PHÂN ĐOẠN HÌNH ẢNH MRI NÃO SỬ DỤNG MẠNG KAN-UNET

Nguyễn Quốc Uy
Học viện Công nghệ Bưu chính Viễn thông, Việt Nam

***Tóm tắt*—Phân đoạn u não từ ảnh MRI là bước quan trọng trong chẩn đoán và điều trị ung thư não. Nghiên cứu này giới thiệu KAN-Unet, mô hình cải tiến từ U-Net với lý thuyết Kolmogorov-Arnold (KAN), nhằm nâng cao hiệu suất phân đoạn u não. Huấn luyện trên tập dữ liệu BraTS2020, KAN-Unet đạt độ chính xác cao với Accuracy 99.29% và F1-Score 99.24%, chứng minh khả năng phân vùng u hiệu quả ngay cả trong trường hợp phức tạp, mở ra tiềm năng ứng dụng trong chẩn đoán hình ảnh y tế.**

***Từ khóa*—KAN-Unet, phân đoạn u não, cộng hưởng từ MRI, phân đoạn hình ảnh y tế, trí tuệ nhân tạo.**

I. GIỚI THIỆU

U não là một trong những loại ung thư nguy hiểm, ảnh hưởng đến nhiều bệnh nhân trên toàn thế giới, đặc biệt là ở trẻ em và người lớn trẻ tuổi. Theo các thống kê gần đây, u não nằm trong top 10 nguyên nhân hàng đầu gây tử vong do ung thư (Jemal et al., 2011 [1]). Việc chẩn đoán và phân đoạn u não chính xác là yếu tố quyết định trong việc lập kế hoạch điều trị và nâng cao tỷ lệ sống sót của bệnh nhân. Hình ảnh cộng hưởng từ (MRI) được xem là phương pháp hiệu quả và không xâm lấn để phát hiện các khối u và theo dõi sự phát triển của chúng trong não (Bauer et al., 2013 [2]). Tuy nhiên, việc phân đoạn khối u từ ảnh MRI một cách chính xác là một nhiệm vụ đầy thách thức do sự đa dạng về kích thước, hình dạng và vị trí của các khối u giữa các bệnh nhân.

Hiện nay, các hệ thống phân đoạn dựa trên trí tuệ nhân tạo và học sâu đang ngày càng trở nên phổ biến nhằm tự động hóa và cải thiện độ chính xác trong việc phân đoạn u não. Mặc dù những mô hình như U-Net (Mạng nơ-ron tích chập có cấu trúc hình chữ U) đã mang lại những kết quả ấn tượng trong lĩnh vực phân đoạn ảnh y tế, nhưng chúng vẫn gặp khó khăn khi đối mặt với các mẫu dữ liệu phức tạp và phi tuyến tính. Để khắc phục những hạn chế này, nghiên cứu của chúng tôi đề xuất mô hình KAN-Unet, một kiến trúc học sâu kết hợp giữa U-Net và lớp tích chập FastKANConvLayer dựa trên lý thuyết Kolmogorov-Arnold (KAN). Sự kết hợp này giúp mô hình không chỉ trích xuất được các đặc trưng từ ảnh MRI một cách hiệu quả mà còn xử lý tốt các mối quan hệ phi tuyến phức tạp giữa các vùng trong khối u.

Mục tiêu của nghiên cứu là cải thiện độ chính xác trong phân đoạn các loại u não khác nhau trên ảnh MRI, bao gồm khối u tăng cường (Enhancing Tumor - ET), lõi u (Tumor Core - TC), và toàn bộ khối u (Whole Tumor - WT). Mô hình KAN-Unet đã được thử nghiệm trên tập dữ liệu BraTS2020 [3] và chứng minh tính hiệu quả vượt trội so với các mô hình phân đoạn u não hiện có.

II. CÔNG VIỆC LIÊN QUAN

Nghiên cứu của Nodirov et al., 2022 [4] sử dụng mô hình 3D U-Net kết hợp MobileNetV2 và các mô-đun chú ý trên tập dữ liệu BraTS2020. Mô hình này giúp cải thiện tốc độ và độ chính xác trong việc phân đoạn u não. Kết quả đạt được điểm Dice 88.54%, thể hiện hiệu quả tốt trong suy luận nhanh và chính xác. Rehman et al., 2020 [5] sử dụng mô hình BU-Net với các mô-đun Residual (RES) và Weight Channel (WC) trên tập dữ liệu BraTS2017, BraTS2018. Các mô-đun này giúp tối ưu hóa khả năng học và trích xuất đặc trưng, cải thiện hiệu suất phân đoạn. Điểm Dice đạt từ 83.70% đến 90.10%, cho thấy mô hình hoạt động tốt nhưng vẫn có tiềm năng cải thiện. Nghiên cứu của Zhang et al., 2021 [6] giới thiệu mô hình ME-net với kiến trúc Multi-encoder trên tập dữ liệu BraTS2020. Mỗi phương thức MRI được xử lý riêng biệt, giúp tăng cường độ chính xác phân đoạn các vùng u não khác nhau. Điểm Dice của nghiên cứu đạt từ 70% đến 88%, cho thấy sự vượt trội trong việc xử lý các chi tiết nhỏ. Jiang et al., 2022 [7] sử dụng mô hình SwinBTS, kết hợp Swin Transformer

Tác giả liên hệ: Nguyễn Quốc Uy,
Email: uynq@ptit.edu.vn
Đến tòa soạn: 22/8/2024, chỉnh sửa: 24/9/2024, chấp nhận đăng: 12/10/2024.

Bảng I
CÁC PHƯƠNG PHÁP PHÂN ĐOẠN U NÃO GẦN ĐÂY

Bài báo	Tập dữ liệu	Mô hình	Phương pháp	Accuracy	F1-Score	Dice	IoU
Nodirov et al., 2022	BraTS2020	3D U-Net + MobileNetV2	3D U-Net với MobileNetV2 và các mô-đun chú ý để suy luận nhanh và chính xác hơn	90,87%	89,74%	89,74%	80,97%
Rehman et al., 2020	BraTS2017, BraTS2018	BU-Net	Các mô-đun RES và WC để cải thiện khả năng trích xuất đặc trưng	90,87%	90,10%	90,10%	82,18%
Zhang et al., 2021	BraTS2020	ME-net	Mạng multi-encoder, mỗi phương thức MRI được xử lý riêng lẻ, kết hợp qua các kết nối bỏ qua, sử dụng hàm mất Dice phân loại	99%	88,30%	88,30%	79,13%
Jiang et al., 2022	BraTS2019, BraTS2020, BraTS2021	SwinBTS	Swin Transformer kết hợp với CNN	99%	91,83%	91,83%	85,30%
Guan et al., 2022	BraTS2020	AGSE-VNet	Tích hợp mô-đun SE và AG vào mô hình VNet	99%	85,00%	85,00%	74,00%

và CNN, trên tập dữ liệu BraTS2019, BraTS2020, BraTS2021. Việc kết hợp hai phương pháp này giúp tăng cường khả năng nhận diện đặc trưng không gian. Mô hình đạt điểm Dice 89.06%, cao nhất trong các nghiên cứu, cho thấy tiềm năng mạnh mẽ của Swin Transformer. Cuối cùng, Guan et al., 2022 [8] áp dụng mô hình AGSE-VNet trên tập dữ liệu BraTS 2020, kết hợp các mô-đun Squeeze and Excite (SE) và Attention Guide Filter (AG). Các mô-đun này cải thiện khả năng tập trung vào các vùng quan trọng trong ảnh MRI. Kết quả cho thấy điểm Dice từ 70% đến 85%, cho thấy sự cải thiện trong phân đoạn các vùng u não khó khăn.

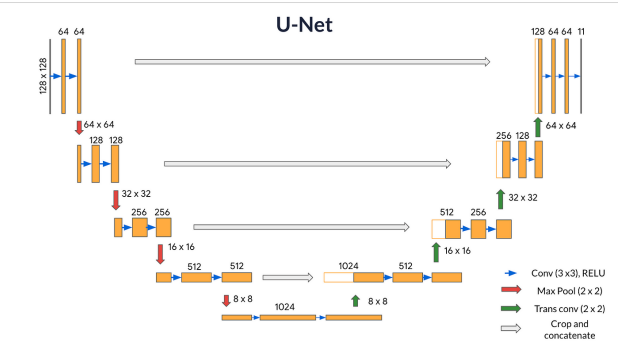
Các nghiên cứu trong Bảng 1 đều cho thấy xu hướng phát triển của các phương pháp phân đoạn u não từ việc sử dụng các mô hình truyền thống như BU-Net đến các mô hình tiên tiến hơn như ME-net và SwinBTS, với điểm số Dice ngày càng được cải thiện.

III. PHƯƠNG PHÁP

A. Mạng U-net

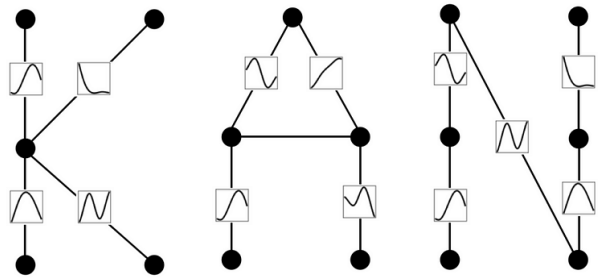
U-Net [9] là một kiến trúc mạng nơ-ron tích chập (CNN) được thiết kế đặc biệt cho các tác vụ phân đoạn ảnh, ban đầu được giới thiệu cho phân đoạn ảnh y khoa. U-Net có cấu trúc dạng "U" với hai thành phần chính: contraction path (con đường thu hẹp) và expansion path (con đường mở rộng).

- Contraction path: Phần này gồm các lớp tích chập và pooling, giúp trích xuất đặc trưng quan trọng và nắm bắt thông tin toàn cục bằng cách giảm độ phân giải nhưng tăng độ sâu của ảnh.
- Expansion path: Sử dụng các lớp upsampling để khôi phục độ phân giải ban đầu và kết nối các đặc trưng từ contraction path, giúp mô hình giữ lại thông tin toàn cục lẫn chi tiết cần cho phân đoạn chính xác.



Hình 1. Kiến trúc mạng UNET

B. Mạng Kolmogorov-Arnold



Hình 2. Kiến trúc mạng KAN

Mạng Kolmogorov-Arnold (KAN) [10] là một giải pháp thay thế mới cho mạng nơ-ron truyền thống Multi-Layer Perceptron (MLP) [11], dựa trên định lý biểu diễn Kolmogorov-Arnold. Trong khi MLP

sử dụng các hàm kích hoạt cố định trên các nút (neuron), KAN đặt các hàm kích hoạt có thể học được trên các cạnh (trọng số), dưới dạng các hàm đơn biến được tham số hóa bằng spline. Sự thay đổi này giúp KAN cải thiện cả độ chính xác và khả năng giải thích, đặc biệt là trong các bài toán AI và khoa học phức tạp, trong đó bất kỳ hàm liên tục nhiều biến nào $f(x_1, x_2, \ldots, x_n)$ đều có thể được biểu diễn dưới dạng tổng của các hàm đơn biến như công thức (1):

$$f(x_1, x_2, \ldots, x_n) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_{p=1}^{n} \phi_{q,p}(x_p) \right) \quad (1)$$

Thay vì sử dụng các hàm kích hoạt cố định trên các nút như MLP:

$$MLP(x) = (W_3 \circ \sigma_2 \circ W_2 \circ \sigma_1 \circ W_1)(x) \quad (2)$$

Công thức (2) biểu diễn mạng MLP với đầu vào x, qua các trọng số W_1, W_2, W_3 và các hàm kích hoạt σ_1, σ_2 theo thứ tự. Mỗi lớp thực hiện biến đổi tuyến tính và phi tuyến để học đặc trưng.

KAN sử dụng các hàm kích hoạt có thể học được trên các cạnh:

$$KAN(x) = (\Phi_3 \circ \Phi_2 \circ \Phi_1)(x) \quad (3)$$

Hàm spline trong KAN được định nghĩa như sau:

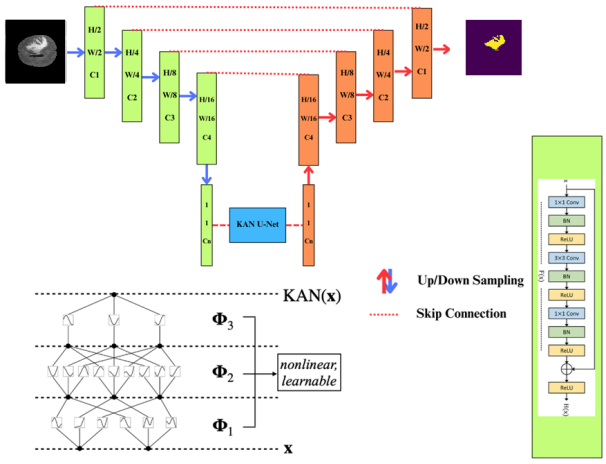
$$spline(x) = \sum_i c_i B_i(x) \quad (4)$$

với $B_i(x)$ là các hàm cơ sở spline và c_i là các hệ số có thể học được. Kiến trúc này cho phép KAN vượt trội hơn MLP về độ chính xác và khả năng giải thích, đặc biệt trong các bài toán yêu cầu học cấu trúc tổng hợp và tối ưu các hàm đơn biến.

KANs có khả năng ứng dụng mạnh mẽ trong các vấn đề khoa học quy mô nhỏ, như giải các phương trình vi phân (PDE), toán học ký hiệu, và bài toán xấp xỉ hàm số, nơi mà hiệu năng của chúng mở rộng hiệu quả hơn so với MLP truyền thống.

C. Mô hình đề xuất - Mạng KAN-Unet

Mạng KAN-Unet là một biến thể của kiến trúc U-Net, được sử dụng cho các nhiệm vụ phân đoạn ảnh. Mô hình này áp dụng cấu trúc mã hóa-giải mã với các kết nối bỏ qua giữa các tầng tương ứng trong



Hình 3. Kiến trúc mạng KAN-Unet

phần mã hóa và giải mã, giúp cải thiện khả năng học và phân đoạn các chi tiết không gian trong ảnh.

Phần mã hóa bao gồm một lớp DoubleConv1, tiếp theo là bốn module Down. Mỗi module Down thực hiện giảm độ phân giải của bản đồ đặc trưng thông qua phép pooling, sau đó áp dụng hai lớp chập liên tiếp.

$$X' = \text{Conv}(X) \quad (5)$$

Mỗi tầng mã hóa thực hiện phép chập $\text{Conv}(X)$ để trích xuất các đặc trưng từ dữ liệu đầu vào với chiều cao H, chiều rộng W, và số kênh C.

Phần giải mã của KAN-Unet gồm bốn module Up, tăng dần độ phân giải bản đồ đặc trưng thông qua nội suy song tuyến hoặc chập chuyển vị. Các bản đồ này được ghép nối với bản đồ từ phần mã hóa qua các kết nối bỏ qua (skip connections), giúp duy trì thông tin không gian và chi tiết quan trọng của ảnh, từ đó cải thiện độ chính xác trong phân đoạn.

$$X_{\text{up}} = \text{UpConv}(X_{\text{down}}) \quad (6)$$

Phần giải mã tăng kích thước bản đồ đặc trưng X_{down} thông qua phép nội suy hoặc chập chuyển vị.

$$X_{\text{final}} = \text{Concat}(X_{\text{up}}, X_{\text{skip}}) \quad (7)$$

Tại mỗi bước, bản đồ đặc trưng của mã hóa và giải mã được ghép nối qua các kết nối bỏ qua, giúp giữ lại thông tin quan trọng.

Đầu ra của mạng được tạo qua lớp OutConv, mỗi pixel biểu thị xác suất thuộc về một lớp trong

ảnh phân đoạn. DoubleConv gồm hai lớp chập kèm Batch Normalization và ReLU, giúp ổn định và tăng cường học đặc trưng. Down Module giảm kích thước không gian của bản đồ đặc trưng, trong khi Up Module tăng kích thước và kết nối các chi tiết từ các tầng trước để cải thiện phân đoạn.

$$Y_{\text{output}} = \text{OutConv}(X_{\text{final}}) \tag{8}$$

Sau các bước giải mã, bản đồ phân đoạn cuối cùng Y_{output} được tạo ra qua lớp chập cuối cùng, đại diện cho xác suất của từng lớp phân đoạn.

D. Chỉ số đánh giá

1) Chỉ số Dice: **Dice** (Dice Similarity Coefficient, DSC) [12] là một chỉ số đo lường dùng để đánh giá mô hình phân đoạn ảnh, đo độ tương đồng giữa tập dự đoán và tập thực tế. Điểm **Dice** dao động từ 0 (không khớp) đến 1 (hoàn hảo).

Công thức **Dice**:

$$\text{Dice} = \frac{2|A \cap B|}{|A| + |B|} \tag{9}$$

Trong đó: A - Tập pixel dự đoán (predicted), B - Tập pixel thực tế (ground truth), $A \cap B$ - Số pixel chung giữa dự đoán và thực tế.

2) Chỉ số F1-Score: **F1-Score** là [13] chỉ số đo lường dùng để đánh giá mô hình phân loại, dựa trên *Precision* và *Recall*. **F1-Score** đạt giá trị cao khi Precision và Recall đều cao.

Công thức **F1-Score**:

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \tag{10}$$

Trong đó: Precision - Tỷ lệ dự đoán đúng trong các mẫu dương, Recall - Tỷ lệ dự đoán đúng trên tổng số mẫu dương thực tế.

3) Chỉ số IoU: **Intersection over Union (IoU)** [14] là chỉ số đo lường mức độ chồng lấp giữa vùng dự đoán và vùng thực tế, phổ biến trong phân đoạn ảnh và phát hiện đối tượng. IoU được tính bằng:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \tag{11}$$

Trong đó: A - Vùng dự đoán, B - Vùng thực tế, $A \cap B$ - Phần giao của hai vùng, $A \cup B$ - Phần hợp của hai vùng.

IV. KẾT QUẢ

A. Dữ liệu

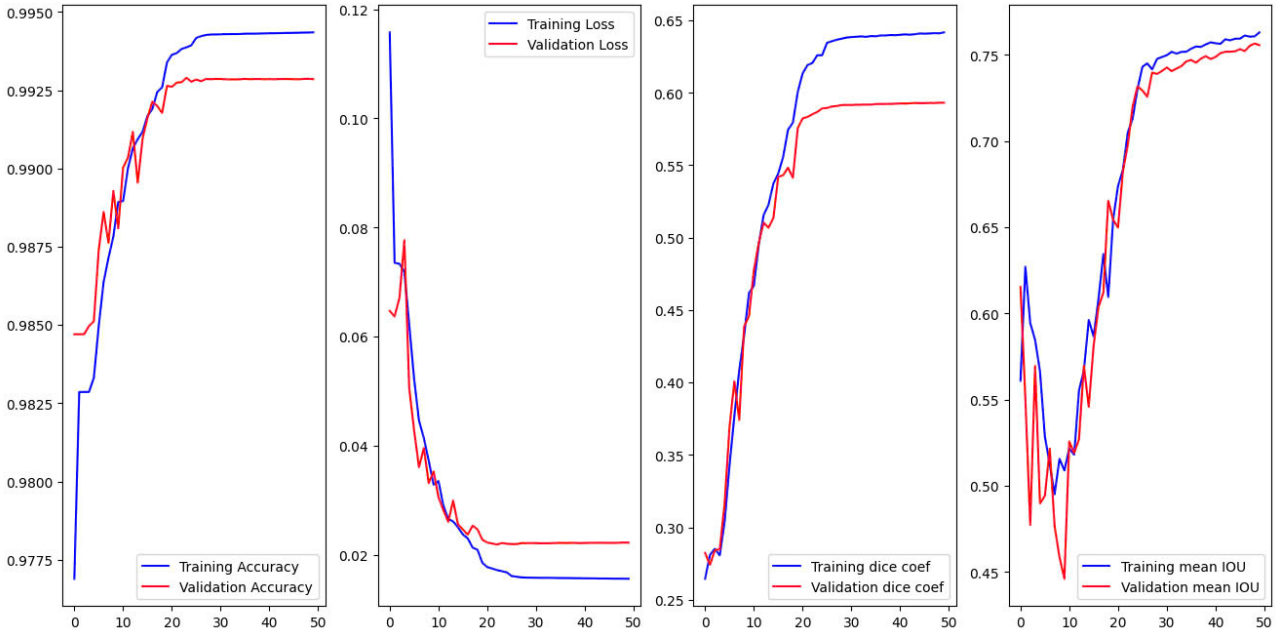
BraTS2020 (Brain Tumor Segmentation 2020) là một tập dữ liệu tiêu chuẩn trong lĩnh vực phân đoạn u não. Tập dữ liệu này được sử dụng rộng rãi trong các nghiên cứu và cuộc thi về phân đoạn ảnh y tế, đặc biệt là MICCAI BraTS Challenge. Mục tiêu chính của BraTS2020 là phân đoạn chính xác các vùng u não trên ảnh MRI, hỗ trợ chẩn đoán và điều trị cho bệnh nhân u não. Loại u chính được tập trung trong tập dữ liệu này là u thần kinh đệm (gliomas), bao gồm cả các u ác tính cao và u ác tính thấp.

Tập dữ liệu BraTS2020 có kích thước lớn, bao gồm hơn 369 trường hợp bệnh nhân với các hình ảnh MRI và các nhãn phân đoạn được chú thích bởi các chuyên gia y tế. Dữ liệu được lưu trữ ở định dạng NIfTI, giúp lưu trữ và quản lý hiệu quả hình ảnh y khoa. Các vùng u não trong dữ liệu đã được chú thích thủ công, tạo thành nhãn phân đoạn chi tiết, phục vụ cho việc huấn luyện và kiểm thử các mô hình trí tuệ nhân tạo.

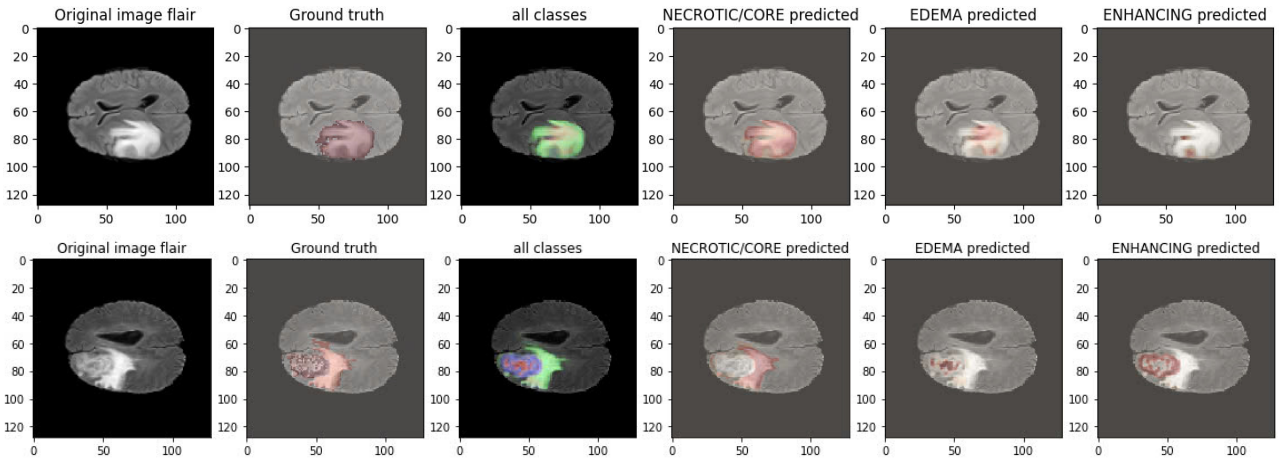
Quy trình tiền xử lý ảnh MRI bao gồm các bước chính nhằm đảm bảo dữ liệu nhất quán và rõ ràng cho mô hình phân đoạn. Đầu tiên, chuẩn hóa cường độ ảnh thường được thực hiện qua chuẩn hóa Z-score, giúp điều chỉnh cường độ về một khoảng chung và giảm sự khác biệt giữa các máy quét MRI. Tiếp theo, cân bằng độ sáng và tăng cường độ tương phản giúp làm nổi bật cấu trúc trong ảnh, tăng sự khác biệt giữa vùng u và mô lành, hỗ trợ mô hình nhận diện rõ hơn các khu vực cần phân đoạn. Ảnh MRI sau đó được cắt lát và điều chỉnh kích thước để tạo ra dữ liệu đồng nhất với độ phân giải cố định, giúp mạng nơ-ron xử lý hiệu quả hơn. Để làm rõ biên vùng u, loại bỏ nhiễu bằng kỹ thuật như Gaussian Blur giúp giảm nhiễu và tăng độ chính xác khi nhận diện. Chuẩn hóa không gian căn chỉnh ảnh về một không gian chuẩn, giảm sai lệch vị trí giải phẫu giữa các ảnh. Cuối cùng, tăng cường dữ liệu qua các kỹ thuật xoay, lật, và co giãn tạo ra nhiều biến thể của ảnh, giúp mô hình học tốt hơn sự đa dạng của dữ liệu và tăng tính tổng quát. Các bước này góp phần cải thiện độ chính xác và độ tin cậy của mô hình phân đoạn trên ảnh MRI.

B. Kết quả quá trình đào tạo và kiểm thử

Trong quá trình huấn luyện mô hình KAN-Unet, card đồ họa GTX 4090 được sử dụng để xử lý các phép tính ma trận phức tạp. Với learning rate 0.0001,



Hình 4. Quá trình đào tạo và kiểm thử của kiến trúc mạng KAN-Unet



Hình 5. Hình ảnh MRI sau khi được phân đoạn

mô hình học từ từ, giúp tránh tình trạng học quá nhanh dẫn đến việc mô hình không thể hội tụ đúng. Mô hình được huấn luyện trên cả tập training và validation để đánh giá khả năng tổng quát hóa của nó.

Trong đồ thị đầu tiên của Hình 4, cả training và validation accuracy đều bắt đầu ở mức 0.9775 và tăng lên trên 0.99 sau 10 epoch, cho thấy mô hình học tốt mà không gặp vấn đề overfitting. Đồ thị thứ hai biểu diễn training và validation loss, bắt đầu ở mức 0.12 và nhanh chóng giảm xuống còn 0.02 và 0.04 sau 10 epoch, cho thấy sự cải thiện rõ rệt. Đồ thị thứ ba minh họa Dice coefficient tăng từ 0.25 lên 0.65, phản ánh khả năng phân vùng của mô hình được cải thiện theo thời gian. Cuối cùng, đồ thị thứ tư thể hiện mean IoU tăng từ 0.45 lên 0.75 sau 10 epoch, khẳng định độ chính xác phân vùng cũng cải thiện rõ rệt.

C. So sánh với các nghiên cứu khác

Từ Bảng II ta thấy Kết quả từ mô hình KAN-Unet cho thấy độ chính xác (Accuracy) đạt mức

Bảng II
SO SÁNH KAN-UNET VỚI CÁC PHƯƠNG PHÁP PHÂN ĐOẠN U NÃO KHÁC

Model	Accuracy	IoU	Dice	F1-Score
Nodirov et al., 2022	90.87%	80.97%	89.74%	89.74%
Rehman et al., 2020	90.87%	82.18%	90.10%	90.10%
Zhang et al., 2021	99%	79.13%	88.30%	88.30%
Jiang et al., 2022	99%	85.30%	91.83%	91.83%
Guan et al., 2022	99%	74.00%	85.00%	85.00%
KAN-Unet	99.29%	81.98%	59.32%	99.24%

99.29%, cao hơn so với mô hình của Nodirov et al., 2022 và Rehman et al., 2020 (đều đạt 90.87%), đồng thời tương đương với các phương pháp hiện đại như Zhang et al., 2021, Jiang et al., 2022, và Guan et al., 2022 (đều đạt 99%). Điều này chứng minh rằng KAN-Unet có khả năng cạnh tranh về độ chính xác trong việc phân đoạn u não, đáp ứng tốt các yêu cầu về dự đoán chính xác cấu trúc u não từ dữ liệu phức tạp. Xét về chỉ số IoU, KAN-Unet đạt 81.98%, cao hơn Nodirov et al., 2022 (80.97%) và Guan et al., 2022 (74.00%), tuy nhiên vẫn thấp hơn Jiang et al., 2022 (85.30%) và Rehman et al., 2020 (82.18%). Điều này cho thấy khả năng mô hình hóa vùng mục tiêu của KAN-Unet khá tốt, nhưng vẫn có thể được cải thiện để đạt mức cao nhất trong phân đoạn khối u. Tuy nhiên, chỉ số Dice của KAN-Unet chỉ đạt 59.32%, thấp hơn đáng kể so với các phương pháp khác như Jiang et al., 2022 (91.83%), Rehman et al., 2020 (90.10%), và Nodirov et al., 2022 (89.74%), điều này cho thấy mô hình cần được tối ưu hóa hơn trong việc phân đoạn chính xác vùng u não. Mặc dù vậy, KAN-Unet lại vượt trội về F1-Score, đạt 99.24%, cao hơn tất cả các phương pháp còn lại, cho thấy mô hình này có sự cân bằng tốt giữa độ chính xác và độ nhạy. KAN-Unet có chỉ số Dice thấp hơn do nhạy cảm với lỗi ranh giới và chưa tối ưu tốt cho các chi tiết nhỏ trong vùng u não. Dù đạt Accuracy và F1-Score cao, mô hình có thể chưa tập trung đủ vào các biên phức tạp. Các mô hình khác thường dùng Dice Loss hoặc Attention Modules để tối ưu Dice, trong khi KAN-Unet có thể dựa trên Cross-Entropy Loss. Để cải thiện, KAN-Unet có thể tích hợp Dice Loss và cơ chế chú ý nhằm tăng khả năng nhận diện ranh giới chính xác hơn. Mô hình này vượt trội về Accuracy, F1-Score, và IoU nhưng cần cải thiện Dice cho phân đoạn u não hiệu quả hơn.

V. KẾT LUẬN

Nghiên cứu này giới thiệu và đánh giá KAN-Unet, một cải tiến của U-Net kết hợp lý thuyết Kolmogorov-Arnold, nhằm nâng cao phân đoạn u não trên ảnh MRI. Kết quả trên dữ liệu BraTS2020 cho thấy KAN-Unet đạt độ chính xác cao, với Accuracy và F1-Score vượt trội so với các phương pháp hiện có. Hướng nghiên cứu tiếp theo sẽ tối ưu chỉ số Dice và mở rộng KAN-Unet sang phân đoạn ảnh y khoa từ siêu âm và CT để kiểm chứng tính hiệu quả và đa dụng.

TÀI LIỆU THAM KHẢO

[1] A. Jemal, F. Bray, M. M. Center, J. Ferlay, E. Ward, and D. Forman, "Global cancer statistics," *CA: a cancer journal for clinicians*, vol. 61, no. 2, pp. 69–90, 2011.

[2] S. Bauer, R. Wiest, L.-P. Nolte, and M. Reyes, "A survey of mri-based medical image analysis for brain tumor studies," *Physics in Medicine & Biology*, vol. 58, no. 13, p. R97, 2013.

[3] T. Henry, A. Carré, M. Lerousseau, T. Estienne, C. Robert, N. Paragios, and E. Deutsch, "Brain tumor segmentation with self-ensembled, deeply-supervised 3d u-net neural networks: a brats 2020 challenge solution," in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop, BrainLes 2020, Held in Conjunction with MICCAI 2020, Lima, Peru, October 4, 2020, Revised Selected Papers, Part I 6*. Springer, 2021, pp. 327–339.

[4] J. Nodirov, A. B. Abdusalomov, and T. K. Whangbo, "Attention 3d u-net with multiple skip connections for segmentation of brain tumor images," *Sensors*, vol. 22, no. 17, p. 6501, 2022.

[5] M. U. Rehman, S. Cho, J. H. Kim, and K. T. Chong, "Bu-net: Brain tumor segmentation using modified u-net architecture," *Electronics*, vol. 9, no. 12, p. 2203, 2020.

[6] W. Zhang, G. Yang, H. Huang, W. Yang, X. Xu, Y. Liu, and X. Lai, "Me-net: multi-encoder net framework for brain tumor segmentation," *International Journal of Imaging Systems and Technology*, vol. 31, no. 4, pp. 1834–1848, 2021.

[7] Y. Jiang, Y. Zhang, X. Lin, J. Dong, T. Cheng, and J. Liang, "Swinbts: A method for 3d multimodal brain tumor segmentation using swin transformer," *Brain sciences*, vol. 12, no. 6, p. 797, 2022.

[8] X. Guan, G. Yang, J. Ye, W. Yang, X. Xu, W. Jiang, and X. Lai, "3d agse-vnet: an automatic brain tumor mri data segmentation framework," *BMC medical imaging*, vol. 22, pp. 1–18, 2022.

[9] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *CoRR*, vol. abs/1505.04597, 2015. [Online]. Available: http://arxiv.org/abs/1505.04597

[10] Z. Liu, Y. Wang, S. Vaidya, F. Ruehle, J. Halverson, M. Soljačić, T. Y. Hou, and M. Tegmark, "Kan: Kolmogorov-arnold networks," *arXiv preprint arXiv:2404.19756*, 2024.

[11] H. Taud and J.-F. Mas, "Multilayer perceptron (mlp)," *Geomatic approaches for modeling land change scenarios*, pp. 451–455, 2018.

[12] K. Zou, S. Warfield, A. Bharatha, C. Tempany, M. Kaus, S. Haker, W. Wells, F. Jolesz, and R. Kikinis, "Statistical validation of image segmentation quality based on a spatial

overlap index," *Academic Radiology*, vol. 11, no. 2, pp. 178–189, Feb 2004.
[13] W. W. Cohen, P. Ravikumar, S. E. Fienberg *et al.*, "A comparison of string distance metrics for name-matching tasks." in *IIWeb*, vol. 3, 2003, pp. 73–78.
[14] S. K. Divvala, D. Hoiem, J. H. Hays, A. A. Efros, and M. Hebert, "An empirical study of context in object detection," in *2009 IEEE Conference on computer vision and Pattern Recognition*. IEEE, 2009, pp. 1271–1278.

BRAIN MRI IMAGE SEGMENTATION USING KAN-UNET

Abstract **- Brain tumor segmentation from MRI images is a crucial step in the diagnosis and treatment of brain cancer. This study introduces KAN-Unet, an improved model based on U-Net and Kolmogorov-Arnold theory (KAN), designed to enhance brain tumor segmentation performance. Trained on the BraTS2020 dataset, KAN-Unet achieved high accuracy, with an Accuracy of 99.29% and an F1-Score of 99.24%, demonstrating adequate tumor delineation even in complex cases, thus highlighting its potential for applications in medical imaging diagnostics.**

Keyword **- KAN-Unet, brain tumor segmentation, MRI, medical image segmentation, artificial intelligence.**



Nguyễn Quốc Uy Tiến sĩ, giảng viên đại học, chuyên ngành tin học- điều khiển hệ thống kĩ thuật.