

CHẨN ĐOÁN XUẤT HUYẾT NÃO DỰA TRÊN CHỈ SỐ HOUNSFIELD VÀ KỸ THUẬT MẠNG NƠON TÍCH CHẬP

Phan Anh Cang¹, Nguyễn Thị Mỹ Nga¹, Phan Thượng Cang²

¹ Khoa Công nghệ Thông tin, Trường Đại học Sư phạm Kỹ thuật Vĩnh Long

² Khoa Công nghệ Thông tin và Truyền thông, Trường Đại học Cần Thơ

cangpa@vlute.edu.vn, ngantm@vlute.edu.vn, ptcang@cit.ctu.edu.vn

TÓM TẮT: Trong những năm gần đây, xuất huyết não đang có xu hướng gia tăng nhanh chóng và là một trong những căn bệnh nguy hiểm đến tính mạng. Vì vậy, việc phát hiện và phân loại tự động các dạng xuất huyết não là rất cần thiết cho các bác sĩ điều trị. Trong bài báo này chúng tôi trình bày một cách tiếp cận mới sử dụng kỹ thuật mạng nơon tích chập (CNN) và chỉ số Hounsfields trong phân tích nhận dạng xuất huyết não từ các ảnh MRI. Phương pháp đề xuất gồm hai pha: phân loại xuất huyết não dựa trên CNN và xác định vùng xuất huyết cũng như cấp độ, thời gian xuất huyết dựa trên chỉ số Hounsfields. Phương pháp này hỗ trợ hiệu quả cho các bác sĩ chẩn đoán nguyên nhân gây ra xuất huyết, biết được vị trí, thời gian và mức độ nghiêm trọng của xuất huyết để có hướng dẫn điều trị bệnh nhân kịp thời.

Từ khóa: Xuất huyết não, mạng nơon tích chập, Hounsfields, ảnh CT/MRI.

I. TỔNG QUAN

Đột quy là một căn bệnh vô cùng nguy hiểm và là nguyên nhân gây tử vong lớn thứ ba cho con người. Theo thống kê của Hội tim mạch Toàn quốc năm 2016, tại Việt Nam, trong năm 2005 có 16 triệu bệnh nhân tai biến mạch máu não lần đầu trong đó 5,7 triệu bệnh nhân tử vong, trung bình cứ 5 giây thì có một trường hợp bệnh. Ở Mỹ mỗi 45 giây có một trường hợp đột quy não cấp. Trong đó bệnh đột quy được chia thành hai loại: đột quy do thiếu máu cục bộ chiếm 20% , đột quy do xuất huyết não chiếm 80% số trường hợp bệnh đột quy [1].

Vì tính chất nguy hiểm của xuất huyết não nên việc chẩn đoán bệnh cần được thực hiện nhanh chóng và chính xác. Não có cấu tạo khá phức tạp làm cho việc nhận biết các dấu hiệu bệnh lý gặp khó khăn. Do đó, một số bác sĩ thiếu kinh nghiệm dễ gặp sai sót trong quá trình phân tích một ảnh CT/MRI não. Bên cạnh đó, các bác sĩ thường làm việc trong môi trường căng thẳng cũng là lý do làm ảnh hưởng không tốt đến việc chẩn đoán xác định bệnh lý. Vì thế, một hệ thống máy tính hỗ trợ chẩn đoán xuất huyết não tự động từ các ảnh y khoa được xây dựng theo hướng tích hợp vào hệ thống chụp CT/MRI là cần thiết, góp phần giảm lỗi chẩn đoán do chủ quan, cũng như rút ngắn thời gian chẩn đoán để đạt được hiệu quả điều trị.

Đối với các hệ thống chẩn đoán xuất huyết não tự động dựa trên tập đặc trưng, các đặc trưng được rút trích chủ yếu dựa trên kinh nghiệm quan sát của các chuyên gia về đặc điểm riêng của các ảnh y khoa. Tuy nhiên, vấn đề thách thức của các phương pháp này đó là nghiên cứu xác định tập đặc trưng phù hợp để phân lớp xuất huyết. Để giải quyết vấn đề này, một số nghiên cứu gần đây [2], [3], [4], [5], [6] đề xuất sử dụng mô hình kiến trúc mạng nơon tích chập (Convolution Neural Network - CNN). Đây là một trong những mô hình học sâu (deep learning) tiên tiến. CNN là một mô hình mạng nơon nhân tạo giúp chúng ta có thể xây dựng được những hệ thống phân tích hình ảnh trực quan [2], phân đoạn, phân loại ảnh đạt được độ chính xác cao. Mặt khác, CNN có khả năng học một tập dữ liệu đầu vào đại diện mà không cần phân tích, rút trích bất kỳ tập đặc trưng nào. Hiện nay, một số hệ thống lớn như: Facebook, Google, Amazon đang sử dụng kỹ thuật CNN này để xử lý giọng nói, xử lý hình ảnh, nhận diện ảnh, nhận diện khuôn mặt, ... Đặc biệt, CNN được ứng dụng hiệu quả trong phân loại ảnh y khoa. Một số công trình nghiên cứu phát hiện và phân đoạn ảnh não ở trẻ sơ sinh và người lớn [3], [4], [5], [6] được đề xuất; các nghiên cứu đánh giá và thảo luận chi tiết về kỹ thuật CNN áp dụng cho việc phân tích ảnh CT/MRI não [7] [8]; nghiên cứu xác định xuất huyết nội sọ bằng ảnh chụp não cắt lớp [11]. Cụ thể, nhóm tác giả Jose Bernal et al. [7] nghiên cứu sử dụng mạng nơon tích chập để phân tích ảnh não trên hình ảnh CT/MRI. Phương pháp này gồm các bước chuẩn bị dữ liệu, tiền xử lý ảnh và áp dụng các tầng của CNN. Các hàm quan trọng như hàm Loss, hàm ReLU và các trọng số của mô hình được trình bày. Kỹ thuật CNN giúp việc phân tích ảnh nhanh hơn các hệ thống truyền thống, tuy nhiên để học hiệu quả thì nó cần có một tập dữ liệu lớn và hệ thống được thực thi trên máy tính xử lý đồ họa mạnh (Graphics Processing Unit - GPU). Mina Rezaei et al. [8] đề xuất phương pháp phát hiện não bất thường bằng mô hình mạng CNN để phát hiện bệnh Glioma nặng, Glioma nhẹ, bệnh đa xơ cứng, bệnh Alzheimer. Kiến trúc mạng CNN đề xuất gồm mười tầng với bảy tầng tích chập và ba tầng kết nối đầy đủ. Bên cạnh đó, Mohammad et al. [11] trình bày phương pháp xác định xuất huyết nội sọ bằng kiến trúc CNN sử dụng năm tầng tích chập, hai tầng kết nối đầy đủ và các tầng tổng hợp bằng hàm Max Pooling. Nhìn chung, các phương pháp này sử dụng kỹ thuật CNN để phân lớp ảnh y khoa. Tuy nhiên, chất lượng hình ảnh có ảnh hưởng đến việc phân lớp nên các tác giả đề xuất giai đoạn tiền xử lý ảnh thậm chí phân tích trên ảnh JPEG. Điều này sẽ làm mất mát thông tin được lưu trên ảnh trong quá trình xử lý và ảnh hưởng kết quả phân tích. Ngoài ra, kỹ thuật CNN có thể không cho kết quả chính xác vùng xuất huyết não cũng như không cung cấp thông tin về thời gian xuất huyết để hỗ trợ các bác sĩ có phác đồ điều trị kịp thời.


Từ những hạn chế trên, chúng tôi đề xuất một phương pháp gồm hai pha chính: pha thứ nhất là nhận dạng tự động các loại xuất huyết não nhờ khả năng học, ghi nhớ và khái quát hóa các mẫu dữ liệu huấn luyện dựa trên CNN; pha thứ hai, chúng tôi xác định vùng xuất huyết và thời gian xuất huyết giúp các bác sĩ có phác đồ điều trị bệnh kịp thời dựa trên chỉ số Hounsfield Unit (HU) mà các bác sĩ chuyên khoa thường dùng để đọc ảnh CT/MRI não. Đây cũng chính là một hướng tiếp cận mới được đề xuất trong phương pháp của chúng tôi. Trong bài báo này chúng tôi tập trung nghiên cứu bốn loại xuất huyết não phổ biến: tụ máu ngoài màng cứng, tụ máu dưới màng cứng, xuất huyết dưới nhện, xuất huyết trong não.

II. CÁC CÔNG VIỆC LIÊN QUAN

Để nhận dạng tự động các loại xuất huyết não và xác định vùng xuất huyết, trong nghiên cứu này chúng tôi thực hiện hai pha. Pha đầu tiên, chúng tôi sử dụng kỹ thuật mạng nơ-ron tích chập để phân lớp gồm hai bước: huấn luyện và kiểm tra. Pha thứ hai, chúng tôi tính toán chỉ số HU để phân vùng và xác định thời gian xuất huyết não. Sau đây là mô tả chi tiết các công việc liên quan sử dụng trong phương pháp đề xuất của chúng tôi.

A. Kỹ thuật Deep learning

Deep Learning là một kỹ thuật máy học giúp cho trí tuệ nhân tạo được sánh với trí tuệ con người. Deep Learning cấu tạo từ các mạng nơ-ron, trong đó mạng nơ-ron gồm nhiều tầng (thường là từ 10 đến 100 tầng). Để mạng nơ-ron hoạt động hiệu quả khi dữ liệu học lớn, mô hình mạng lớn, khả năng tính toán của máy tính tốt [10].




Hình 1. Mô hình của kỹ thuật Deep Learning [10]

Hình 1 mô tả kỹ thuật Deep Learning gồm có ba tầng chính là: tầng đầu vào, tầng ẩn và tầng đầu ra. Trong đó, tầng đầu vào là tầng chứa các ảnh đầu vào, tầng ẩn là tầng rút trích các đặc trưng của các ảnh đầu vào. Dựa vào các đặc trưng đã rút trích, tầng đầu ra phân lớp và gán nhãn kết quả. Tầng này có mục đích là phân loại các ảnh đầu vào, gán nhãn cho ảnh.

B. Mạng nơ-ron tích chập (CNN)

CNN là một trong những kỹ thuật tiên tiến của Deep Learning. So với những mô hình mạng nơ-ron truyền thống, CNN sử dụng ít tham số hơn [2]. Mô hình CNN cũng có cấu trúc tương tự mô hình Deep Learning. Hình 2 biểu diễn cho chúng ta thấy rõ chi tiết về mô hình CNN.



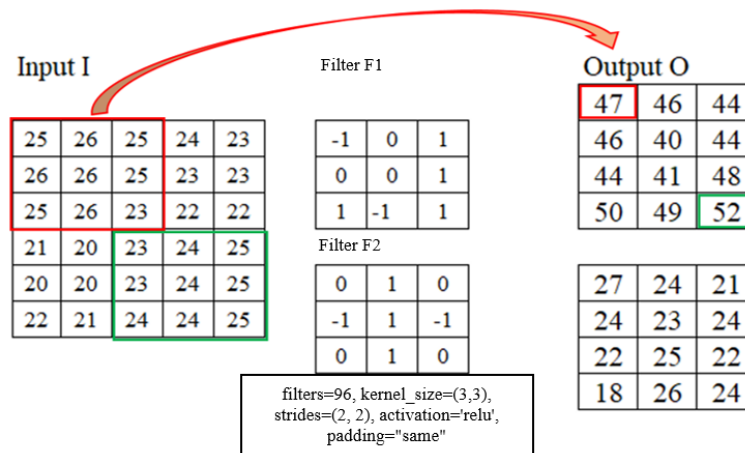
Hình 2. Kiến trúc mạng CNN

Từ hình 2, cho thấy kiến trúc của mạng CNN gồm ba tầng chính: tầng tích chập (Convolution layer), tầng tổng hợp (Pooling layer), tầng kết nối đầy đủ (Fully Connected layer). Bước đầu tiên là ảnh đầu vào được đưa qua tầng tích chập. Sau mỗi tầng tích chập là tầng tổng hợp, tầng tích chập với nhiệm vụ trích đặc trưng ảnh, còn tầng tổng hợp sẽ có

nhệm vụ giảm những đặc trưng không cần thiết nhằm làm giảm kích thước bản đồ đặc trưng (feature map). Sau hai loại tầng này là tầng kết nối đầy đủ, khác với hai loại tầng trước, tầng kết nối đầy đủ là một bản đồ đã được làm phẳng. Sự làm phẳng này với mục đích tạo sự kết nối duy nhất từ một neuron của tầng trước đến một neuron của tầng tiếp theo. Như vậy, ở tầng kết nối đầy đủ cuối cùng, neuron sẽ được kết nối đến duy nhất một neuron có nhân hợp lý ở tầng đầu ra. Chúng tôi trình bày chi tiết về các tầng của CNN trong các nội dung tiếp theo.

1. Tầng tích chập

Mục đích của tầng tích chập là trích xuất đặc trưng của ảnh bằng cách sử dụng phép toán tích chập. Cách thức thực hiện là cho một bộ lọc trượt trên ma trận ảnh đầu vào để tạo ra bản đồ đặc trưng. Các bộ lọc khác nhau sẽ tạo ra các bản đồ đặc trưng khác nhau. Mỗi bộ lọc là một ma trận trượt theo chiều rộng và chiều cao của ma trận ảnh và được mở rộng thông qua chiều sâu. Với ảnh màu chiều sâu của ảnh bằng 3, còn ảnh mức xám chiều sâu ảnh bằng 1. Bên cạnh đó, CNN sử dụng cấu trúc một hoặc nhiều tầng liên kết với nhau, trong đó tầng thứ nhất trích xuất các đặc trưng đơn giản, các tầng sau đó các đặc trưng được trích xuất phức tạp hơn. Sau đây là ví dụ minh họa tạo ra bản đồ đặc trưng tại tầng tích chập:




Hình 3. Tầng tích chập

Trong hình 3, Filter là số lượng bộ lọc, kernel_size là kích thước bộ lọc, strides là số bước nhảy, activation là hàm kích hoạt và padding là kiểu đệm. Một ảnh đầu vào có thể qua nhiều bộ lọc trong một tầng tích chập. Chẳng hạn trong hình 3, ảnh I qua hai bộ lọc F1 và F2, với mỗi bộ lọc sẽ tạo ra một bản đồ 2 chiều riêng biệt, tiếp theo các bản đồ khác sẽ được chồng lên nhau theo chiều sâu và tạo bản đồ đặc trưng đầu ra cho tầng hiện tại. Tuy nhiên, bản đồ đặc trưng được tạo ra ở tầng này có số lượng khá lớn, có thể chứa những đặc trưng dư thừa không cần thiết cho quá trình gán nhãn ảnh làm tốn thời gian học và phân lớp. Để giải quyết hạn chế này, chúng ta sử dụng tầng tổng hợp để giảm những đặc trưng không cần thiết như trình bày trong phần 2.

2. Tầng tổng hợp

Mục đích của tầng tổng hợp là giảm số lượng đặc trưng từ tầng tích chập để làm rõ các đặc trưng của ảnh. Với mỗi tầng tích chập, chúng tôi sẽ sử dụng một tầng tổng hợp. Có ba hàm được giới thiệu: Max Pooling, Average Pooling và Min Pooling. Hàm Max Pooling thường được sử dụng hơn do hiệu suất thực nghiệm của hàm này là cao hơn hai hàm còn lại [13], [14].




Kernel_size: kích thước cửa sổ trượt, stride: số bước nhảy

Hình 4. Tầng tổng hợp

3. Tầng kết nối đầy đủ

Sau khi đã giảm những đặc trưng không cần thiết, bản đồ đặc trưng lúc này đã chứa đầy đủ thông tin cần thiết để phân lớp ảnh. Đó là nhiệm vụ của tầng kết nối đầy đủ, đầu ra của tầng này là các nhân dự đoán [15].



Hình 5. Tầng kết nối đầy đủ

Theo hình 5, tầng kết nối này gồm hai bước: Bước 1 sẽ làm phẳng các bản đồ đặc trưng của tầng ngay trước đó để đạt được dạng vectơ đặc trưng một chiều. Bước 2: mỗi nút của vectơ gán nhãn sẽ được kết nối trực tiếp tới một nút trong tầng ngay trước đó.

Sau khi đã xác định được loại xuất huyết, cần làm nổi bật vùng xuất huyết đó trên ảnh, giúp các bác sĩ dễ dàng nhận ra vị trí xuất huyết cũng như thời gian xuất huyết. Để làm điều này, chúng tôi xác định các giá trị Hounsfield Unit.

C. Xác định giá trị Hounsfields

Chúng tôi phân tích dữ liệu trực tiếp trên các ảnh MRI đầu vào theo định dạng chuẩn Dicom mà không chuyển sang định dạng JPG, BMP, PNG,... Các ảnh đầu vào này bao gồm các thông tin như: họ và tên, mã ID, các dữ liệu của hình ảnh và các giá trị HU. Chúng tôi sử dụng giá trị HU này với mục đích xác định vùng xuất huyết và thời gian xuất huyết não.

Giá trị của HU được xác định dựa trên phép biến đổi tuyến tính với công thức như sau [9]:

$$HU = \text{pixel_value} * \text{RescaleSlope} + \text{RescaleIntercept}$$


Trong đó, **pixel_value** là giá trị từng điểm ảnh, các giá trị **RescaleSlope** và **RescaleIntercept** là các giá trị lưu trữ trong ảnh CT/MRI chuẩn Dicom.

D. Phân đoạn ảnh dựa vào HU để xác định vùng xuất huyết não

Để xác định vùng xuất huyết não, chúng tôi sử dụng kỹ thuật phân đoạn ảnh dựa vào các giá trị HU như trình bày trong bảng 1.

Bảng 1. Mức độ hấp thụ tia X trên ảnh CT/MRI bằng đơn vị Hounsfield [9]

| Độ hấp thụ tia X được đo trên ảnh CT/MRI bằng đơn vị Hounsfield (HU) | |
|--|------------|
| Nước | 0 HU |
| Xương | 1.000 HU |
| Không khí | -1.000 HU |
| Chất xám | 35 - 40 HU |
| Chất trắng | 20 HU |
| Xuất huyết | 40 - 90 HU |
| Vôi hóa | > 120 HU |



Hình 6. Xác định vùng xuất huyết não với kỹ thuật phân đoạn ảnh dựa vào các giá trị HU

Như đã thấy ở bảng 1, các vùng có chỉ số HU từ 40 - 90 chính là vùng xuất huyết não. Dựa vào chỉ số HU, chúng ta sẽ xác định được vùng xuất huyết như biểu diễn trong hình 6.

E. Phân đoạn ảnh dựa vào phương pháp Otsu's

F. Xác định thời gian xuất huyết não

Ngoài việc xác định vùng xuất huyết, các bác sĩ cũng cần biết thông tin quan trọng khác đó là thời gian xuất huyết để kịp thời chữa trị. Thời gian xuất huyết não được chia thành các cấp: cấp tính, bán tính, mãn tính.

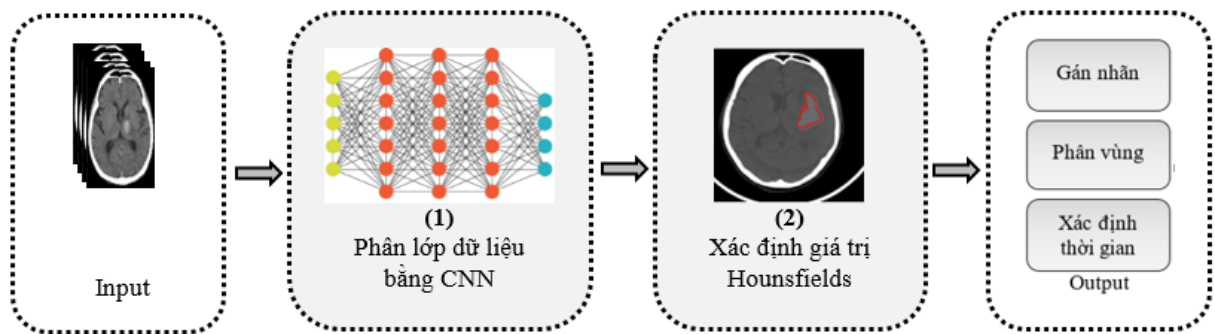
Bảng 2. Thời gian xuất huyết não dựa vào chỉ số HU

| Cấp độ xuất huyết | Chỉ số HU | Thời gian bệnh (ngày) |
|-------------------|-----------|-----------------------|
| Cấp tính | 50 - 60 | 1 - 3 |
| Bán tính | < 40 | 3 - 14 |
| Mãn tính | 18 - 30 | 14 - 21 |

Dựa vào các nghiên cứu liên quan như đã trình bày ở trên, chúng tôi đề xuất phương pháp chẩn đoán xuất huyết não được mô tả chi tiết ở phần III.


III. PHƯƠNG PHÁP ĐỀ XUẤT

Hệ thống được xây gồm 2 pha: pha 1 thực hiện phân lớp ảnh MRI để gán nhãn loại xuất huyết, pha 2 thực hiện phân vùng ảnh dựa vào HU để xác định vùng xuất huyết và thời gian xuất huyết. Mô hình của phương pháp đề xuất được biểu diễn trong hình 7.

**Hình 7.** Mô hình chẩn đoán xuất huyết não của phương pháp đề xuất

Theo hình 7, ảnh đầu sẽ được đưa vào hệ thống xử lý bởi hai pha: pha 1 thực hiện phân lớp dữ liệu bằng kỹ thuật CNN, pha 2 thực hiện phân vùng ảnh dựa vào HU để xác định vùng xuất huyết và thời gian xuất huyết. Sau đây chúng tôi trình bày chi tiết về hai pha này.

A. Pha 1: Phân lớp ảnh với kỹ thuật CNN

**Hình 8.** Phân lớp dữ liệu bằng kỹ thuật CNN

Mô hình của pha này gồm các tầng tích chập, tầng tổng hợp, tầng kết nối đầy đủ như biểu diễn trong hình 8. Pha này bao gồm 2 bước: bước 1 học các đặc trưng của ảnh, bước 2 phân lớp ảnh xuất huyết dựa trên các đặc trưng đã học.

1. Học tập đặc trưng

a) Xây dựng tầng tích chập

Trong phương pháp của chúng tôi, mô hình của pha này sử dụng 5 tầng tích chập vì nó để đạt được kết quả gán nhãn với độ chính xác cao thông qua các kết quả thử nghiệm mà không mất nhiều thời gian để học. Trong các tầng tích chập, chúng tôi sử dụng hàm biến đổi phi tuyến tính ReLU biến đổi dữ liệu theo công thức sau:

$$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (1)$$

b) Xây dựng tầng tổng hợp

Sau khi dữ liệu được xử lý bởi tầng tích chập, chúng tôi chọn áp dụng một số tầng tổng hợp với hàm chọn cho tầng này là Max Pooling vì nó được sử dụng phổ biến trong các ứng dụng xử lý ảnh y khoa. Chúng tôi sử dụng bộ lọc (2x2) giúp tầng này giảm đáng kể kích thước không gian của đầu vào. Công việc này nhằm mục đích giảm số lượng thông số

hoặc trọng số để giảm chi phí tính toán, đồng thời làm nổi bật các đặc trưng quan trọng cần thiết cho việc phân lớp hình ảnh.

2. Giai đoạn 2: Phân lớp

Để phân lớp thì tầng kết nối đầy đủ gồm 2 tầng: tầng dày đặc (Dense) và tầng bỏ học (Dropout).

a) Tầng dày đặc:

Tầng này thực hiện kết nối mỗi tầng với tầng khác theo kiểu chuyển tiếp. Đối với mỗi tầng, bản đồ đặc trưng của tầng trước được sử dụng làm đầu vào cho tầng sau. Tầng dày đặc có lợi thế là tăng cường các đặc trưng mạnh, giảm gradient, khuyến khích sử dụng lại các đặc trưng và làm giảm đáng kể số lượng tham số [12]. Tầng này có hai hàm đó là ReLU và Softmax, trong đó hàm ReLU sẽ chuyển đổi những giá trị âm thành 0, hàm Softmax thường là hàm phi tuyến dùng để phân loại ảnh.

b) Tầng bỏ học:

Trong tầng này, một số số lượng dữ liệu được bỏ qua ngẫu nhiên từ các lớp ẩn trong quá trình học. Điều này giúp phá vỡ các phụ thuộc hiểm hoi có thể xảy ra trong dữ liệu học. Bỏ học là cách tiếp cận để bình thường hóa trong các mạng CNN giúp giảm sự học phụ thuộc lẫn nhau giữa các nơon.

Kết quả của tầng kết nối đầy đủ là gán nhãn phân loại cho ảnh thuộc một trong bốn loại xuất huyết não: tụ máu ngoài màng cứng, tụ máu dưới màng cứng, xuất huyết dưới nhện, xuất huyết trong não.

B. Pha 2: Phân vùng và xác định thời gian xuất huyết dựa trên chỉ số HU

Như đã trình bày ở pha 1, ảnh não đã được gán nhãn loại xuất huyết. Tuy nhiên, bác sĩ cần biết những thông tin quan trọng khác đó là vùng xuất huyết và thời gian xuất huyết để có phát đồ điều trị kịp thời. Vì vậy, chúng tôi đề xuất pha 2 để tính toán các giá trị HU để phân vùng và xác định thời gian xuất huyết não.

Kết thúc giai đoạn 1, ảnh đã được gán nhãn xuất huyết theo bốn loại máu tụ ngoài màng cứng, máu tụ dưới màng cứng, xuất huyết dưới nhện, xuất huyết nội sọ. Để xác định vùng và thời gian xuất huyết não, chúng tôi đề xuất sử dụng kỹ thuật phân vùng dựa vào chỉ số HU như đã trình bày ở phần D và E.

IV. KẾT QUẢ

Chúng tôi thực nghiệm trên tập dữ liệu 138 ảnh MRI về sọ não theo chuẩn Dicom của các bệnh nhân được thu thập từ bệnh viện Trường Đại học Y Dược Cần Thơ. Vấn đề quan trọng hàng đầu của các phương pháp này là tập dữ liệu huấn luyện. Nó được sử dụng để phục vụ quá trình học, tính toán các tham số, huấn luyện và tinh chỉnh mô hình. Chúng tôi xây dựng hệ thống tương tác với các chuyên gia, bác sĩ chuyên ngành của bệnh viện để hình thành tập dữ liệu huấn luyện và được gán nhãn trước. Vì vậy, tập dữ liệu huấn luyện được gán nhãn từ ý kiến của các chuyên gia và bác sĩ chuyên ngành. Tập dữ liệu này gồm 138 ảnh cụ thể như sau:

Bảng 3. Tập dữ liệu ảnh MRI theo chuẩn Dicom về sọ não

| Phân loại | Số lượng |
|------------------------|----------|
| Máu tụ ngoài màng cứng | 18 |
| Máu tụ dưới màng cứng | 23 |
| Xuất huyết dưới nhện | 12 |
| Xuất huyết nội sọ | 85 |

Với tập dữ liệu này, chúng tôi chọn ngẫu nhiên 70% ảnh để huấn luyện và 30% ảnh cho quá trình kiểm tra. Số lần mạng được huấn luyện là 100 lần. Hệ thống của chúng tôi được cài đặt bằng ngôn ngữ Python và chạy trên máy tính có bộ xử lý đồ họa Graphic Processing Unit (GPU). Sau đây là một số kết quả kiểm tra thực nghiệm đạt được từ phương pháp đề xuất.


1. Phân lớp ảnh xuất huyết não áp dụng phương pháp đề xuất với số lượng các tầng khác nhau

Để đạt được kết quả thực nghiệm trên, chúng tôi đã kiểm thử mô hình với số các tầng khác nhau. Sau đây là so sánh kết quả đạt được khi sử dụng số lượng tầng khác nhau trong mô hình.



Hình 9. Kết quả thực nghiệm khi thay đổi số tầng của mô hình CNN

Trong hình 9, số lượng tầng biểu diễn trên trục hoành của đồ thị, trục tung thể hiện độ chính xác (%) phân lớp tương ứng với số tầng đó. Từ hình 9 chúng ta có thể thấy mỗi lần thực nghiệm thay đổi số tầng khác nhau của mô hình thì kết quả phân lớp cũng thay đổi. Chẳng hạn, trường hợp 7 tầng tích chập, 7 tầng tổng hợp, 2 tầng Dense và 1 tầng Dropout cho kết quả phân lớp với độ chính xác 100% đối với tập huấn luyện và 89.9% đối với tập kiểm tra. Từ kết quả thực nghiệm, chúng tôi dừng thực nghiệm ở mô hình với số lượng 8 tầng tích chập vì số lượng tầng càng lớn sẽ tốn nhiều thời gian huấn luyện hơn nhưng kết quả về độ chính xác phân lớp không tăng như biểu diễn trong biểu đồ hình 11.



Hình 10. Thời gian thực nghiệm khi thay đổi số lớp của mô hình CNN

Theo hình 10, trục hoành thể hiện số tầng của mô hình. Tương ứng với mỗi giá trị trên trục hoành, thời gian huấn luyện (tính bằng đơn vị giây) được thể hiện trên trục tung. Chúng ta thấy từ mô hình với 7 tầng tích chập, 7 tầng tổng hợp trở về sau thì thời gian thực hiện tăng nhanh và lớn hơn các mô hình trước đó với số tầng thấp hơn trong khi độ chính xác phân lớp có thể như nhau. Vì vậy, chúng tôi chọn mô hình đề xuất với 5 tầng tích chập, 5 tầng tổng hợp, 2 tầng dày đặc và 1 tầng bỏ học.



Hình 11. Kết quả thực nghiệm

Hình 11 biểu diễn độ chính xác phân lớp với 100 lần huấn luyện mạng nơon (chia tập dữ liệu với tỉ lệ 70% học, 30% kiểm tra). Nếu số lần học quá thấp, thì độ chính xác phân lớp ảnh xuất huyết não thấp. Độ chính xác bắt đầu tăng dần và ổn định từ giá trị 80 đến 100 lần học. Vì vậy, chúng tôi ngừng huấn luyện tại lần học thứ 100. Từ các kết quả trình bày trong hình 9, 10, 11, chúng tôi đề xuất mô hình thực nghiệm với 5 tầng tích chập, 5 tầng tổng hợp, 2 tầng Dense và 1 tầng Dropout.


2. Xác định vùng và thời gian xuất huyết não

Sau khi đã xác định đúng loại xuất huyết não, phương pháp đề xuất của chúng tôi sẽ xác định rõ vùng và thời gian xuất huyết não trên ảnh giúp các bác sĩ dễ dàng tập trung vào vùng xuất huyết để điều trị. Chúng tôi đã so sánh các phương pháp phân vùng và có kết quả như hình 12, 13 và 14.




a) Máu tụ ngoài màng cứng b) Máu tụ dưới màng cứng c) Xuất huyết dưới nhện d) Xuất huyết nội sọ

Hình 12. Kết quả phân loại xuất huyết não dựa trên HU của phương pháp đề xuất



Hình 13. Kết quả phân vùng xuất huyết dùng thuật toán FBB (fast bounding box) [16]

Một số phương pháp phân vùng dựa trên kỹ thuật Deep Learning [16] và ngưỡng mức xám của các pixel ảnh (thuật toán Otsu và Otsu cải tiến [17], [18]) cho kết quả phân vùng xuất huyết não chưa chính xác so với thuật toán đề xuất của chúng tôi dựa trên các giá trị HU như biểu diễn hình 12 và 13. Hình 13 cho thấy vùng xuất huyết được xác định bởi vùng khoanh chữ nhật trong khi phương pháp của chúng tôi xác định chính xác vùng xuất huyết. Đây là vùng có các chỉ số HU từ 40 - 90. Hơn nữa, các giá trị HU còn được sử dụng để xác định thời gian xuất huyết não trong phương pháp đề xuất của chúng tôi. Hình 14 biểu diễn vùng xuất huyết não xảy ra trong thời gian từ 1-3 ngày vì HU có giá trị từ 50 - 60.



Hình 14. Xác định thời gian xuất huyết trong phương pháp đề xuất

V. KẾT LUẬN

Trong nghiên cứu này, chúng tôi đề xuất một hướng tiếp cận mới dựa trên kỹ thuật mạng nơon tích chập để phân loại xuất huyết não và các giá trị HU được các bác sĩ chuyên khoa thường sử dụng để phân vùng xuất huyết, đồng thời xác định thời gian xuất huyết và cấp độ bệnh. Phương pháp đề xuất của chúng tôi không chỉ phân loại xuất huyết não mà còn xác định vùng, cấp độ và thời gian xuất huyết nhằm hỗ trợ hiệu quả cho các bác sĩ trong điều trị bệnh nhân. Kết quả thực nghiệm của mô hình cho thấy, độ chính xác phân loại đạt kết quả 89.9% và xác định chính xác vùng xuất huyết não. Tuy nhiên, nghiên cứu của chúng tôi còn hạn chế với số lượng tập dữ liệu nhỏ, chưa so sánh đánh giá phương pháp đề xuất với các phương pháp nghiên cứu khác. Đây sẽ là những hướng nghiên cứu phát triển tiếp theo của chúng tôi.

VI. TÀI LIỆU THAM KHẢO

- [1] Nguyễn Văn Chi, “Cập nhật về chẩn đoán và xử trí đột quy não cấp”, Hội nghị Tim mạch Toàn quốc, 2016.
- [2] Lectures of Stanford University, “Introduction to Convolutional Neural Networks”, 2018.
- [3] S. González-Villà, A. Oliver, S. Valverde, L. Wang, R. Zwigelaar, X. Lladó, “A review on brain structures segmentation in magnetic resonance imaging”, *Artificial Intelligence in Medicine* 73, 2016, pp. 45-69.
- [4] J. Mitra, P. Bourgeat, J. Fripp, S. Ghose, S. Rose, O. Salvado, A. Connelly, B. Campbell, S. Palmer, G. Sharma, et al., “Lesion segmentation from multimodal CT/MRI using random forest following ischemic stroke”, *Neuroimage* 98, 2014, pp. 324-335.
- [5] E. Roura, A. Oliver, M. Cabezas, S. Valverde, D. Pareto, J. C. Vilanova, L. Ramió-Torrentà, À. Rovira, X. Lladó, “A toolbox for multiple sclerosis lesion segmentation”, *Neuroradiology* 57 (10), 2015, pp. 1031-1043.
- [6] K.-k. Shen, J. Fripp, F. Mériaudeau, G. Chételat, O. Salvado, P. Bourgeat, A. D. N. Initiative, et al., “Detecting global and local hippocampal shape changes in Alzheimer’s disease using statistical shape models”, *Neuroimage* 59 (3), 2012, pp. 2155-2166.
- [7] Jose Bernal, Kaisar Kushibar, Daniel S. Asfaw, Sergi Valverde, Arnau Oliver, Robert Mart, Xavier Llado, “Deep convolutional neural networks for brain image analysis on magnetic resonance imaging: a review”, Computer Vision and Robotics Institute Dept. of Computer Architecture and Technology University of Girona, 2017.
- [8] Mina Rezaei, Haojin Yang, Christoph Meinel, “Brain Abnormality Detection by Deep Convolutional Neural Network”, 2017.
- [9] Phan Anh Cang, Phan Thượng Cang, Võ Văn Quyền, Lê Thị Hoàng Yến, “Phát hiện và phân loại tự động xuất huyết não trên các ảnh CT/MRI”, Hội thảo quốc gia lần thứ XX: Một số vấn đề chọn lọc của Công nghệ thông tin và truyền thông, 2017.
- [10] <https://blog.algorithmia.com/introduction-to-deep-learning/>
- [11] Mohammad R. Arbabshirani, Brandon K. Fornwalt, Gino J. Mongelluzzo, Jonathan D. Suever, Brandon D. Geise, Aalpen A. Patel & Gregory J. Moore, “Advanced machine learning in action: identification of intracranial hemorrhage on computed tomography scans of the head with clinical workflow integration”, 2018.
- [12] Gao Huang, Zhuang Liu, Laurens van der Maaten, “Densely Connected Convolutional Networks”, This CVPR paper is the Open Access version, provided by the Computer Vision Foundation. Except for this watermark, it is identical to the version available on IEEE Xplore, 28/01/2018, pp. 4700-4708.
- [13] Y.-L. Boureau, F. Bach, Y. LeCun, J. Ponce, “Learning mid-level features for recognition”, in: 2010 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2010, pp. 2559-2566.
- [14] Y.-L. Boureau, J. Ponce, Y. LeCun, “A theoretical analysis of feature pooling in visual recognition”, in: Proceedings of the 27th international conference on machine learning (ICML-10), 2010, pp. 111-118.
- [15] A. Krizhevsky, I. Sutskever, G. E. Hinton, “Imagenet classification with deep convolutional neural networks”, in: Advances in neural information processing systems, 2012, pp. 1097-1105.
- [16] Sacid Fazli, Parisa Nadirkhanlou, “A Novel Method for Automatic Segmentation of Brain Tumors in MRI Images”, 2013.
- [17] Wei Shang, Yan-Fen Cheng, “An improved OTSU method based on Genetic Algorithm”, 4th International Conference on Machinery, Materials and Information Technology Applications (ICMMITA), 2016, pp. 1656-1661.
- [18] Abhishek Thakur, Rajesh Kumar, Amandeep Bath, Jitender Sharma, “Improved Segmentation Technique for Enhancement of Biomedical Images”, *IJEEE*, Vol. 1, Spl. Issue 1, e-ISSN: 1694-2310, 2014, pp.4-10.

DIAGNOSIS OF BRAIN HEMORRHAGE BASED ON HOUNSFIELD VALUES AND CONVOLUTION NEURAL NETWORK TECHNIQUE

Phan Anh Cang, Nguyen Thi My Nga, Phan Thuong Cang

ABSTRACT: *In recent years, brain hemorrhage tends to increase rapidly and is one of the most dangerous for our life. Thus, the automatic detection and classification of brain hemorrhage are essential for doctors to treat. In this paper we present a new approach using convolution neural network technique and Hounsfield values for analyzing brain hemorrhage from CT/MRI images. Our method is effective for doctors in recognizing brain hemorrhage, diagnosing the location, time and severity of brain hemorrhage for prompt patient treatment.*