

Đánh Giá Hiệu Năng Một Số Kỹ Thuật Học Sâu Cho Phân Vùng Mạch Máu Gan Trong Ảnh Chụp Cắt Lớp Vi Tính

Lê Quốc Anh*, Phạm Xuân Lộc†, Lưu Mạnh Hà*† §

* Viện Tiên tiến về Kỹ thuật và Công nghệ, Trường Đại học Công nghệ, ĐHQGHN

† Khoa Điện tử - Viễn thông, Trường Đại học Công nghệ, ĐHQGHN

§ Email: halm@vnu.edu.vn

Tóm tắt—Phân vùng mạch máu gan trong ảnh chụp cắt lớp vi tính (CLVT) là bước quan trọng đối với việc chẩn đoán và lập kế hoạch điều trị các bệnh lý liên quan tới gan. Mạch máu gan có cấu trúc phức tạp, độ tương phản thấp, ảnh hưởng bởi nhiều, do đó đã đặt ra nhiều thách thức cho việc phân vùng chính xác mạch máu gan. Trong lĩnh vực xử lý ảnh y tế, kỹ thuật học sâu đã cho thấy sự phát triển nhanh chóng. Gần đây, mạng nơ-ron Transformer được áp dụng và cho kết quả khả quan trong lĩnh vực xử lý ảnh y tế. Trong bài báo này, chúng tôi đánh giá hiệu năng phân vùng mạch máu gan giữa kỹ thuật học sâu dựa trên mạng nơ-ron tích chập (3D-ResUNet, 2D/3D nn-UNet) và kỹ thuật học sâu sử dụng mạng nơ-ron Transformer (TransUNet, Swin-UNet, MedT). Dữ liệu ảnh chụp CLVT sử dụng để huấn luyện và đánh giá được thu thập từ nhiều cơ sở y tế trên thế giới bao gồm ảnh chụp CLVT sử dụng bức xạ liều thông thường và liều thấp. Kết quả cho thấy 3D nn-UNet có độ chính xác (ACC) trung bình cao nhất, 98%; ba kỹ thuật học sâu 2D/3D nn-UNet và TransUNet đều đạt trung bình giá trị chỉ số đánh giá DSC lớn hơn 75%. Trong kỹ thuật điều trị đốt sóng cao tần (RFA) mạch máu gan lớn là vùng được quan tâm, cả ba kỹ thuật học sâu đều ở trên đều cho chỉ số đánh giá trung bình DSC ở vùng mạch máu lớn lớn hơn 80%. Kết quả của nghiên cứu cho thấy rằng 3D nn-UNet có thể tự động phân vùng mạch máu gan với độ chính xác cao, cho thấy tiềm năng ứng dụng vào quá trình lập kế hoạch can thiệp điều trị ung thư gan bằng kỹ thuật RFA.

Từ khóa—*Phân vùng mạch máu gan, mạch máu gan lớn, ảnh chụp CLVT, kỹ thuật học sâu, mạng nơ-ron tích chập, mạng nơ-ron Transformer.*

I. GIỚI THIỆU

Phân tích mạch máu gan là bước quan trọng trong quá trình chẩn đoán và điều trị các bệnh lý liên quan tới gan [1]. Trong giải phẫu chức năng gan, thông tin về hệ thống mạch máu gan (đặc biệt là các nhánh chính) giúp phân chia các phân thùy, hỗ trợ thực hiện một số thủ thuật như cắt bỏ, cấy ghép gan [2]. Phân vùng mạch máu gan còn giúp hiển thị thông tin mạch máu trên không gian 3 chiều, hỗ trợ việc lập kế hoạch và thực hiện các thủ thuật can thiệp trong vùng gan [3]. Ảnh chụp CLVT

kết hợp với thuốc cản quang được sử dụng phổ biến giúp cung cấp thông tin về mạch máu gan mà không cần thực hiện các thủ thuật xâm lấn. Khỏi u gan nằm cạnh mạch máu lớn (đường kính > 3 mm) khi điều trị bằng kỹ thuật RFA có thể gia tăng tỉ lệ tái phát tại chỗ do ảnh hưởng bởi hiệu ứng tỏa nhiệt (heat-sink effect) [4].

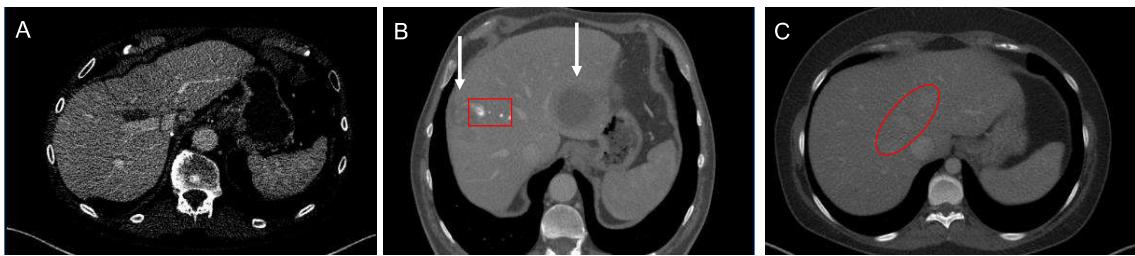
Phân vùng mạch máu gan thủ công là một công việc khá tốn công sức và không mang lại hiệu quả cao [5]. Do vậy, các nghiên cứu cải thiện độ chính xác và sự hiệu quả của tác vụ phân vùng mạch máu gan một cách tự động/bán tự động được công đồng nghiên cứu quan tâm. Tuy nhiên, cấu trúc phức tạp, ảnh hưởng bởi nhiều và có mức độ tương phản thấp (xem Hình 1) đã đặt ra nhiều thách thức cho phân vùng mạch máu gan trong ảnh chụp CLVT [6].

Gần đây, sự phát triển mạnh mẽ của các kỹ thuật học sâu trong lĩnh vực xử lý ảnh y tế đã tạo ra nhiều kỹ thuật hiệu quả cho tác vụ phân vùng. Tuy nhiên nghiên cứu ứng dụng kỹ thuật học sâu cho phân vùng mạch máu trong ảnh CT phục vụ lập kế hoạch điều trị ung thư gan bằng kỹ thuật đốt sóng cao tần còn rất hạn chế. Qua nghiên cứu tổng quan, chúng tôi nhận thấy rằng việc đánh giá hiệu năng phân vùng mạch máu gan với kỹ thuật học sâu sử dụng Transformer cần được khảo sát kỹ lưỡng hơn. Do vậy, mục tiêu nghiên cứu này của chúng tôi là đánh giá hiệu năng phân vùng mạch máu gan của một số kỹ thuật học sâu và chú ý đến vùng mạch máu gan lớn (đường kính > 3 mm). Cụ thể, chúng tôi sử dụng ba kỹ thuật học sâu dựa trên CNNs bao gồm 3D-ResUNet [7], 2D/3D nn-UNet [8] và so sánh với ba kỹ thuật học sâu sử dụng Transformer hiện đại là TransUNet [9], Swin-UNet [10] và MedT [11].

II. CÁC NGHIÊN CỨU LIÊN QUAN

A. Phương pháp xử lý ảnh cổ điển

Nhiều nghiên cứu về các phương pháp phân vùng mạch máu gan đã được công bố [3], [6]. Nhóm các phương pháp xử lý ảnh cổ điển phần lớn sử dụng các



Hình 1. Ví dụ về một số thách thức trong phân vùng mạch máu gan: (A) Ảnh chụp CLVT sử dụng bức xạ liệu thấp, ảnh chứa nhiều nhiễu, (B) Ảnh chứa khối u với các mạch máu nằm cạnh (mũi tên màu trắng) và vùng mô mềm có dạng tương tự mạch máu gan (hình vuông màu đỏ), (C) Tính mạch gan không hiển thị rõ ràng do thời gian ngắt thuốc cản quang chưa hoàn toàn (hình elip màu xanh).

bộ lọc để giảm thiểu nhiễu và tăng cường tương phản của mạch máu gan với các vùng mô gan xung quanh, sau đó áp dụng các kỹ thuật xử lý hình thái học để dự đoán phân vùng mạch máu gan [12], [13]. Luu và cộng sự [12] đề xuất phương pháp tiếp cận dựa trên kỹ thuật region growing để đánh giá sự hiệu quả phân vùng mạch máu gan với sáu loại bộ lọc tăng cường tương phản mạch máu. Sangsefidi và cộng sự [13] cải thiện tác vụ phân vùng mạch máu bằng một biến thể của kỹ thuật graph cuts cho việc xác định các cấu trúc nhỏ của mạch máu gan. Bên cạnh các kỹ thuật hình thái học, Zeng và cộng sự [14] trích xuất đặc trưng từ ba loại bộ lọc và sử dụng thuật toán máy học cực trị (ELM) để phân vùng mạch máu gan. Tuy nhiên, các nghiên cứu được liệt kê ở trên có hạn chế do yêu cầu việc xác định cẩn thận tính chất của dữ liệu và lựa chọn thông số phù hợp cho từng tập dữ liệu cụ thể.

B. Phương pháp áp dụng kỹ thuật học sâu

Với sự phát triển mạnh mẽ của phần cứng máy tính trong thập kỷ qua, cùng với nhiều bộ dữ liệu nguồn mở được công bố, nhóm phương pháp ứng dụng các kỹ thuật học sâu đã cho thấy sự hiệu quả trong lĩnh vực xử lý ảnh y tế [5], [15]. Một trong những lý do giải thích cho sự mạnh mẽ của các kỹ thuật học sâu là sử dụng mạng nơ-ron thu lại những đặc trưng phức tạp của ảnh và gộp chúng lại bằng biểu diễn phân cấp để đưa ra các dự đoán [3]. Nhiều nghiên cứu đã áp dụng kỹ thuật học sâu dựa trên mạng nơ-ron tích chập (CNNs) cho tác vụ phân vùng mạch máu gan. Huang và cộng sự [3] đã sử dụng 3D UNet kết hợp với biến thể của hàm mất mát Dice loss và nghiên cứu ảnh hưởng của việc gán nhãn dữ liệu tới độ chính xác của tác vụ phân vùng mạch máu gan. Yu và cộng sự [7] kết hợp kiến trúc ResNet với 3D UNet tạo nên kiến trúc 3D ResUNet cho phân vùng mạch máu gan. Kittrungrotsakul và cộng sự [5] đề xuất phương pháp phân vùng mạch máu gan với ba mạng CNNs sử dụng kiến trúc DensNet cho trích xuất đặc trưng từ ba mặt phẳng (plane) khác nhau trong ảnh chụp CLVT. Su và cộng sự [15] cũng đề xuất kiến trúc DV-Net cho phân vùng mạch máu gan. Các phương

pháp dựa trên CNNs được nêu ở trên chỉ nghiên cứu đến kỹ thuật liên quan đến việc thay đổi kiến trúc CNNs, Isensee và cộng sự [8] đã công bố một công cụ mạnh mẽ trong tác vụ phân vùng ảnh y tế, sử dụng kiến trúc UNet kết hợp với việc tự động thiết lập các thông số dựa theo bộ dữ liệu cho quá trình huấn luyện và kiểm thử đã giúp nn-UNet có đạt độ chính xác cao ở nhiều tác vụ phân vùng ảnh y tế. Tuy nhiên một số hạn chế của CNNs là được thiết kế có xu hướng trích xuất đặc trưng cục bộ (local) [16], trong khi đó đặc trưng toàn cầu (global) cho thấy tính hiệu quả trong tác vụ phân vùng [17].

Mạng nơ-ron Transformer (Transformer) thiết kế với mô hình dự đoán sequence-to-sequence đã nổi lên trở thành kiến trúc học máy tạo ra bước ngoặt trong lĩnh vực xử lý ngôn ngữ tự nhiên (NLP) [9]. Trong lĩnh vực xử lý ảnh, Transformer đã trở thành một hướng nghiên cứu mới và tiềm năng cho tác vụ phân vùng trong ảnh. Điểm nổi bật của Transformer so với CNNs là mô hình có thể thu thập đặc trưng toàn cầu trong ảnh [16]. Đã có nhiều nghiên cứu về kỹ thuật học sâu sử dụng Transformer cho phân vùng trong ảnh y tế và cho thấy kết quả khả quan so với kỹ thuật học sâu dựa trên CNNs [16], [9], [10], [11].

III. PHƯƠNG PHÁP NGHIÊN CỨU

A. Tiền xử lý dữ liệu

Mục tiêu của bước tiền xử lý dữ liệu giúp giới hạn vùng dự đoán cho phân vùng mạch máu gan. Đầu tiên, giá trị các điểm ảnh trong ảnh chụp CLVT được giới hạn trong khoảng [0, 400], khoảng giá trị này thu lại được hầu hết thông tin phía bên trong vùng gan trong ảnh chụp CLVT [15]. Sau đó, chúng tôi sử dụng "mặt nạ gan" để thu hẹp lại vùng dự đoán mạch máu gan. "Mặt nạ gan" được tạo từ phân vùng gan dự đoán bởi mạng CNNs đã được nhóm thực hiện từ nghiên cứu trước [18] và kết hợp với kỹ thuật hình thái học giãn nở (dilation) với hệ số mở rộng (X,Y,Z) là (30,30,1) để đảm bảo bao phủ đầy đủ vùng mạch máu gan.

B. Kỹ thuật học sâu cho phân vùng mạch máu gan

- **3D-ResUNet:** Kỹ thuật được sử dụng bởi Yu và cộng sự (2019) [7] cho phân vùng mạch máu gan, kỹ thuật kết hợp 3D UNet với ResNets giúp tăng hiệu quả trong quá trình huấn luyện và cải thiện khả năng trích xuất đặc trưng cục bộ và đặc trưng toàn cầu.
- **nn-UNet:** Đây là công vụ mạnh mẽ cho tác vụ phân vùng trong ảnh y tế, với khả năng tự động cấu hình dựa theo dữ liệu đưa vào. Công cụ được sử dụng để đánh giá trong tác vụ phân vùng mạch máu và khối u gan trong cuộc thi phân vùng ảnh y tế Decathlon và đạt kết quả ở vị trí đầu tiên [8].
- **TransUNet:** Kỹ thuật sử dụng kiến trúc UNet và có sự thay đổi tại bộ mã hóa. Transformer mã hóa đặc trưng trích xuất từ CNNs để đưa đến bộ giải mã. [9].
- **Swin-UNet:** Kỹ thuật sử dụng kiến trúc UNet tuy nhiên thay đổi CNNs thành các khối Swin Transformer cho việc trích xuất đặc trưng của ảnh [10].
- **MedT:** Kỹ thuật áp dụng Transformer hoàn toàn chỉ dựa trên cơ chế tự chú ý (self-attention) và không yêu cầu sử dụng mô hình pre-train [11].

C. Hàm mất mát (loss function)

Hàm mất mát đóng vai trò quan trọng trong kỹ thuật học sâu, giúp xác định sự sai khác giữa nhãn dự đoán so với nhãn ground truth và tối ưu lại kết quả. Chúng tôi liệt kê một số hàm mất mát được sử dụng trong mã chương trình nguồn mở bởi các kỹ thuật học sâu trong bài báo này. Hàm kết hợp Dice loss và BCE được sử dụng trong 2D/3D nn-UNet, TransUNet và Swin-UNet. Trong khi đó, MedT sử dụng hàm Entropy chéo nhị phân, còn 3D-ResUNet sử dụng hàm Dice loss.

1) Hàm Entropy chéo nhị phân (BCE):

$$\mathcal{L}_{BCE}(g, p) = -\frac{1}{N} \sum_{i=0}^N (g_i \log(p_i) - (1 - g_i) \log(1 - p_i)) \quad (1)$$

với g và p là nhãn phân vùng mạch máu gan ground truth và dự đoán; N là số lượng điểm ảnh tham gia trong quá trình huấn luyện; g_i và p_i là giá trị tại điểm ảnh thứ i của g và p .

2) Hàm Dice loss:

$$\mathcal{L}_{Dice}(g, p) = 1 - \frac{2 \times \sum_{i=0}^N g_i p_i + smooth}{\sum_{i=0}^N g_i + \sum_{i=0}^N p_i + smooth} \quad (2)$$

với $smooth$ là một hằng số khác 0 giúp hàm mất mát luôn có nghĩa cho trường hợp g và p có tất cả các giá trị bằng 0.

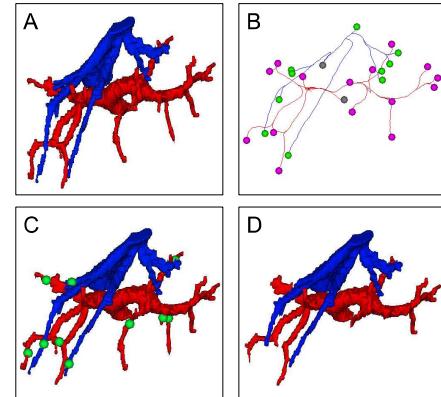
3) Hàm kết hợp Dice loss và BCE (D-BCE):

$$\mathcal{L}_{D-BCE} = \lambda \mathcal{L}_{Dice} + \gamma \mathcal{L}_{BCE} \quad (3)$$

với hai hệ số λ và γ sử dụng điều chỉnh sự cân bằng tỉ lệ mẫu [15].

D. Xác định phân vùng mạch máu gan lớn

Trong quá trình điều trị ung thư gan bằng kỹ thuật RFA, mạch máu gan lớn (đường kính > 3 mm) là thông tin liên qua đến tỉ lệ tái phát cục bộ sau khi điều trị [4]. Vì vậy, chúng tôi tiến hành đánh giá độ chính xác của các kỹ thuật học sâu với phân vùng mạch máu gan lớn. Chúng tôi giới hạn vùng đánh giá bằng việc xác định phân vùng mạch máu gan lớn từ vùng mạch máu gan ground truth. Quá trình xác định vùng mạch máu gan lớn được mô tả trong Hình 2. Phương pháp sẽ xác định centerline bằng các điểm kết thúc của các nhánh mạch máu, từ đường centerline các hình cầu nội tiếp được tạo ra để ước lượng đường kính của nhánh mạch máu. Với các nhánh mạch máu có đường kính nhỏ hơn 3 mm tại điểm bắt đầu của nhánh đó sẽ tạo ra một hình cầu và xóa các giá trị điểm ảnh vùng mạch máu gan trong hình cầu đó. Cuối cùng, phân vùng mạch máu gan lớn được thu lại bằng việc giữ lại vùng điểm ảnh lớn nhất.



Hình 2. Quá trình xác định vùng mạch máu gan lớn. (A) Toàn bộ phân vùng mạch máu gan, (B) Điểm bắt đầu (màu xám), các điểm kết thúc (màu xanh lá và màu tím) của nhánh mạch máu, đường centerline (màu xanh và màu đỏ) của cấu trúc vùng mạch máu gan, (C) Các điểm rẽ nhánh của vùng mạch máu nhỏ (màu xanh lá), (D) Phân vùng mạch máu gan lớn.

IV. THỰC NGHIỆM VÀ ĐÁNH GIÁ KẾT QUẢ

A. Dữ liệu ảnh y tế và gán nhãn

Trong nghiên cứu này, dữ liệu ảnh chụp CLVT được chúng tôi tổng hợp từ 5 bộ dữ liệu thu thập tại nhiều trung tâm y tế và bệnh viện trên thế giới. Bộ dữ liệu đầu tiên là bộ dữ liệu nguồn mở 3Dircadb-01 (IRCADB)¹ được sử

¹<https://www.ircad.fr/research/3d-ircadb-01/>.

dụng phổ biến cho các nghiên cứu phân vùng mạch máu gan [5], [15]. Chúng tôi lựa chọn 12 ảnh cho quá trình huấn luyện và 5 ảnh sử dụng để kiểm thử. Bộ dữ liệu thứ hai từ cuộc thi phân vùng gan năm 2007 của MICCAI (SLiver07)² được gợi ý sử dụng bởi nhiều nghiên cứu về phân vùng mạch máu gan [3], [19]. Chúng tôi lựa chọn 8 ảnh và 5 ảnh trong SLiver07 tương ứng cho quá trình huấn luyện và kiểm thử.

Hai bộ dữ liệu tiếp theo thu thập từ Trung tâm Y học Erasmus (EMC) và Bệnh viện Trung ương Quân đội 108 (H108) và đã được cho phép sử dụng vào mục đích nghiên cứu. Trong đó, 10 ảnh chụp CLVT từ 10 bệnh nhân được thu thập trong quá trình chẩn đoán và lập kế hoạch điều trị ung thư gan bằng kỹ thuật RFA tại EMC; 5 ảnh chụp CLVT từ 5 bệnh nhân được thu thập trong quá trình thăm khám và chẩn đoán ung thư gan tại H108. Ảnh chụp CLVT từ EMC và H108 sử dụng bức xạ liều thấp được xác nhận từ các nghiên cứu trước [20], [18]. Trong bộ dữ liệu EMC chúng tôi lựa chọn 5 ảnh cho quá trình huấn luyện, để kiểm thử 5 ảnh còn lại trong EMC và 5 ảnh trong H108 được sử dụng.

Trong bộ dữ liệu IRCADB, 12 ảnh sử dụng cho quá trình huấn luyện đã được gán nhãn đầy đủ vùng mạch máu gan (tĩnh mạch gan, tĩnh mạch cửa) bởi một số chuyên gia. Dữ liệu còn lại sử dụng trong nghiên cứu này được gán nhãn thủ công bởi kỹ thuật viên và có sự xác nhận bởi chuyên gia. Tất cả ảnh chụp CLVT không hiển thị rõ ràng vùng tĩnh mạch gan (xem Hình 1.C) sẽ được loại bỏ trong nghiên cứu này.

Gần đây, cuộc thi phân vùng trong ảnh y tế Decathlon³ được tổ chức đã công bố một bộ dữ liệu lớn với 404 ảnh chụp CLVT cho tác vụ phân vùng mạch máu gan và u gan (MSD8), tuy nhiên có nghiên cứu đã xác nhận bộ dữ liệu có một số vùng mạch máu gan chưa được gán nhãn [21], vì vậy chúng tôi không sử dụng MSD8 cho quá trình huấn luyện. Chúng tôi chọn 10 ảnh trong đó chỉnh lại nhãn gán vùng mạch máu gan và sử dụng quá trình kiểm thử.

B. Cấu hình phần cứng và thực thi

Chúng tôi thực thi các kỹ thuật học sâu trên Python 3.8 sử dụng Pytorch 1.7 trên nền CUDA 11.2. Kỹ thuật 3D ResUNet sử dụng mã nguồn tại <https://github.com/assassint2017/MICCAI-LITS2017>. Các kỹ thuật học sâu còn lại tận dụng mã nguồn được nêu trong bài báo gốc. Các thông số cài đặt được để huấn luyện và kiểm thử chương trình sử dụng theo sự gợi ý từ tác giả của bài báo gốc.

Phương pháp xác định mạch máu gan lớn sử dụng thư viện VMTK⁴ tích hợp trên gói phần mềm 3D Slicer.

Nghiên cứu này được thực hiện trên máy tính hệ điều hành Ubuntu 20.04 với bộ vi xử lý Intel® Core™ i9 10900 và GPU NVIDIA GeForce RTX™ 3090 (24 GB).

C. Các chỉ số đánh giá

Để so sánh hiệu năng của các kỹ thuật học sâu cho phân vùng mạch máu gan, bốn chỉ số đánh giá phổ biến trong nhiều nghiên cứu về phân vùng mạch máu được sử dụng [3], [15] bao gồm: độ chính xác (*ACC*), độ nhạy (*SEN*), độ đặc hiệu (*SPE*) và hệ số tương đồng DICE (*DSC*). Các chỉ số được tính với *TP* là số lượng điểm ảnh dự đoán chứa mạch máu gan và nằm trong phân vùng mạch máu gan ground truth, *FN* là số lượng điểm ảnh dự đoán không phải vùng mạch máu gan và nằm trong phân vùng mạch máu gan ground truth. *FP* là số lượng điểm ảnh dự đoán chứa mạch máu gan và không nằm trong phân vùng mạch máu gan ground truth. *TN* là số lượng điểm ảnh dự đoán không chứa mạch máu gan và không nằm trong phân vùng mạch máu gan ground truth. Do nghiên cứu này tập trung đến ứng dụng trong RFA nên vùng tĩnh mạch chủ dưới (IVC) không sử dụng đánh giá trong nghiên cứu này.

1) Độ chính xác (*ACC*):

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \quad (4)$$

2) Độ nhạy (*SEN*):

$$SEN = \frac{TP}{TP + FN} \quad (5)$$

3) Độ đặc hiệu (*SPE*):

$$SPE = \frac{TN}{TN + FP} \quad (6)$$

4) Hệ số tương đồng Dice (*DSC*):

$$DSC = \frac{2 \times TP}{TP + FP + TN + FN} \quad (7)$$

D. Kết quả và thảo luận

Kết quả các chỉ số đánh giá phân vùng mạch máu gan của các kỹ thuật học sâu sử dụng trong bài báo được tổng hợp trong Bảng I. Phản đầu tiên, chúng tôi đánh giá trên các bộ dữ liệu nguồn mở (IRCADB, SLiver07, MSD8) và thấy rằng kỹ thuật 3D nn-UNet cho hiệu năng tốt nhất khi có chỉ số *DSC* trung bình là 81.6% tốt hơn các phương pháp còn lại. Về chỉ số *ACC* các phương pháp đều cho kết quả lớn hơn 96%, riêng với kỹ thuật MedT chỉ số này đạt trung bình 91.8% điều này kiến hiệu năng của MedT là thấp nhất so với các phương pháp khác. Chỉ số *SEN* với 3D ResUNet đạt giá trị cao nhất, tuy nhiên 3D ResUNet có xu hướng dự đoán nhãn với vùng bao phủ lớn hơn so với ground truth (xem Hình 3), vì vậy chỉ số *SPE* cho giá trị thấp kiến hiệu năng tổng thể giảm xuống. Swin-UNet chỉ cung

²<http://www.sliver07.org/>

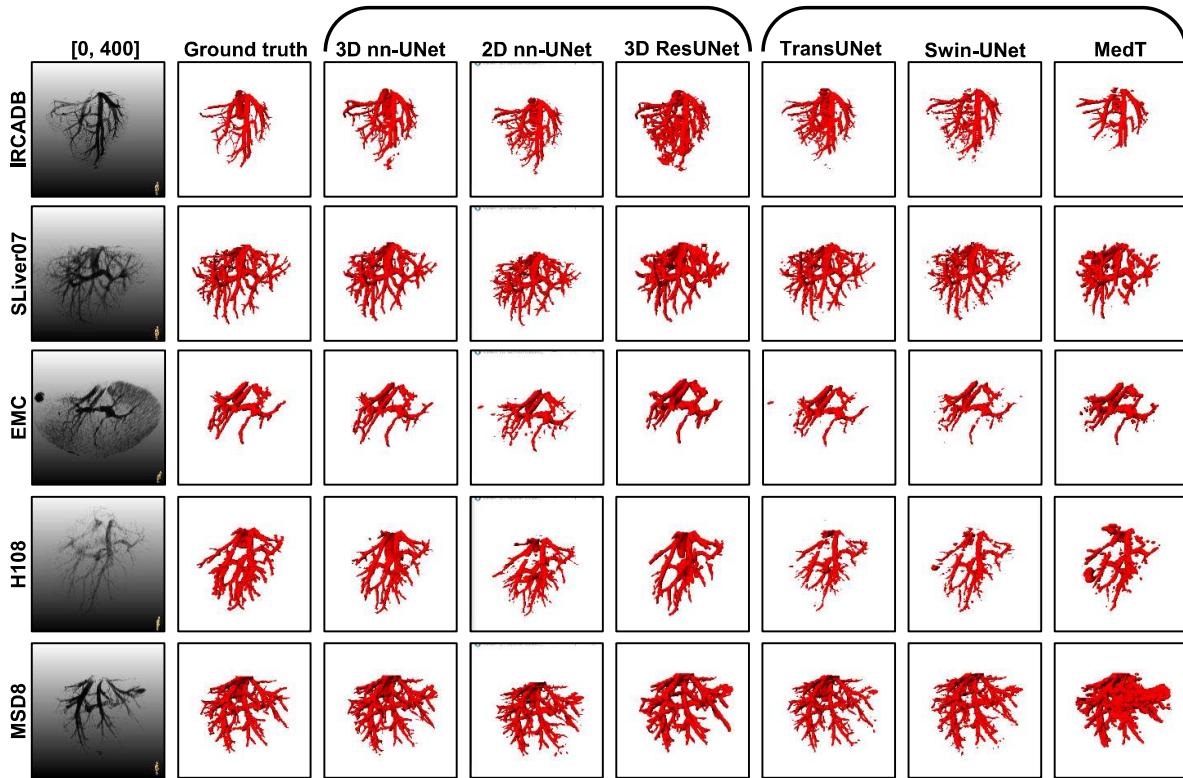
³<http://medicaldecathlon.com>

⁴<http://www.vmtk.org/>

Bảng I

GIÁ TRỊ TRUNG BÌNH VÀ ĐỘ LỆCH CHUẨN CỦA CHỈ SỐ ĐÁNH GIÁ PHÂN VÙNG MẠCH MÁU GAN (KHÔNG CHỨA IVC) CỦA CÁC KỸ THUẬT HỌC SÂU TRÊN BỘ DỮ LIỆU NGUỒN MỚI (IRCADB, SLIVER07, MSD8) VÀ BỘ DỮ LIỆU TỪ HAI CƠ SỞ Y TẾ (EMC, H108).

Phương pháp	IRCADB, SLiver07, MSD8				EMC, H108				Thời gian xử lý trung bình (s)
	ACC (%)	SEN (%)	SPE (%)	DSC (%)	ACC (%)	SEN (%)	SPE (%)	DSC (%)	
3D nn-UNet	98.2±0.5	84.3±6.7	99.0±0.6	81.6±6.1	98.5±0.5	77.7±8.0	99.4±0.2	81.2±6.2	68.5±18.4
3D ResUNet	96.5±0.9	89.4±7.2	96.9±1.1	71.0±9.0	97.5±1.0	68.9±18.8	98.6±1.1	68.0±11.7	3.9±1.7
2D nn-UNet	97.9±0.5	80.1±8.7	98.9±0.6	78.4±5.8	98.2±0.5	70.3±7.6	99.4±0.2	76.0±5.9	16.9±6.8
TransUNet	97.9±0.5	77.5±10.1	99.1±0.4	78.3±4.2	98.2±0.7	65.9±12.0	99.6±0.2	75.0±8.9	12.1±5.8
Swin-UNet	97.6±0.4	71.4±8.4	99.1±0.6	73.9±5.0	98.0±0.6	62.6±12.0	99.5±0.3	71.6±8.0	9.9±4.8
MedT	91.8±21.7	55.4±21.6	93.7±22.3	60.7±18.7	96.8±1.7	48.4±14.7	98.9±1.9	56.3±12.2	29.8±14.6



Hình 3. Ví dụ về kết quả phân vùng mạch máu gan trên năm bộ dữ liệu (IRCADB, SLiver07, EMC, H108 và MSD8). Cột đầu tiên hiển thị ảnh chụp CLVT sau khi giữ lại các điểm ảnh có giá trị trong khoảng [0, 400] và chỉnh độ tương phản hiển thị. Các cột kế tiếp thể hiện phân vùng mạch máu gan ground truth và phân vùng mạch máu gan dự đoán bởi các kỹ thuật học sâu sử dụng trong bài báo.

cấp mô hình pre-train cho kích thước ảnh 224x224 nên hiệu năng của kỹ thuật này cũng giảm xuống do vấn đề giảm mẫu (downsample) của ảnh đầu vào kiến kết quả dự đoán đầu ra bị ảnh hưởng bởi quá trình tăng mẫu (upsample) (xem Hình 3). Hai kỹ thuật 2D nn-UNet và TransUNet cho hiệu năng khá tương đồng với chỉ số DCS là 78%.

Tiếp theo, chúng tôi đánh giá trên bộ dữ liệu từ hai cơ sở y tế (EMC, H108) các kết quả nhận xét tương đồng với kết quả từ bộ dữ liệu nguồn mở. Tuy nhiên, ảnh chụp CLVT từ EMC và H108 sử dụng bức xạ liều

thấp và qua Bảng I thấy rằng hiệu năng của các kỹ thuật học sâu giảm xuống do ảnh hưởng của nhiễu sinh ra từ việc sử bức xạ liều thấp.

Về thời gian xử lý của các kỹ thuật học sâu, mặc dù có hiệu năng tốt nhất, 3D nn-UNet lại yêu cầu thời gian xử lý dài nhất với trung bình là 68.5 giây, quá trình thực thi thấy rằng 3D nn-UNet yêu cầu một bước tiền xử lý chiếm thời gian kiến tổng thời gian xử lý tăng lên. Trong việc lập kế hoạch điều trị bằng RFA vẫn đề giới hạn về thời gian không phải là một vấn đề nghiêm trọng, tuy nhiên quá trình phân vùng mạch máu kéo dài thời gian

tổng thể của việc lập kế hoạch cũng là một yếu tố cần được xem xét cân nhắc.

Bảng II
KẾT QUẢ PHÂN VÙNG MẠCH MÁU GAN LỚN (ĐƯỜNG KÍNH > 3 MM)
DÁNH GIÁ TRÊN BỘ DỮ LIỆU EMC.

Phương pháp	ACC (%)	SEN (%)	SPE (%)	DSC (%)
3D nn-UNet	92.3±5.1	80.6±11.1	97.4±1.5	86.0±8.2
3D ResUNet	83.6±1.8	68.0±16.8	90.6±2.3	68.3±16.5
2D nn-Unet	90.4±5.2	73.4±11.6	97.7±1.0	81.8±8.7
TransUNet	90.9±5.8	73.9±13.7	98.3±1.2	82.6±10.3
Swin-Unet	89.0±5.7	70.1±15.3	97.3±1.1	78.5±10.7
MedT	84.9±3.7	56.3±9.2	97.0±3.5	68.5±6.4

Bảng II hiển thị kết quả chỉ số đánh giá của các kỹ thuật học sâu trong vùng mạch máu gan lớn (đường kính > 3 mm) với ứng dụng lập kế hoạch điều trị bằng RFA. Chúng tôi đánh giá hiệu năng phân vùng mạch máu gan lớn bằng việc giới hạn lại vùng đánh giá được nêu tại mục III-D. Việc giới hạn lại vùng đánh giá khiến chỉ số ACC có sự giảm xu hướng so với Bảng I do số lượng điểm ảnh không chứa mạch máu gan trong vùng đánh giá giảm đáng kể, tuy nhiên chỉ số SPE không có sự suy giảm đáng kể điều này cho thấy rằng các kỹ thuật học sâu không dự đoán quá nhiều số lượng điểm ảnh FP tại vùng mạch máu gan lớn. So sánh đánh giá hiệu năng của các kỹ thuật học sâu với mạch máu gan lớn có sự tương đồng với đánh giá toàn bộ vùng gan.

V. KẾT LUẬN

Trong nghiên cứu này, chúng tôi đã đánh giá hiệu năng phân vùng mạch máu gan trong ảnh chụp CLVT của sáu kỹ thuật học sâu. Kết quả cho thấy rằng 3D nn-UNet cho hiệu năng tốt nhất trong tác vụ phân vùng mạch máu gan.Thêm vào đó, chúng tôi đánh giá hiệu năng phân vùng mạch máu gan lớn cho ứng dụng lập kế hoạch điều trị ung thư gan bằng RFA. Kết quả của nghiên cứu là tiền đề cho nghiên cứu áp dụng kỹ thuật học sâu vào quy trình lập kế hoạch điều trị ung thư gan bằng kỹ thuật RFA.

LỜI CẢM ƠN

Nghiên cứu này được tài trợ bởi Quỹ Phát triển khoa học và công nghệ Quốc gia (NAFOSTED) trong đê tài mã số 102.01-2018.316.

TÀI LIỆU THAM KHẢO

- [1] D. Selle, B. Preim, A. Schenk, and H.-O. Peitgen, “Analysis of vasculature for liver surgical planning,” *IEEE transactions on medical imaging*, vol. 21, no. 11, pp. 1344–1357, 2002.
- [2] A. Nazir, M. N. Cheema, B. Sheng, P. Li, J. Kim, and T.-Y. Lee, “Living donor-recipient pair matching for liver transplant via ternary tree representation with cascade incremental learning,” *IEEE Transactions on Biomedical Engineering*, 2021.
- [3] Q. Huang, J. Sun, H. Ding, X. Wang, and G. Wang, “Robust liver vessel extraction using 3d u-net with variant dice loss function,” *Computers in biology and medicine*, vol. 101, pp. 153–162, 2018.
- [4] A. Loriaud, A. Denys, O. Seror, N. Vietti Violi, A. Digkla, R. Duran, H. Trillaud, and A. Hocquelet, “Hepatocellular carcinoma abutting large vessels: comparison of four percutaneous ablation systems,” *International Journal of Hyperthermia*, vol. 34, no. 8, pp. 1171–1178, 2018.
- [5] T. Kitrungrotsakul, X.-H. Han, Y. Iwamoto, L. Lin, A. H. Foruzan, W. Xiong, and Y.-W. Chen, “Vesselnet: A deep convolutional neural network with multi pathways for robust hepatic vessel segmentation,” *Computerized Medical Imaging and Graphics*, vol. 75, pp. 74–83, 2019.
- [6] S. Survarachakan, E. Pelanis, Z. A. Khan, R. P. Kumar, B. Edwin, and F. Lindseth, “Effects of enhancement on deep learning based hepatic vessel segmentation,” *Electronics*, vol. 10, no. 10, p. 1165, 2021.
- [7] W. Yu, B. Fang, Y. Liu, M. Gao, S. Zheng, and Y. Wang, “Liver vessels segmentation based on 3d residual u-net,” in *2019 IEEE International Conference on Image Processing (ICIP)*. IEEE, 2019, pp. 250–254.
- [8] F. Isensee, P. F. Jaeger, S. A. Kohl, J. Petersen, and K. H. Maier-Hein, “nnu-net: a self-configuring method for deep learning-based biomedical image segmentation,” *Nature methods*, vol. 18, no. 2, pp. 203–211, 2021.
- [9] J. Chen, Y. Lu, Q. Yu, X. Luo, E. Adeli, Y. Wang, L. Lu, A. L. Yuille, and Y. Zhou, “Transunet: Transformers make strong encoders for medical image segmentation,” *arXiv preprint arXiv:2102.04306*, 2021.
- [10] H. Cao, Y. Wang, J. Chen, D. Jiang, X. Zhang, Q. Tian, and M. Wang, “Swin-unet: Unet-like pure transformer for medical image segmentation,” *arXiv preprint arXiv:2105.05537*, 2021.
- [11] J. M. J. Valanarasu, P. Oza, I. Hacihaliloglu, and V. M. Patel, “Medical transformer: Gated axial-attention for medical image segmentation,” *arXiv preprint arXiv:2102.10662*, 2021.
- [12] H. M. Luu, C. Klink, A. Moelker, W. Niessen, and T. Van Walsum, “Quantitative evaluation of noise reduction and vesseness filters for liver vessel segmentation on abdominal ct images,” *Physics in Medicine & Biology*, vol. 60, no. 10, p. 3905, 2015.
- [13] N. Sangsefidi, A. H. Foruzan, and A. Dolati, “Balancing the data term of graph-cuts algorithm to improve segmentation of hepatic vascular structures,” *Computers in biology and medicine*, vol. 93, pp. 117–126, 2018.
- [14] Y. Z. Zeng, Y. Q. Zhao, M. Liao, B. J. Zou, X. F. Wang, and W. Wang, “Liver vessel segmentation based on extreme learning machine,” *Physica Medica*, vol. 32, no. 5, pp. 709–716, 2016.
- [15] J. Su, Z. Liu, J. Zhang, V. S. Sheng, Y. Song, Y. Zhu, and Y. Liu, “Dv-net: Accurate liver vessel segmentation via dense connection model with d-bce loss function,” *Knowledge-Based Systems*, p. 107471, 2021.
- [16] C. Nguyen, Z. Asad, and Y. Huo, “Evaluating transformer based semantic segmentation networks for pathological image segmentation,” *arXiv preprint arXiv:2108.11993*, 2021.
- [17] C.-Y. Lin, Y.-C. Chiu, H.-F. Ng, T. K. Shih, and K.-H. Lin, “Global-and-local context network for semantic segmentation of street view images,” *Sensors*, vol. 20, no. 10, p. 2907, 2020.
- [18] H. S. Hoang, C. P. Pham, D. Franklin, T. van Walsum, and M. H. Luu, “An evaluation of cnn-based liver segmentation methods using multi-types of ct abdominal images from multiple medical centers,” in *2019 19th international symposium on communications and information technologies (ISCIT)*. IEEE, 2019, pp. 20–25.
- [19] M.-A. Lebre, A. Vacant, M. Grand-Brochier, H. Rositi, A. Abergel, P. Chabrot, and B. Magnin, “Automatic segmentation methods for liver and hepatic vessels from ct and mri volumes, applied to the couinaud scheme,” *Computers in biology and medicine*, vol. 110, pp. 42–51, 2019.
- [20] M. H. Son, M. H. Bang, S. Bae, D. T. Giang, N. T. Thinh, J. C. Paeng *et al.*, “Diagnostic and prognostic value of 99m tcm-aa spect/ct for treatment planning of 90 y-resin microsphere radioembolization for hepatocellular carcinoma: comparison with planar image,” *Scientific reports*, vol. 11, no. 1, pp. 1–9, 2021.
- [21] L. Liu, J. Tian, C. Zhong, Z. Shi, and F. Xu, “Robust hepatic vessels segmentation model based on noisy dataset,” in *Medical Imaging 2020: Computer-Aided Diagnosis*, vol. 11314. International Society for Optics and Photonics, 2020, p. 113140L.