

APPLICATION OF DEEP LEARNING TO EXTRACT TUMORS REGIONS IN MEDICAL IMAGES

NGHIÊN CỨU KỸ THUẬT HỌC SÂU TRONG TRÍCH XUẤT VÙNG KHỐI U TỪ ẢNH Y TẾ

Võ Hoàng Thành
Trường Đại học Quảng Bình

ABSTRACT: Brain tumor segmentation provides valuable information for surgical planning, treatment planning, and cancer diagnosis. Recently, many researchers have applied computer vision and deep learning techniques to the medical field and achieved great success, contributing to improving the work of medical examination and treatment for society. One of the techniques that are widely applied in medicine is the segmentation research used to process medical images. Although this task achieved great improvement in terms of accuracy, it still is a challenging problem in medical image processing due to that brain tumors can arise in various locations, shapes, and sizes e.g., especially for too small regions of brain tumors. In this paper, we build a simple but effective system model for segmenting diseased areas in medical images, such as a whole tumor, tumor core, enhancing tumor, edema, and necrotic. Firstly, we improve the U-Net network architecture to enhance the feature representation of brain tumor regions. To do that, adopting residual connection to U-Net can extract more informative features from input data and help optimization of deeper layers. Secondly, to verify the effectiveness of the proposed network, we train and evaluate the models using 4D input images of the BraTS 2018 dataset collected by MRI scanners, to solve the medical imaging problem of human brain tumors. As a result, the brain tumor segmentation image obtained through the training model clearly separated the layers from each other. In numerical results, the modified U-Net achieves the Dice score of 74%, 86%, and 75% for enhancing tumor, whole tumor, and tumor core, respectively.

Keywords: Tumor segmentation, model training, deep learning techniques

TÓM TẮT: Phân đoạn khối u não cung cấp các thông tin có giá trị cho việc lập kế hoạch phẫu thuật, lập kế hoạch điều trị và chẩn đoán ung thư. Ngày nay, nhiều nhà nghiên cứu về lĩnh vực thị giác máy tính đã ứng dụng các kỹ thuật học máy vào giải quyết các bài toán y học và thu được những thành công lớn, góp phần nâng cao công việc khám và chữa bệnh cho xã hội. Một trong những kỹ thuật được ứng dụng nhiều vào y học, đó là kỹ thuật phân đoạn dùng để xử lý hình ảnh trong y tế dựa vào các mô hình học sâu. Mặc dù, nhiệm vụ này đạt được sự cải thiện lớn về độ chính xác, nhưng nhiệm vụ này vẫn là một vấn đề thách thức trong xử lý hình ảnh y tế do các khối u não có thể phát sinh ở nhiều vị trí, hình dạng và kích thước khác nhau, ví dụ, đặc biệt đối với các vùng khối u não quá nhỏ. Trong bài báo này, chúng tôi xây dựng mô hình hệ thống phân đoạn vùng bệnh trong ảnh y tế với các loại như whole tumor, tumor core, enhancing tumor, edema, và necrotic. Mô hình được đề xuất bao gồm: (1) Xây dựng lại mô hình U-Net áp dụng cho bài toán phân đoạn khối u não; (2)

Xây dựng mô hình U-Net kết hợp kỹ thuật Residual block để tăng khả năng học của mô hình và cải thiện độ chính xác của phương pháp được đề xuất so với mô hình U-Net. Để đánh giá độ hiệu quả của mô hình mới, chúng tôi tiến hành các thí nghiệm sử dụng bộ dữ liệu BraTS 2018 trong đó các ảnh đầu vào 4D được thu thập bằng máy quét MRI và bộ dữ liệu này được sử dụng rộng rãi trong việc giải quyết bài toán ảnh y tế của khối u não bộ người. Về kết quả, mô hình được đề xuất đã phân đoạn các vùng của khối u não trong ảnh y tế một cách chính xác hơn về cả hai yếu tố định lượng và định tính. Về kết quả số, mô hình đã cải thiện mạng U-Net đạt được độ chính xác 74%, 86%, và 75% điểm số Dice của lớp enhancing tumor, whole tumor và tumor core.

Từ khóa: Phân đoạn khối u, huấn luyện mô hình, kỹ thuật học sâu.

1. GIỚI THIỆU TỔNG QUAN

Ảnh y học được sử dụng để thể hiện hình ảnh cơ thể con người hoặc bộ phận cơ thể phục vụ cho mục đích lâm sàng và cận lâm sàng nhằm chẩn đoán, kiểm tra bệnh hoặc khoa học y tế (bao gồm cả giải phẫu và sinh lý). Ảnh y học theo nghĩa rộng của nó, đó là một phần của hình ảnh sinh học và kết hợp X-Quang, y học hạt nhân, nội soi... dùng trong chẩn đoán điều trị bệnh lý của con người.

Y học hiện đại chẩn đoán bệnh dựa vào các triệu chứng lâm sàng (chẩn đoán lâm sàng) và các triệu chứng cận lâm sàng (chẩn đoán cận lâm sàng). Trong chẩn đoán cận lâm sàng thì chẩn đoán dựa trên hình ảnh thu được từ các thiết bị, máy y tế (chẩn đoán hình ảnh) ngày càng chiếm một vai trò quan trọng, nhất là ngày nay với sự trợ giúp của các thiết bị, máy y tế hiện đại, công nghệ cao có các phần mềm tin học hỗ trợ khiến cho hình ảnh rõ nét và chính xác hơn.

Các phương pháp chẩn đoán bệnh bằng hình ảnh y tế được ứng dụng nhiều trong nghiên cứu và thực nghiệm, như chẩn đoán qua hình ảnh X-Quang, hình ảnh siêu âm, siêu âm - Doppler màu, hình ảnh nội soi (mà thông dụng là nội soi tiêu hoá và nội soi tiết niệu) hình ảnh chụp cắt lớp vi tính (Computed Tomography Scanner- CT.

Scanner), hình ảnh chụp cộng hưởng từ hạt nhân (Magnetic Resonance Imaging-MRI)...

Chẩn đoán bệnh thông qua hình ảnh đã góp phần quan trọng nâng cao tính chính xác, kịp thời và hiệu quả cao trong việc phát hiện bệnh ở thời kỳ sớm. Dựa trên hình ảnh siêu âm, người bác sĩ có thể xác định tương đối chính xác kích thước của các bộ phận trong ổ bụng như gan, lách, thận, tụy, ...và phát hiện các khối bất thường nếu có. Từ hình ảnh siêu âm tim có thể xác định cấu trúc, kích thước các buồng tim, van tim và các mạch máu lớn. Trong sản khoa, siêu âm giúp xác định và theo dõi sự phát triển của thai nhi trong bụng mẹ; hình ảnh CT Scanner giúp thầy thuốc xác định được một số bệnh lý ở sọ não, đặc biệt là xác định máu tụ nội sọ, khối u não, chụp cộng hưởng từ hạt nhân xác định chính xác hơn các hình thái và các khối bất thường trong cơ thể (nếu có).

Trong thị giác máy tính, nhiệm vụ phân đoạn là một vấn đề thách thức bởi vì mô hình yêu cầu sự phân cụm của các đối tượng trong ảnh đạt độ chính xác cao. FCN [5] là một mạng tích chập đầy đủ mà ứng dụng các kỹ thuật trong phân loại ảnh vào phân đoạn đối tượng. Để hồi phục kích thước ảnh, mạng giải hóa sử dụng toán tử


tích chập chuyển vị [6] để tăng kích thước đặc trưng. Dựa vào mạng U-Net và FCN, Segnet [7] đề xuất mạng tích chập đầy đủ bao gồm mạng mã hóa và giải mã. Deeplab [8] là phương pháp phân đoạn hàng đầu mà đề xuất lớp tích chập giãn nở để điều khiển kích thước đặc trưng và độ phủ của bộ lọc.

Gần đây, lĩnh vực ảnh y tế mà sử dụng các kỹ thuật học sâu đã trở nên tin cậy và hiệu quả hơn các phương pháp truyền thống. Nhiều nghiên cứu dựa vào mạng tích chập như [9], [10], [11], [12], [13] được đề xuất cho phân đoạn khối u não. Đặc biệt dựa vào mạng U-Net, nhiều phương pháp [14], [15], [16] đã nâng cao mạng mã hóa và giải mã để xử lý dữ liệu MRI mà đạt được độ chính xác cao. Ở trong bài báo này, chúng tôi cũng cải thiện mạng U-Net bằng cách sử dụng kỹ thuật residual connection trong mỗi lớp tích chập của mạng mã hóa và giải mã. Lợi ích của kỹ thuật residual connection là có thể hồi phục lại thông tin bị mất sau mỗi lần giảm kích thước đặc trưng và có thể tránh sự suy giảm gradient trong quá trình học.

2. ĐỀ XUẤT MÔ HÌNH


Ở phần này, chúng tôi mô tả và phân tích các thành phần hệ thống bao gồm hệ thống xử lý ảnh đầu vào, sau đó đưa vào mạng học sâu Convolutional Neural Networks (CNNs) để trích xuất các đặc trưng của ảnh y tế và đưa ra kết quả phân vùng bệnh. Do hình ảnh y tế được thu thập từ các thiết bị công nghệ cao, có độ phân

giải cao và từ nhiều nguồn dữ liệu khác nhau nên cần phải có hệ thống để xử lý ảnh đầu vào theo một chuẩn nhất định. Ở bài toán này chúng tôi xây dựng thử nghiệm và đánh giá mô hình được đề xuất trên bộ dữ liệu BraTS 2018 [1] để xác định khối u ở não người. Chúng tôi sử dụng mô hình mạng học sâu dùng để trích xuất đặc trưng của đối tượng và học các vùng bệnh cần quan tâm thông qua Mạng U-net và Mạng U-net kết hợp Residual block.



Hình 1. Sơ đồ hệ thống trích xuất vùng bệnh trên ảnh y tế

Hình 1 thể hiện các thành phần cơ bản của hệ thống, đầu vào là ảnh y tế được đưa qua mạng học sâu kết hợp sử dụng kỹ thuật phân đoạn để đưa ra kết quả là hình ảnh phân vùng bệnh. Đối với trường hợp thực nghiệm, chúng tôi đã sử dụng ảnh về não bộ người của bộ dữ liệu BraTS 2018.



Hình 2. Sơ đồ hệ thống phân đoạn ảnh của khối u ở não người

Theo Hình 2, chúng tôi đã xây dựng chi tiết hệ thống phân vùng ảnh của khối u ở não người với bộ dữ liệu BraTS 2018. Từ dữ liệu đầu vào scan MRI (.nii.gz) của bộ dữ liệu BraTS 2018, chúng tôi đã chuẩn hóa dữ liệu này thông qua xử lý ảnh bằng hai thư viện Nibabel [2] (Thư viện dành riêng cho xử lý ảnh về thần kinh) và Python numpy.

Sử dụng lệnh với cú pháp:

```
import nibabel
mri = nibabel.load(*.nii.gz)
```

Trong đó * là đường dẫn file với 4 loại file khác nhau tương ứng với 4 phương thức của scan MRI (t1, t1ce, t2, flair). Qua bước xử lý ảnh này sẽ cho ra được hình ảnh của

khối u trên não người.


Sau đó, dữ liệu sẽ được biến đổi về dạng mảng numpy (ma trận 3D) để phù hợp với mạng CNN, bằng cách sử dụng lệnh với cú pháp:

```
numpy_array = mri.get_data()
```

Và ma trận này sẽ được đưa vào mô hình mạng học sâu CNN để phân đoạn khối u, từ mô hình này sẽ đưa ra được kết quả của các phân vùng ảnh của khối u trên não người.

2.1. Xây dựng mô hình U-Net áp dụng bài toán phân đoạn khối u não

Chúng tôi xây dựng lại chi tiết cụ thể của mô hình U-Net [3] như sau:




Hình 3. Mô hình U-Net ứng dụng cho phân đoạn u não

Mô hình U-Net bao gồm phần encoding để trích xuất đặc trưng của ảnh đầu vào và phần decoding để tăng độ phân giải của các feature map. Phần encoding chúng tôi sử dụng toán tử max-pooling, theo sau 2 lớp convolution để giảm độ phân giải của feature maps. Phần decoding sử dụng transposed convolution với scale = 2 để tăng độ phân giải của feature maps. Để không đánh mất các thông tin đặc trưng của ảnh, chúng tôi dùng toán tử concatenation để kết hợp hai feature maps cùng kích thước ở phần encoding và phần decoding một


cách tương ứng.

2.2. Xây dựng mô hình U-Net kết hợp Residual block [4] dùng để phân đoạn khối u não

Kiến trúc mạng này kế thừa mô hình U-Net áp dụng bài toán phân đoạn khối u não nhưng khác với mô hình U-Net: bên trong các khối 1), 2), ..., 10) (Mô tả trong mô hình U-Net), chúng tôi tiến hành dùng kết nối tắt (hoặc gọi là residual block) để tránh vanishing gradient và có thể bảo toàn đặc trưng từ các lớp trước.



Hình 4: Mô hình mạng U-Net kết hợp Residual block



Hình 5: Mô hình mạng Residual block

Theo Hình 5, hiển thị khối kết nối tắt được sử dụng trong mạng. Đầu vào x và đầu ra của khối được kết nối với nhau thông qua identity mapping mà không cần thêm các lớp convolution. Với $H(x)$ là giá trị dự đoán, $F(x)$ là giá trị thật (nhãn), chúng ta muốn $H(x)$ bằng hoặc xấp xỉ $F(x)$.

3. THỰC NGHIỆM

3.1. Cơ sở dữ liệu thực nghiệm

Chúng tôi sử dụng bộ cơ sở dữ liệu hình ảnh dùng để huấn luyện mô hình và đánh giá là bộ dữ liệu BraTS2018[1] của Trường Y khoa Perelman (thuộc Đại học Pennsylvania, Hoa Kỳ).

Bộ dữ liệu này được cập nhật từ bộ BraTS'16, với các lần quét MRI đa phương thức 3T được thu nhận lâm sàng thường xuyên hơn và tất cả các nhãn thật cơ bản đã được chỉnh sửa thủ công bởi các chuyên gia thần kinh được hội đồng chuyên môn chứng nhận.

BraTS luôn tập trung vào việc đánh giá các phương pháp hiện đại để phân đoạn

khối u não trong chụp cộng hưởng từ đa phương thức (MRI). BraTS 2018 sử dụng quét MRI trước khi phẫu thuật và tập trung vào phân đoạn các khối u não không đồng nhất về bản chất (ngoại hình, hình dạng và mô học), cụ thể là gliomas (u thần kinh đệm).


3.2. Mô tả dữ liệu hình ảnh

Hình ảnh quét từ máy MRI là hình ảnh 4D có dung lượng lớn, nên đã được tổ chức và chuẩn hóa lại vừa giữ được chất lượng ảnh đồng thời dung lượng không quá lớn. Do đó, tất cả các bản quét đa phương thức BraTS đều có sẵn dưới dạng tệp NIfTI (.nii.gz) và bao gồm 4 phương thức (modals):

- Trọng số T1 (T1 của hình ảnh gốc)
- Trọng số T1 sau tương phản (T1CE)
- Trọng số T2 (Trọng số khi tăng cường)
- Khối lượng Phục hồi đảo ngược giảm dịch T2 (T2 Fluid Attenuated Inversion Recovery - FLAIR).

Dữ liệu được thu thập với các quy trình lâm sàng khác nhau bằng các máy quét khác nhau từ nhiều tổ chức.

Tất cả các bộ dữ liệu hình ảnh đã được dán nhãn theo cách thủ công, từ một đến bốn người đánh giá, theo cùng một cách thức dán nhãn và nhãn của chúng đã được các nhà X quang thần kinh có kinh nghiệm phê duyệt.



Hình 6. Minh họa về Dữ liệu hình ảnh đầu vào

Theo Hình 6, từ trái qua phải hình T1 (với trọng số T1 của ảnh gốc sau khi quét não người bằng máy MRI), hình T1CE (trọng số T1 sau khi tương phản), hình T2 (trọng số T2 khi tương cường) và hình FLAIR (Khối lượng Phục hồi đảo ngược giảm dịch T2). Hình cuối cùng phía bên phải là hình ảnh phân đoạn khối u bằng phương pháp thủ công có 4 nhãn:

- Nhãn 1: Background (Nền màu đen)
- Nhãn 2: Nectrotic and non-enhancing tumor core (Lõi khối u hoại tử và không tăng cường - màu vàng)
- Nhãn 3: Peritumoral Edema (Phù

phục mạc - màu tím)

- Nhãn 4: Enhancing Tumor (Khối u tăng cường - màu xanh)

Dữ liệu hình ảnh được quét từ máy MRI gồm có 750 ảnh trong đó 484 ảnh dùng để huấn luyện cho mô hình và 266 ảnh dùng để đánh giá. Hình ảnh dữ liệu là ảnh 4D và có kích thước ảnh là 240x240x155x4.

3.3. Cài đặt thử nghiệm và cấu hình

Cài đặt các thông số mô hình

Chúng tôi xây dựng mô hình mạng huấn luyện cho bài toán phân đoạn hình ảnh khối u của não người với các thông số sau:

- Trình tối ưu hóa (Optimizer: Adam (learning rate: 0.001, weight decay: 0.00005) với tỷ lệ học 0.001 và trọng số phân rã 0.00005.

- Tổng epochs: 50, batch size: 4

- GPUs: NVIDIA 1070 Ti, 8 GB

- Hàm loss: chúng tôi sử dụng hàm

Dice loss

$$D = \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2} \quad (3.1)$$

N: số lượng voxels;

p_i : Khối lượng phân đoạn dự đoán nhị phân (predicted binary segmentation volume);

g_i : Khối lượng nhãn thực nhị phân (ground truth binary volume).

[Tiêu chuẩn đánh giá:

Chúng tôi xây dựng tiêu chuẩn đánh giá cho bài toán phân đoạn hình ảnh khối u trong não người dựa vào hàm Dice Score.


$$\text{Score} = \frac{2TP}{2TP+FP+FN} \quad (3.2)$$

Trong đó:

TP: Số lượng True Positive (Tổng số lượng pixels mà có độ sáng bằng 1 ở cả prediction và ground truth);

FP: Số lượng False Positive (Số lượng pixels bằng 1 ở prediction nhưng bằng 0 ở ground truth);

FN: Số lượng False Negative.



Hình 7. Mô tả về Dice score
($2 \times \text{Overlap} / \text{Total number of pixels}$)


Hình 7 thể hiện cách tính Dice score giữa hai vùng ảnh prediction (màu xanh) và vùng ground truth (màu cam). Dice score được tính: $2 \times \text{diện tích của 2 vùng giao nhau} / \text{Tổng pixels ở hai vùng ảnh}$. Như vậy, Dice score được tính tương tự như IoU (prediction, ground truth) và được sử dụng như là tiêu chuẩn chính để so sánh độ chính xác trên bộ dataset BraTS2018.

Ở bài toán này, chúng tôi có 3 loại dice score: Dice ET, Dice WT, Dice TC

ET: enhancing tumor core (Lõi khối u tăng cường - vùng màu vàng);

WT: whole tumor (Toàn bộ khối u - tập hợp các vùng vàng, xanh, đỏ);

TC: tumor core (Lõi khối u - tập hợp vùng vàng và đỏ).



Hình 8. So sánh phân đoạn khối u não bộ người giữa mô hình huấn luyện và thực tế

3.4. Kết quả thực nghiệm và đánh giá


Trong quá trình huấn luyện và đánh giá mô hình mạng học sâu dùng để phân đoạn hình ảnh khối u của não bộ người, chúng tôi đã sử dụng 484 hình ảnh để huấn luyện và 266 hình ảnh để đánh giá. Kết quả thu được thể hiện trong minh họa qua Hình 9 theo chiều từ trái qua phải các ảnh hiển thị kết quả như sau:

- Original image (ảnh gốc): ảnh đầu vào của mô hình.
- Predicted feature map (ảnh dự đoán đối tượng): ảnh phân đoạn khối u sau khi huấn luyện.

- Ground truth dense label (nhãn thật): ảnh phân đoạn khối u được làm thủ công và được các chuyên gia y tế kiểm duyệt đánh giá.

- Trong hình ảnh được phân đoạn khối u não bộ người bao gồm 4 lớp:

- + Lớp background: nền (màu đen)
- + Lớp necrotic tumor: khối u hoại tử (màu vàng)
- + Lớp peritumoral edema: phù phúc mạc (màu tím)
- + Lớp enhancing tumor: khối u tăng cường (màu xanh)



Hình 9. Minh họa kết quả phân đoạn khối u não giữa mô hình huấn luyện và thực tế

Phân tích kết quả phân đoạn khối u não bộ ở người ta thấy:

- Hình ảnh phân đoạn khối u thu được qua mô hình huấn luyện cũng đã phân rõ được các lớp với nhau nhưng ở một số điểm dự đoán chưa được tốt khi so sánh với nhãn thật.


- Lớp peritumoral edema là vùng có diện tích lớn nhất và có hình dạng gần tương đồng với nhãn thật, như vậy ta có dễ dàng phân đoạn lớp này.

Kết quả của phân đoạn khối u não bộ người được đánh giá qua hàm Dice score

(Dice ET, Dice WT, Dice TC) được thể hiện qua Bảng 1.

Bảng 1. Kết quả của tiêu chuẩn đánh giá phân đoạn khối u não giữa mô hình huấn luyện và thực tế

Mô hình	Dice ET	Dice WT	Dice TC
U-Net	0.66	0.87	0.69
U-Net + Residual	0.74	0.86	0.75



Hình 10. Một số kết quả phân đoạn khối u não giữa mô hình huấn luyện và thực tế

4. KẾT LUẬN

Những nghiên cứu về bài toán phân đoạn ảnh sử dụng kỹ thuật xử lý ảnh, trí tuệ nhân tạo và đặc biệt là mạng tích chập học sâu CNN, đã giúp chúng tôi có cách tiếp cận với ảnh y tế và đưa ra được phân vùng của khối u ở não người.

Chúng tôi đã áp dụng cải tiến được mô hình để phân đoạn hình ảnh để trích xuất vùng bệnh trên ảnh y tế và đã ứng dụng trên bộ dữ liệu BraTS 2018. Kết quả của hình

ảnh phân đoạn khối u não người, đã xác định được các vùng của khối u một cách cơ bản.

Bên cạnh đó, chúng tôi cũng đánh giá hiệu suất của các phương pháp bằng kỹ thuật thực nghiệm trên tập dữ liệu lớn. Trong đó, chúng tôi đã so sánh kết quả phân đoạn ảnh khối u giữa các mô hình mạng khác nhau và đánh giá chúng theo tiêu chuẩn cụ thể.

TÀI LIỆU THAM KHẢO

- [1] D. BraTS 2018. Available: <https://www.med.upenn.edu/sbia/brats2018/data.html>
- [2] T. v. Nibabel. Available: <https://nipy.org/nibabel/#>
- [3] O. Ronneberger, P. Fischer, and T. Brox (2015), "U-net: Convolutional networks for biomedical image segmentation", in *International Conference on Medical image computing and computer-assisted intervention*, pp. 234-241: Springer.
- [4] K. He, X. Zhang, S. Ren, and J. Sun (2016), "Deep residual learning for image recognition", in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778.
- [5] J. Long, E. Shelhamer, and T. Darrell (2015), "Fully convolutional networks for semantic segmentation", in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440.
- [6] F. Yu and V. Koltun (2015), "Multi-scale context aggregation by dilated convolutions," *arXiv preprint arXiv:1511.07122*.
- [7] V. Badrinarayanan, A. Kendall, and R. Cipolla (2017), "Segnet: A deep convolutional encoder-decoder architecture for image segmentation," *IEEE transactions on pattern analysis and machine intelligence*, vol. 39, no. 12, pp. 2481-2495.
- [8] L.-C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille (2017), "Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs," *IEEE transactions on pattern analysis and machine intelligence*, vol. 40, no. 4, pp. 834-848.
- [9] H. Shen, R. Wang, J. Zhang, and S. J. McKenna (2017), "Boundary-aware fully convolutional network for brain tumor segmentation," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, pp. 433-441.
- [10] S. Pereira, A. Pinto, V. Alves, and C. A. Silva (2016), "Brain tumor segmentation using convolutional neural networks in mri images," *IEEE transactions on medical imaging*, vol. 35, no. 5, pp. 1240-1251.

- [11] L. Chen, Y. Wu, A. M. DSouza, A. Z. Abidin, A. Wismuller, and C. Xu (2018), “Mri tumor segmentation with densely connected 3d cnn,” in Medical Imaging 2018: Image Processing, vol. 10574. International Society for Optics and Photonics, p. 105741F.
- [12] H. Li, A. Li, and M. Wang (2019), “A novel end-to-end brain tumor segmentation method using improved fully convolutional networks,” Computers in biology and medicine, vol. 108, pp. 150-160.
- [13] K. Hu, Q. Gan, Y. Zhang, S. Deng, F. Xiao, W. Huang, C. Cao, and X. Gao (2019), “Brain tumor segmentation using multi-cascaded convolutional neural networks and conditional random field,” IEEE Access, vol. 7, pp. 92 615-92 629.
- [14] H. Dong, G. Yang, F. Liu, Y. Mo, and Y. Guo (2017), “Automatic brain tumor detection and segmentation using u-net based fully convolutional networks,” in annual conference on medical image understanding and analysis. Springer, pp. 506-517.
- [15] A. Kermi, I. Mahmoudi, and M. T. Khadir (2018), “Deep convolutional neural networks using u-net for automatic brain tumor segmentation in multimodal mri volumes,” in International MICCAI Brainlesion Workshop. Springer, pp. 37-48.
- [16] M. U. Rehman, S. Cho, J. H. Kim, and K. T. Chong (2020), “Bu-net: Brain tumor segmentation using modified u-net architecture,” Electronics, vol. 9, no. 12, p. 2203.

Liên hệ:

ThS. Võ Hoàng Thành

Phòng Quản trị, Trường Đại học Quảng Bình

Địa chỉ: 312 Lý Thường Kiệt, Đồng Hới, Quảng Bình

Email: vohoangthanh@gmail.com

Ngày nhận bài: 15/6/2022

Ngày gửi phản biện: 18/6/2022

Ngày duyệt đăng: 11/10/2022