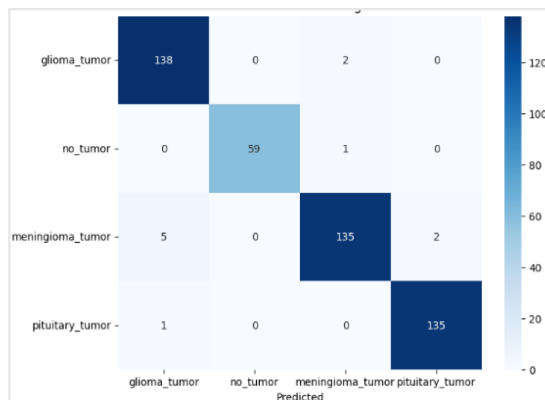
*Kịch bản 1*




*Kịch bản 2*




Kịch bản 3



Kịch bản 4



Kịch bản 5



Kịch bản 6 (Fuzzy-EDTrans)

Hình 5. Ma trận nhầm lẫn của các kịch bản

Hình 5 trình bày ma trận nhầm lẫn của tất cả các kịch bản. Kịch bản 1 xảy ra một số nhầm lẫn khi phân loại các trường hợp glioma thành meningioma, trong khi Kịch bản 2 đã giảm thiểu lỗi này nhưng xuất hiện nhầm lẫn nhẹ với lớp không có khối u. Kịch bản 3 ghi nhận tỷ lệ nhầm lẫn cao nhất, đặc biệt giữa glioma và meningioma. Các kịch bản tổng hợp trong Kịch bản 4 đến 6 đã cải thiện rõ rệt khả năng phân biệt giữa các lớp. Kịch bản 4 giảm lỗi ở tất cả các lớp, Kịch bản 5 tiếp tục giảm thiểu sự nhầm lẫn, và Kịch bản 6 đạt được sự phân bố cân bằng nhất, bao gồm phân loại chính xác tuyệt đối đối với lớp không có khối u. Những kết quả này cho thấy hiệu quả của

học tập tổng hợp, trong đó Kịch bản 6 sử dụng phương pháp Fuzzy Voting đạt độ chính xác và ổn định nhất.

Bảng 3 tóm tắt kết quả đánh giá của cả sáu kịch bản. Kịch bản 1 và 2 cho thấy hiệu suất tốt trong nhóm các mô hình đơn lẻ, trong khi Kịch bản 3 đạt độ chính xác thấp nhất. Các phương pháp học tập tổng hợp trong Kịch bản 4 đến 6 đạt hiệu suất tổng thể vượt trội hơn, với Kịch bản 6 đạt độ chính xác cao nhất là 0,9791 và điểm F1 cao trên tất cả các lớp. Những kết quả này cho thấy hiệu quả của phương pháp kết hợp Fuzzy Voting trong việc nâng cao tính nhất quán và giảm thiểu sai lệch trong phân loại

Bảng 3. Tổng hợp kết quả kiểm thử

Kịch bản	Class	Precision	Recall	F1-score	Accuracy
1	Glioma	0.9571	0.9571	0.9571	0.9749
	No tumor	1.000	1.000	1.000	
	Meningioma	0.9580	0.9647	0.9614	
	Pituitary	1.000	0.992	0.9963	
2	Glioma	0.9432	0.9500	0.9466	0.9707
	No tumor	1.000	0.9666	0.9830	
	Meningioma	0.9366	0.9366	0.9366	
	Pituitary	0.9854	0.9926	0.9890	
3	Glioma	0.9770	0.9142	0.9446	0.9603
	No tumor	0.9833	0.9833	0.9833	
	Meningioma	0.9183	0.9507	0.9342	
	Pituitary	0.9642	0.9926	0.9782	
4	Glioma	0.9643	0.9643	0.9643	0.9749
	No tumor	1.000	1.000	1.000	
	Meningioma	0.9650	0.9718	0.9684	
	Pituitary	1.000	0.9926	0.9963	
5	Glioma	0.9571	0.9571	0.9571	0.9770
	No tumor	1.000	1.000	1.000	
	Meningioma	0.9580	0.9647	0.9614	
	Pituitary	1.000	0.992	0.9963	
6 <i>Fuzzy-EDTrans</i>	Glioma	0.9432	0.9500	0.9466	<b>0.9791</b>
	No tumor	1.000	0.9666	0.9830	
	Meningioma	0.9366	0.9366	0.9366	
	Pituitary	0.9854	0.9926	0.9890	

#### 4.5. So sánh và thảo luận

Bảng 4 trình bày so sánh độ chính xác phân loại giữa phương pháp đề xuất và một số phương pháp học sâu gần đây trong bài toán phân loại khối u não, sử dụng cùng tập

dữ liệu MRI BrTC2020 (gồm 3.264 ảnh). Phương pháp đề xuất Fuzzy-EDTrans đạt độ chính xác ấn tượng 97,91%, cho thấy tính cạnh tranh cao so với các phương pháp hiện có.

Bảng 4. So sánh các phương pháp phân loại khối u não

Author	Phương pháp-Mô hình	Class	Dataset	Accuracy (%)
Sameh Samir [6]	EfficientNet pre-trained	4	3264 ảnh	97.98
Medina & Sánchez [7]	EfficientNet Fine-tuned	4	3264 ảnh	97.75
Preeti Sharma, Anand Shukla [8]	EfficientNet-B0 & B7	3	3000 ảnh	98.0
Phương pháp đề xuất	<b>Fuzzy-EDTrans</b>	<b>4</b>	3264 ảnh	<b>97.91</b>

## 5. KẾT LUẬN

Bài báo đề xuất Fuzzy-EDTrans – một phương pháp học sâu tổng hợp mở cho bài toán phân loại khối u não từ ảnh MRI. Điểm nổi bật của phương pháp nằm ở việc tích hợp ba kiến trúc mạng tiên tiến gồm EfficientNet-B0, DenseNet-169 và Vision Transformer thông qua Fuzzy Sugeno Integral, cho phép tận dụng hiệu quả điểm mạnh của từng mô hình để tăng cường khả năng phân loại. Khác với các phương pháp đơn mô hình truyền thống, Fuzzy-EDTrans không chỉ cải thiện độ chính xác mà còn nâng cao tính ổn định trong các tình huống

dữ liệu phức tạp. Kết quả thực nghiệm trên tập dữ liệu cho thấy phương pháp đạt độ chính xác 97,91%, cao hơn với phần lớn các mô hình riêng lẻ và các kỹ thuật ensemble hiện tại. Từ đó chứng minh hiệu quả của việc tích hợp mô hình đa kiến trúc trong bài toán phân loại ảnh y tế và mở ra hướng ứng dụng thực tiễn trong hệ thống hỗ trợ chẩn đoán thông minh. Trong tương lai, nghiên cứu sẽ mở rộng sang các tập dữ liệu đa mô thức và tích hợp các phương pháp AI có khả năng giải thích nhằm tăng cường khả năng hỗ trợ chuyên gia y tế trong thực hành lâm sàng.

## TÀI LIỆU THAM KHẢO

- [1]. Charity, *Brain Tumour Statistics*, United Kingdom, Jun. 2023.
- [2]. International Agency for Research on Cancer, *Viet Nam Cancer Fact Sheet*, 2022.
- [3]. M. C. Center, “Brain Tumor Diagnosis - MRI,” 2024. [Online]. Available: <https://www.moffitt.org/cancers/brain-tumor/diagnosis/mri/>. [Accessed: Aug. 30, 2025].
- [4]. J. Cheng, W. Huang, S. Cao, R. Yang, W. Yang, Z. Yun, Z. Wang, and Q. Feng, “Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition,” *PLOS ONE*, vol. 10, no. 10, p. e0140381, Oct. 2015, doi: 10.1371/journal.pone.0140381.
- [5]. V. R. Sajja and H. K. Kalluri, “Classification of Brain Tumors using Fuzzy C-means and VGG16,” *Turkish Journal of Computer and Mathematics Education*, vol. 12, no. 9, pp. 2103–2113, Apr. 2021.
- [6]. S. Samir, “EfficientNet Algorithm for Classification of Different Types of Cancer,” *arXiv preprint*, arXiv:2304.08715, Apr. 2023.
- [7]. J. M. Medina and J. Sánchez, “High Accuracy Brain Tumor Classification with EfficientNet and Magnetic Resonance Images,” in *Proc. 5th Int. Conf. Advances in Signal Processing and Artificial Intelligence (ASPAI)*, Tenerife, Spain, Jun. 2023, pp. 1–6.
- [8]. P. Sharma and A. P. Shukla, “Transfer Learning Approach Using EfficientNet

- Architecture for Brain Tumor Classification in MRI Images,” *Advances and Applications in Mathematical Sciences*, vol. 21, no. 12, pp. 7091–7106, Oct. 2022.
- [9]. M. F. Alanazi, M. U. Ali, S. J. Hussain, A. Zafar, M. Mohtaram, M. Irfan, R. Alruwaili, M. Alruwaili, N. H. Ali, and A. M. Albarrak, “Brain Tumor/Mass Classification Framework Using Magnetic-Resonance-Imaging-Based Isolated and Developed Transfer Deep-Learning Model,” *Sensors*, vol. 22, no. 1, p. 372, Jan. 2022, doi: 10.3390/s22010372.
- [10]. W. Chen, “A Robust Approach for Multi-Type Classification of Brain Tumor Using Deep Feature Fusion,” *Frontiers in Neuroscience*, vol. 18, p. 142, 2024, doi: 10.3389/fnins.2024.00142.
- [11]. J. Kang, Z. Ullah, and J. Gwak, “MRI-Based Brain Tumor Classification Using Ensemble of Deep Features and Machine Learning Classifiers,” *Sensors*, vol. 21, no. 6, p. 222, Mar. 2021, doi: 10.3390/s21062222.
- [12]. Brain Tumour Research, “Brain Tumor Symptoms,” May 31, 2024. [Online]. Available: <https://virtualtrials.org/symptoms.pdf>. [Accessed: Aug. 30, 2025].
- [13]. Brain Tumour Research, “Brain Tumour Research,” May 31, 2024. [Online]. Available: <https://braintumourresearch.org/pages/information-brain-tumour-symptoms>. [Accessed: Aug. 30, 2025].
- [14]. S. J. Pan and Q. Yang, “A Survey on Transfer Learning,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 10, pp. 1345–1359, Oct. 2010, doi: 10.1109/TKDE.2009.191.
- [15]. M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” in *Proc. 36th Int. Conf. Machine Learning (ICML)*, Long Beach, CA, USA, 2019, pp. 6105–6114.
- [16]. A. Dosovitskiy *et al.*, “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” in *Proc. Int. Conf. Learning Representations (ICLR)*, 2021. [Online]. Available: <https://arxiv.org/abs/2010.11929>. [Accessed: Aug. 30, 2025].
- [17]. G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 2017, pp. 2261–2269.
- [18]. T. G. Dietterich, “Ensemble Methods in Machine Learning,” in *Multiple Classifier Systems*, J. Kittler and F. Roli, Eds. Berlin, Heidelberg: Springer, 2000, pp. 1–15, doi: 10.1007/3-540-45014-9\_1.
- [19]. L. Rokach, “Ensemble-based classifiers,” *Artificial Intelligence Review*, vol. 33, no. 1, pp. 1–39, Feb. 2010, doi: 10.1007/s10462-009-9124-7.
- [20]. M. Sugeno, “Fuzzy Measures and Fuzzy Integrals—A Survey,” *Fuzzy Measures and Integrals*, Elsevier, 1993, pp. 251–257.
- [21]. R. Kundu, H. Basak, A. Kollala, S. Chattopadhyay, O. Chakraborty, and N. Das, “Ensemble of CNN Classifiers Using Sugeno Fuzzy Integral Technique for Cervical Cytology Image Classification,” in *Proc. Int. Conf. Artificial Intelligence in Medicine (AIME)*, 2021, pp. 134–145.