BỘ CÔNG THƯƠNG

TRƯỜNG ĐẠI HỌC CÔNG NGHIỆP THÀNH PHỐ HỒ CHÍ MINH



LÊ NHỊ LÃM THUÝ

TRÍCH XUẤT MẠCH VÀNH VÀ PHÁT HIỆN BẤT THƯỜNG TRÊN MẠCH VÀNH HỖ TRỢ TRONG CHẨN ĐOÁN

LUẬN ÁN TIẾN SĨ

THÀNH PHỐ HỒ CHÍ MINH, NĂM 2024

BỘ CÔNG THƯƠNG
TRƯỜNG ĐẠI HỌC CÔNG NGHIỆP THÀNH PHỐ HỒ CHÍ MINH

LÊ NHỊ LÃM THUÝ

TRÍCH XUẤT MẠCH VÀNH VÀ PHÁT HIỆN BẤT THƯỜNG TRÊN MẠCH VÀNH HỖ TRỢ TRONG CHẨN ĐOÁN

Ngành: Khoa học máy tính
Mã số ngành: 9480101

Chủ tịch: GS.TS. Phan Thị Tươi (Trường ĐH Nguyễn Tất Thành)
Phản biện 1: PGS.TS. Nguyễn Thị Thúy Loan (Trường ĐH Quốc Tế, ĐHQG TP.HCM)
Phản biện 2: PGS.TS. Đỗ Văn Nhơn (Trường ĐH Quốc tế Hồng Bàng)
Phản biện 3: TS. Nguyễn Viết Hưng (Trường ĐH Sư Phạm TP.HCM)
Ủy viên: PGS.TS. Lê Hoàng Thái (Trường ĐH Khoa học Tự Nhiên, ĐHQG TP.HCM)
Ủy viên: TS. Lê Trọng Ngọc (Trường Đại học Công nghiệp TP.HCM)
Thư ký: PGS.TS. Huỳnh Tường Nguyên (Trường Đại học Công nghiệp TP.HCM

NGƯỜI HƯỚNG DẪN:
1. PGS.TS. Phạm Thế Bảo
2. PGS.TS. Huỳnh Trung Hiếu

BỘ CÔNG THƯƠNG
TRƯỜNG ĐẠI HỌC CÔNG NGHIỆP THÀNH PHỐ HỒ CHÍ MINH

CỘNG HÒA XÃ HỘI CHỦ NGHĨA VIỆT NAM
Độc lập - Tự do - Hạnh phúc

NHIỆM VỤ LUẬN ÁN TIẾN SĨ

Họ tên nghiên cứu sinh: Lê Nhị Lãm Thuý ..... MSHV: 19630951

Ngày, tháng, năm sinh: 26/3/1980 ..... Nơi sinh: TP.HCM

Ngành: Khoa học máy tính ..... Mã ngành: 9480101

I. TÊN LUẬN ÁN

Trích xuất mạch vành và phát hiện bất thường trên mạch vành hỗ trợ trong chẩn đoán

NHIỆM VỤ VÀ NỘI DUNG:

Bệnh động mạch vành là mối đe dọa lớn đối với sức khoẻ con người và đây là bệnh gây tử vong hàng đầu. Tuy nhiên việc xác định một mạch vành có bất thường hay không và bất thường thế nào thông qua ảnh mạch vành thường đòi hỏi thời gian và chuyên môn của bác sĩ vì mỗi cấp độ của động mạch vành có tính chất và kích thước khác nhau.

Các động mạch vành chính thường có độ tương phản cao so với nền, trong khi các động mạch vành thứ cấp có độ tương phản thấp so với nền và cấu trúc mỏng. Hơn nữa, một số mạch nhỏ bị ngắt kết nối hoặc bị phá vỡ các phân đoạn mạch máu. Luận án cần giải quyết hai bài toán:

(1) phân đoạn mạch vành và

(2) phát hiện bất thường trên mạch vạch (nếu có).

Bài toán đầu tiên cần được giải quyết làm cơ sở để giải quyết bài toán (2).

II. NGÀY GIAO NHIỆM VỤ: 06/7/2020 theo quyết định số 818/QĐ-ĐHCN của trường đại học Công Nghiệp TP.HCM

III. NGÀY HOÀN THÀNH NHIỆM VỤ: 17/2/2025

IV. NGƯỜI HƯỚNG DẪN KHOA HỌC:

1. PGS.TS. Phạm Thế Bảo
2. PGS.TS. Huỳnh Trung Hiếu

Tp. Hồ Chí Minh, ngày .... tháng …. năm 2025

NGƯỜI HƯỚNG DẪN	**CHỦ NHIỆM BỘ MÔN ĐÀO TẠO**
(Họ tên và chữ ký)	*(Họ tên và chữ ký)*

TRƯỞNG KHOA CÔNG NGHỆ THÔNG TIN

LỜI CAM ĐOAN

Tôi xin cam đoan nội dung của luận án là kết quả nghiên cứu của chính bản thân tác giả dưới sự hướng dẫn của các cán bộ hướng dẫn khoa học. Tất cả thông tin tham khảo đều được nêu rõ nguồn gốc trong danh mục các tài liệu tham khảo của luận án. Những đóng góp chính của luận án là nghiên cứu của tác giả đã công bố trong các bài báo được liệt kê trong danh mục các công trình nghiên cứu, và chưa được công bố bởi tác giả nào khác. Các công trình nghiên cứu của nhiều tác giả được đưa vào luận án đã được sự đồng ý của tất cả các đồng tác giả.

Tác giả luận án

Lê Nhị Lãm Thuý

TÓM TẮT LUẬN ÁN TIẾN SĨ

Bệnh động mạch vành (Coronary Artery Disease - CAD) là mối đe dọa lớn đối với sức khỏe con người. Đây là bệnh gây tử vong nhất trên thế giới. CAD là loại bệnh tim mạch (Cardiovascular Diseases - CVD) thường xuyên nhất. Trong khám chữa bệnh, việc xác định các vùng bất thường (bao gồm phình động mạch và hẹp) trên các mạch máu là rất quan trọng. Khi các vùng bất thường trở nên nghiêm trọng, nó sẽ hạn chế lưu lượng máu và dẫn đến các triệu chứng như đau thắt ngực hoặc nhồi máu cơ tim. Để chẩn đoán CAD, một bác sĩ phải giỏi và có nhiều kinh nghiệm cũng như rất nhiều thời gian để xem xét, phân tích, và ra quyết định. Do đó trong nghiên cứu này, luận án đề xuất một cách tiếp cận để phát hiện và định vị các bất thường trên hình ảnh tia X mạch vành. Mỗi cấp độ của động mạch vành có kích thước và tính chất khác nhau. Các động mạch vành chính thường có độ tương phản cao so với nền, trong khi các động mạch vành thứ cấp có độ tương phản thấp so với nền và cấu trúc mỏng. Hơn nữa, một số mạch nhỏ bị ngắt kết nối hoặc bị phá vỡ các phân đoạn mạch máu. Luận án cần giải quyết hai bài toán: (1) phân đoạn mạch vành và (2) phát hiện bất thường trên mạch vạch (nếu có). Bài toán đầu tiên cần được giải quyết làm cơ sở để giải quyết bài toán (2), luận án đã đề xuất hướng tiếp cận từ thô đến mịn trên các mô hình học sâu khác nhau để giải quyết cho bài toán phân đoạn đối tượng với loại dữ liệu phức tạp có kích thước biến động, từ ý tưởng này luận án đã phân đoạn thành công mạch vành với dữ liệu phức tạp và kích thước mạch vành biến động, cũng như vị trí phức tạp. Từ kết quả phân đoạn này luận án đã đề xuất xây dựng các thuật toán duyệt trên thành mạch vành đã được phân đoạn và mô hình học sâu khác nhau để phát hiện vùng bất thường trên mạch vành (nếu có). Kết quả nghiên cứu đã được công bố 05 bài báo khoa học trên các tạp chí uy tín, hội nghị quốc tế.

ASTRACT

Coronary Artery Disease (CAD) is a significant health risk and the leading cause of death globally. It is the most common form of cardiovascular disease. Identifying abnormal regions in blood vessels, such as aneurysms and narrowings, is crucial during medical examinations and treatments. These abnormalities can impede blood flow, potentially leading to angina or myocardial infarction. Diagnosing CAD requires a skilled doctor and considerable time. This study introduces a method to detect and locate abnormalities in coronary X-rays. Coronary arteries vary in size and characteristics, with primary arteries displaying high contrast against the background and secondary arteries showing low contrast and thinner structures. Additionally, some small vessels may be disconnected or have disrupted blood flow. The research focuses on two main challenges: (1) segmentation of the coronary arteries, and (2) detection of any abnormalities. The first challenge forms the foundation for addressing the second. The study employs a range of deep learning models, starting from basic to more refined approaches, to segment the coronary arteries effectively. This technique has been successful in handling complex data with varying sizes and intricate positioning of thecoronary arteries. Upon successful segmentation, the study presents advanced algorithms which was called the vessel wall browsing algorithm and learning models for detecting abnormalities on the coronary artery walls. These research findings have been published in 05 scientific articles in reputable scientific journals and international conference.

LỜI CẢM ƠN

Đầu tiên, tôi xin chân thành gửi lời tri ân sâu sắc đến PGS.TS. Phạm Thế Bảo và PGS.TS. Huỳnh Trung Hiếu đã tận tình hướng dẫn, chia sẻ kiến thức, mở lối dẫn đường cho tôi hoàn thành nghiên cứu luận án này.

Con cũng xin cảm ơn sâu sắc ba mẹ, gia đình đã luôn là chỗ dựa, hậu phương vững chắc cho con trong hành trình khó khăn vất vả.

Tôi cũng xin cảm ơn Quý Thầy Cô khoa Công Nghệ Thông Tin trường đại học Công Nghiệp TP.HCM, đã cung cấp kiến thức quý báu thông qua các chuyên đề, thảo luận, trao đổi giúp đỡ cho tôi trên con đường nghiên cứu học thuật.

Tôi xin cảm ơn Ban giám hiệu trường đại học Sài Gòn đã tạo thuận lợi cho tôi trong quá trình học tập công tác. Đồng thời tôi cũng xin cảm ơn Quý lãnh đạo khoa Công Nghệ Thông Tin, Thầy Cô khoa Công Nghệ Thông Tin trường đại học Sài Gòn đã chia sẻ, thấu hiểu, giúp đỡ, hỗ trợ tôi các công tác giảng dạy, chuyên môn trong quá trình nghiên cứu học tập.

Tôi xin cảm ơn Đại học Chonnam, Hàn Quốc đã cung cấp dữ liệu ảnh mạch vành của bệnh nhân, và dữ liệu đã được thông qua hội đồng kiểm duyệt làm tiền đề để tôi có nghiên cứu này.

Thành phố Hồ Chí Minh ngày……tháng…...năm 2025

Tác giả

MỤC LỤC

LỜI CAM ĐOAN i
TÓM TẮT LUẬN ÁN TIẾN SĨ ii
ASTRACT iii
LỜI CẢM ƠN iv
MỤC LỤC v
DANH MỤC HÌNH ẢNH viii
DANH MỤC BẢNG BIỂU xii
DANH MỤC THUẬT TOÁN xiv
DANH MỤC TỪ VIẾT TẮT xv
MỞ ĐẦU 1
1. Đặt vấn đề 1
2. Mục tiêu nghiên cứu 2
3. Đối tượng và phạm vi nghiên cứu 2
4. Cách tiếp cận và phương pháp nghiên cứu 2
5. Ý nghĩa thực tiễn của đề tài 2
6. Cấu trúc luận án 3
CHƯƠNG 1 TỔNG QUAN 5
1.1 Ảnh y khoa 5
1.2 Mạch vành 9
1.3 Bài toán 13
1.4 Dữ liệu 15
1.5 Kết chương 18
CHƯƠNG 2 CƠ SỞ LÝ THUYẾT 19
2.1 Phương pháp trích khung xương 19
2.2 Mạng neural nhân tạo 19
2.2.1 Kiến trúc tổng quát 20
2.2.2 Quá trình học 24

2.3 Học sâu 29
2.3.1 Mạng neural tích chập 30
2.3.2 Lớp tích chập 30
2.3.3 Lớp tổng hợp 31
2.3.4 Các thành phần cơ bản của mạng neural tích chập 32
2.4 Unet 38
2.5 Kết chương 41
CHƯƠNG 3 BÀI TOÁN PHÂN ĐOẠN MẠCH VÀNH 42
3.1 Các hướng tiếp cận 42
3.1.1 Hướng tiếp cận dựa trên các kỹ thuật nhận dạng mẫu 43
3.1.2 Hướng tiếp cận dựa trên mô hình 45
3.1.3 Hướng tiếp cận dựa trên thông minh nhân tạo 46
3.2 Mô hình đề xuất 51
3.3 Xây dựng mô hình 53
3.3.1 Trích mạch máu chính 53
3.3.2 Trích mạch máu thứ cấp 58
3.3.3 Tái tạo đầy đủ cây mạch máu 61
3.4 Thực nghiệm 61
3.4.1 Môi trường thực nghiệm 63
3.4.2 Phân đoạn mạch máu bằng Unet 63
3.5 Kết quả và đánh giá 64
3.6 Kết chương 69
CHƯƠNG 4 BÀI TOÁN PHÁT HIỆN BẤT THƯỜNG TRÊN MẠCH VÀNH .. 70
4.1 Các hướng tiếp cận 70
4.2 Đề xuất mô hình tổng quát 74
4.3 Hướng tiếp cận chưa tiền xử lý ảnh 76
4.3.1 Xây dựng thuật toán dựa trên kiến thức xử lý ảnh 76
4.3.2 Học sâu 81
4.4 Hướng tiếp cận tiền xử lý trích cạnh 83

4.4.1 Tiền xử lý trích cạnh 83
4.4.2 Phát hiện bất thường với thuật toán duyệt cạnh 84
4.4.3 Mô hình học sâu 84
4.5 Hướng tiếp cận mặt phẳng thông tin 85
4.6 Thực nghiệm 87
4.6.1 Môi trường thực nghiệm 87
4.6.2 Chưa tiền xử lý trích cạnh 87
4.6.3 Tiền xử lý trích cạnh 88
4.6.4 Mặt phẳng thông tin 88
4.7 Kết quả 89
4.7.1 Kết quả phương pháp duyệt cạnh với dữ liệu chưa trích cạnh 89
4.7.2 Kết quả phương pháp duyệt cạnh với dữ liệu đã trích cạnh 92
4.7.3 Kết quả phương pháp học sâu với dữ liệu chưa trích cạnh 94
4.7.4 Kết quả phương pháp học sâu với dữ liệu đã trích cạnh với phương pháp Canny 96
4.7.5 Kết quả phương pháp học sâu với dữ liệu đã trích cạnh với phương pháp DexiNed 98
4.7.6 Kết quả phương pháp học sâu với dữ liệu mặt phẳng bit 103
4.7.7 Kết quả phương pháp học sâu với dữ liệu mặt phẳng màu 113
4.8 Đánh giá 122
4.9 Kết chương 126
CHƯƠNG 5 KẾT LUẬN VÀ HƯỚNG PHÁT TRIỂN 128
5.1 Kết luận 128
5.2 Hướng phát triển của luận án 130
DANH MỤC CÔNG TRÌNH CỦA TÁC GIẢ 131
TÀI LIỆU THAM KHẢO 133

DANH MỤC HÌNH ẢNH

Hình 1.1 Mô hình cho hệ thống chẩn đoán bằng ảnh y khoa [5]. 8
Hình 1.2 Ba lớp của mạch máu [7] 10
Hình 1.3 Bệnh mạch vành [8]. 12
Hình 1.4 Hình X-quang động mạch vành: (a) bệnh hẹp mạch máu và (b) chồng chéo của mạch máu. 12
Hình 1.5 Phương pháp giải quyết bài toán phát hiện bất thường trên ảnh mạch vành. 15
Hình 1.6 Đoạn mạch vành sau khi được phân đoạn. 16
Hình 1.7 Ảnh (một phần mạch vành) dữ liệu của bộ dữ liệu ARCADE. 18
Hình 2.1 Cấu trúc tổng quát của một lớp trong mạng neural nhân tạo 20
Hình 2.2 Cấu trúc tổng quát neural. 21
Hình 2.3 Cấu trúc tổng quát của một lớp trong mạng neural nhân tạo. 22
Hình 2.4 Đồ thị mối quan hệ hàm lỗi và trọng số. 27
Hình 2.5 Kiến trúc của CNN. 30
Hình 2.6 Cách hoạt động của bộ lọc kx, y để đưa ra bản đồ đặc trưng trên ma trận đầu vào fx, y. 31
Hình 2.7 Ví dụ CNN với hai lớp tích chập, hai lớp tổng hợp và hai lớp kết nối đầy đủ để quyết định phân loại hình ảnh [14]. 32
Hình 2.8 Kiến trúc Unet với đầu vào là ảnh xám 572×572 [27]. 40
Hình 3.1 Mô hình đề xuất phân đoạn mạch vành. 52
Hình 3.2 Ảnh mạch máu khi sử dụng Unet để trích xuất. 54
Hình 3.3 Kết quả áp dụng thuật toán Zhang-Suen cải tiến. 55
Hình 3.4 Những điểm nối giữa các nhánh mạch máu. 58
Hình 3.5 Tạo cửa sổ từ các *joint*. 59
Hình 3.6 Ảnh đầu vào có kích thước 512×512. 62
Hình 3.7 Ảnh ground truth. 62
Hình 3.8 Kết quả quá trình phân đoạn ảnh trong cơ sở dữ liệu. 65

Hình 3.9 So sánh kết quả phân đoạn: (a) ảnh đầu vào; (b) kết quả trong [64] (c) kết quả trong [33]; (d) kết quả của phương pháp của luận án. 67

Hình 3.10 Lỗi phân đoạn ảnh mạch nhỏ do ảnh hưởng của ánh sáng (a) ảnh đầu vào; (b) ảnh tăng cường độ tương phản; (c) kết quả sử dụng Unet có tăng cường độ tương phản; (d) kết quả từ phương pháp của luận án không tăng cường độ tương phản. 68

Hình 4.1 Mô hình hướng giải quyết thứ nhất cho phát hiện bất thường trên mạch vành. 75

Hình 4.2 Mô hình hướng giải quyết thứ hai cho phát hiện bất thường trên mạch vành. 75

Hình 4.3 Sơ đồ khối của thuật toán đề xuất. 76

Hình 4.4 Chuẩn hóa vị trí mạch vành: (a) ảnh ban đầu; (b) sau khi chuẩn hóa. 80

Hình 4.5 Kết quả xác định bất thường. 81

Hình 4.6 Mô hình tổng quát với phương pháp học sâu của luận án. 82

Hình 4.7 Tiền xử lý: (a) ảnh ban đầu; (b) trích cạnh; (c) kết quả. 83

Hình 4.8 Mô hình học sâu với dữ liệu đầu vào là ảnh đoạn mạch vành được trích cạnh. 84

Hình 4.9 Sơ đồ tổng quát mô hình đánh giá các mặt phẳng thông tin. 85

Hình 4.10 Thông số kỹ thuật trên Google Colab. 87

Hình 4.11 Đồ thị kết quả các độ đo..... 90

Hình 4.12 (a) ảnh bất thường; (b) phát hiện đúng bất thường. 91

Hình 4.13 (a) không phát hiện được bất thường; (b) phát hiện thiếu vị trí bất thường. 91

Hình 4.14 Ảnh bình thường phát hiện sai là bất thường. 91

Hình 4.15 Đồ thị kết quả các độ đo..... 93

Hình 4.16 Ảnh bất thường: (a) đầu vào; (b) kết quả là bất thường; (c) đầu vào; (d) kết quả là bất thường nhưng thiếu vị trí. 93

Hình 4.17 Ảnh bình thường: (a) đầu vào; (b) kết quả bình thường; (c) đầu vào (d) kết quả bất thường. 93

Hình 4.18 Kết quả lỗi của mô hình khi huấn luyện. 94

Hình 4.19 Kết quả độ chính xác mô hình khi huấn luyện..... 95

Hình 4.20 Đồ thị kết quả các độ đo..... 96
Hình 4.21 Đồ thị kết quả các độ đo..... 97
Hình 4.22 Ảnh bất thường: (a) kết quả đúng; (b) kết quả sai. 98
Hình 4.23 Ảnh bình thường: (a) kết quả đúng; (b) kết quả sai. 98
Hình 4.24 Độ chính xác của tập huấn luyện và tập đánh giá khi trích cạnh. 99
Hình 4.25 Độ sai lệch của tập huấn luyện và tập đánh giá khi trích cạnh. 100
Hình 4.26 Ảnh mạch vành bình thường sau khi được trích cạnh. 100
Hình 4.27 Ảnh mạch vành bất thường sau khi được trích cạnh..... 101
Hình 4.28 Ảnh mạch vành bình thường sau khi được làm giàu thông tin cạnh..... 101
Hình 4.29 Ảnh mạch vành bất thường sau khi được làm giàu thông tin cạnh..... 101
Hình 4.30 Độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện. 102
Hình 4.31 Độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện. 102
Hình 4.32 Đồ thị kết quả các độ đo..... 103
Hình 4.33 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 7. 105
Hình 4.34 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 7. 106
Hình 4.35 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 6. 107
Hình 4.36 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 6. 107
Hình 4.37 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 5. 108
Hình 4.38 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 5. 109
Hình 4.39 Đồ thị kết quả các độ đo..... 110
Hình 4.40 Dự đoán ảnh theo phương pháp mặt phẳng bit: (a) ảnh bình thường ra bình thường; (b) ảnh bình thường ra bất thường. (c) ảnh bất thường ra bình thường; (d) ảnh bất thường ra bất thường. 111
Hình 4.41 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu đỏ. 114

Hình 4.42 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu đỏ. 115

Hình 4.43 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu lục..... 116

Hình 4.44 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu lục. 116

Hình 4.45 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu lam. 117

Hình 4.46 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu lam. 118

Hình 4.47 Đồ thị kết quả các độ đo..... 119

Hình 4.48 Dự đoán ảnh theo phương pháp mặt phẳng màu: (a) ảnh bình thường ra bình thường; (b) ảnh bình thường ra bất thường. (c) ảnh bất thường ra bình thường; (d) ảnh bất thường ra bất thường. 120

Hình 4.49 So sánh mức độ chính xác phương pháp duyệt cạnh với dữ liệu đầu vào là đoạn mạch không trích cạnh và có trích cạnh. 123

Hình 4.50 So sánh mức độ chính xác phương pháp học sâu với dữ liệu đầu vào là đoạn mạch không trích cạnh và có trích cạnh. 124

Hình 4.51 So sánh mức độ chính xác phương pháp học sâu trên mặt phẳng thông tin kết hợp phương pháp voting..... 125

Hình 4.52 So sánh trung bình của ba hướng xử lý: (a) xem xét bình thường và bất thường; (b) chỉ xem xét mức độ chính xác..... 126

DANH MỤC BẢNG BIỂU

Bảng 1.1 Dữ liệu 16
Bảng 2.1 Các loại hàm kích hoạt phổ biến. 23
Bảng 3.1 Giá trị các tham số mô hình Unet main. 63
Bảng 3.2 Giá trị các tham số mô hình Unet branch. 63
Bảng 3.3 Giá trị các tham số thuật toán xây dựng khung xương mạch máu. 64
Bảng 3.4 Kết quả độ chính xác từng ảnh và trung bình. 64
Bảng 3.5 So sánh các phương pháp khác. 65
Bảng 4.1 Cấu trúc mạng CNN. 89
Bảng 4.2 Kết quả các giá trị TP, TN, FP và FN. 90
Bảng 4.3 Kết quả các độ đo. 90
Bảng 4.4 Kết quả các giá trị TP, TN, FP và FN. 92
Bảng 4.5 Kết quả các độ đo. 92
Bảng 4.6 Số lượng dữ liệu dùng cho mô hình. 94
Bảng 4.7 Kết quả các giá trị TP, TN, FP và FN. 95
Bảng 4.8 Kết quả các độ đo. 95
Bảng 4.9 Số lượng dữ liệu dùng cho mô hình. 96
Bảng 4.10 Kết quả các giá trị TP, TN, FP và FN. 97
Bảng 4.11 Kết quả các độ đo. 97
Bảng 4.12 Số lượng dữ liệu dùng cho mô hình. 99
Bảng 4.13 Kết quả các giá trị TP, TN, FP và FN. 103
Bảng 4.14 Kết quả các độ đo. 103
Bảng 4.15 Số lượng dữ liệu dùng cho mô hình. 104
Bảng 4.16 Kết quả độ chính xác của mô hình dự đoán sử dụng từng mặt phẳng bit. 104
Bảng 4.17 Kết quả các độ đo với mặt phẳng bit 7. 106
Bảng 4.18 Kết quả các độ đo với mặt phẳng bit 6. 108
Bảng 4.19 Kết quả các độ đo với mặt phẳng bit 5. 109

Bảng 4.20 Kết quả các giá trị TP, TN, FP và FN..... 109
Bảng 4.21 Kết quả các độ đo với 03 mặt phẳng bit được kết hợp bằng phương pháp voting mềm..... 110
Bảng 4.22 Kết quả độ chính xác của mô hình dự đoán sử dụng từng mặt phẳng bit. 112
Bảng 4.23 Kết quả các độ đo với mặt phẳng bit 7..... 112
Bảng 4.24 Kết quả các độ đo với mặt phẳng bit 6..... 112
Bảng 4.25 Kết quả các độ đo với mặt phẳng bit 5..... 113
Bảng 4.26 Kết quả các giá trị TP, TN, FP và FN..... 113
Bảng 4.27 Kết quả các độ đo với 03 mặt phẳng bit được kết hợp bằng phương pháp voting mềm..... 113
Bảng 4.28 Kết quả độ chính xác của mô hình dự đoán sử dụng mặt phẳng màu.. 114
Bảng 4.29 Kết quả với mặt phẳng màu đỏ..... 115
Bảng 4.30 Kết quả với mặt phẳng màu lục..... 117
Bảng 4.31 Kết quả với mặt phẳng màu lam..... 118
Bảng 4.32 Kết quả các giá trị TP, TN, FP và FN..... 118
Bảng 4.33 Kết quả kiểm tra với 03 mặt phẳng màu được kết hợp bằng phương pháp voting mềm..... 119
Bảng 4.34 Kết quả độ chính xác của mô hình dự đoán sử dụng mặt phẳng màu.. 121
Bảng 4.35 Kết quả với mặt phẳng màu đỏ..... 121
Bảng 4.36 Kết quả với mặt phẳng màu lục..... 121
Bảng 4.37 Kết quả với mặt phẳng màu lam..... 121
Bảng 4.38 Kết quả các giá trị TP, TN, FP và FN..... 122
Bảng 4.39 Kết quả kiểm tra với ba mặt phẳng màu được kết hợp bằng phương pháp voting mềm..... 122

DANH MỤC THUẬT TOÁN

Thuật toán 2.1 Các bước thực hiện Gradient Descent 26
Thuật toán 3.1 Trích xuất mạch máu chính 54
Thuật toán 3.2 Trích khung xương mạch máu từ ảnh nhị phân 55
Thuật toán 3.3 Xác định các joint của mạch máu 57
Thuật toán 3.4 Chọn vùng mạch máu 59
Thuật toán 3.5 Trích mạch máu thứ cấp 60
Thuật toán 3.6 Tái tạo đầy đủ cây mạch máu 61
Thuật toán 4.1 Thuật toán tìm góc xoay và xoay ảnh 77
Thuật toán 4.2 Thuật toán xác định ứng viên bất thường 78
Thuật toán 4.3 Thuật toán tìm điểm bất thường..... 79
Thuật toán 4.4 Thuật toán huấn luyện..... 82

DANH MỤC TỪ VIẾT TẮT

ANN	Artifical Neural Network
AR-SPL	Annotation-Refining Self-Paced Learning Framework
AV	Atrioventricular node
CAD	Coronary Atery Disease
CCTA	Coronary Computed Tomography Angiography
CNN	Convolutional Neural Networks
ConvGRU	Convolutional Gated Recurrent Unit
CT	Computed Tomography
DDFB	Decimation free Directional Filter Bank
DexiNed	Dense Extreme Inception Network
EBCT	Electron beam computed tomography
EEG	Electro Encephalo Graphy
FCN	Fully Convolutional Network
fMRI	Functional Magnetic Resonance Imaging
HF	Homographic Filter
IEEE	Institute of Electrical and Electronics Engineers
KL	Kullback-Leibler
LMCA	Left Main Coronary Atery
LSTM	Long short-term memory
MAE	Mean Absolute Error
MDCT	Multi-detector computed tomography
MEG	Magneto Encephalo Graphy

MRI	Magnetic Resonance Imaging
MSE	Mean Squared Error
MSLE	Mean Squared Logarithmic Error
NN	Neural Network
PE	Processing Elements
PET	Positron Emission Tomography
RCA	Right Coronary Atery
ReLU	Rectified Linear Activation function
SA	Sinoatrial node

MỞ ĐẦU

1. Đặt vấn đề

Bệnh động mạch vành (Coronary Artery Disease - CAD) là mối đe dọa lớn đối với sức khỏe con người, đây là bệnh gây tử vong nhất trên thế giới. CAD là loại bệnh tim mạch (Cardiovascular Diseases - CVD) thường xuyên nhất. Trong khám chữa bệnh, việc xác định các vùng bất thường (bao gồm phình động mạch và hẹp) trên các mạch máu là rất quan trọng. Việc xác định bệnh đòi hỏi bác sĩ có chuyên môn cao và tốn nhiều thời gian. Theo báo cáo của WHO năm 2019, tỷ lệ tử vong do mắc bệnh tim mạch chiếm 32% tỷ lệ các ca tử vong trên toàn cầu. Bệnh lý tim mạch là nguyên nhân gây tử vong hàng đầu trên thế giới, nhiều hơn cả bệnh ung thư. Tại Việt Nam, theo thống kê của Bộ Y tế, mỗi năm có 200.000 người tử vong vì bệnh tim mạch, chiếm tỷ lệ 33%. Trong đó bệnh lý về mạch vành là một trong những bài toán khó trong xử lý. Nguyên nhân chính của bệnh lý về tim mạch là do sự kết hợp của chất béo, canxi, và mô sẹo tích tụ trong các động mạch và làm hẹp hoặc tắc nghẽn động mạch. Việc phát hiện bất thường trên mạch máu là bài toán rất quan trọng trong quá trình chẩn đoán các bệnh lý về mạch máu, hỗ trợ bác sĩ ra quyết định chính xác hơn. Tuy nhiên, để phát hiện được bất thường trên mạch máu đòi hỏi kinh nghiệm và kiến thức của bác sĩ được đào tạo rất chuyên sâu về mạch máu. Ảnh y khoa là các ảnh chụp có được do áp dụng các kỹ thuật để tiếp cận trực quan đến cấu trúc phức tạp bên trong cơ thể, vì vậy ảnh y khoa hỗ trợ rất nhiều trong việc giúp bác sĩ chẩn đoán và điều trị. Tuy nhiên, việc có quá nhiều bệnh nhân sẽ là vấn đề khó khăn khi bác sĩ không thể xem xét, thăm khám, chẩn đoán hết tất cả. Vì lí do đó, việc nghiên cứu các ảnh về mạch máu, mà đặc biệt là mạch vành để phát hiện các bất thường trên mạch vành là rất quan trọng và cần thiết. Với sự hỗ trợ của công nghệ thông tin, các bác sĩ sẽ giảm thiểu được thời gian chẩn đoán, đồng thời hỗ trợ được nhiều bệnh nhân hơn.

2. Mục tiêu nghiên cứu

Luận án cần giải quyết hai bài toán: (1) phân đoạn mạch vành và (2) phát hiện bất thường trên mạch vạch (nếu có). Bài toán đầu tiên cần được giải quyết làm cơ sở để giải quyết bài toán (2).

3. Đối tượng và phạm vi nghiên cứu

- Đối tượng nghiên cứu: ảnh mạch vành.

- Phạm vi nghiên cứu: Luận án sử dụng dữ liệu cung cấp từ bệnh viện Đại học Quốc gia Chonnam, Hàn Quốc. Dữ liệu này đã được hội đồng y đức bệnh viện cho phép, cũng như sự đồng ý của bệnh nhân, các dữ liệu về thông tin nhân thân của người bệnh đã được mã hóa hoặc xóa thông tin. Dữ liệu gồm ban đầu của 48 bệnh nhân, mỗi ảnh màu (màu xám) có kích thước 512×512 điểm ảnh. Luận án hướng đến ứng dụng trực tiếp nhận dữ liệu để phân đoạn và phát hiện bất thường trên mạch vành, nên sẽ không xem xét vấn đề tiền xử lý, vì mỗi thiết bị và thời điểm thu ảnh khác nhau ảnh mạch vành thu được không thể xác định chính xác tiền xử lý như thế nào. Các phân tích chi tiết được trình bày trong luận án.

4. Cách tiếp cận và phương pháp nghiên cứu

Luận án đã đề xuất hướng tiếp cận từ thô đến mịn trên các mô hình học sâu khác nhau để giải quyết cho bài toán phân đoạn đối tượng với loại dữ liệu phức tạp có kích thước biến động.

Từ kết quả phân đoạn này luận án đã đề xuất các thuật toán duyệt trên thành mạch vành đã được phân đoạn và mô hình học sâu khác nhau để phát hiện vùng bất thường trên mạch vành (nếu có).

5. Ý nghĩa thực tiễn của đề tài

Đề tài nghiên cứu đề xuất hướng tiếp cận mới cho phương pháp phân đoạn ảnh có độ phức tạp cao (sự chênh lệch độ sáng và màu sắc giữa đối tượng và nền không nhiều, các đối tượng trong ảnh phức tạp về hình dáng và trạng thái) dựa trên học sâu với

hướng tiếp cận từ thô đến mịn. Phương pháp này được áp dụng cho bài toán đầu tiên trong luận án là phân đoạn mạch vành cho kết quả khả quan. Kết quả này làm tiền đề cho giải quyết bài toán phát hiện bất thường trên mạch vành (nếu có), đây là một trong những công cụ hỗ trợ bác sĩ trong chẩn đoán nhanh các bệnh lý trên mạch vành nói riêng và mạch máu nói chung. Mỗi bác sĩ chỉ có thể xem xét trên một số giới hạn người bệnh để chẩn đoán, đặc biệt là bệnh mạch vành (vì mức độ phức tạp rất cao), với công cụ hỗ trợ này thì sẽ giúp đỡ bác sĩ rất nhiều trong chẩn đoán và điều trị.

6. Cấu trúc luận án

Luận án được trình bày làm 5 chương:

- Chương 1: Giới thiệu tổng quan về đề tài và đề xuất hướng giải quyết cho từng bài toán.
- Chương 2: Trình bày cơ sở lý thuyết được sử dụng trong luận án.
- Chương 3: Trình bày các hướng tiếp cận để giải quyết bài toán phân đoạn mạch vành và chi tiết phương pháp giải quyết của luận án.
- Chương 4: Trình bày các hướng tiếp cận để giải quyết bài toán phát hiện bất thường trên mạch vành và chi tiết phương pháp giải quyết của luận án.
- Chương 5: Kết luận và hướng phát triển.

7. Đóng góp mới

Luận án có những đóng góp mới là đề xuất mới các phương pháp giải quyết bài toán:

- Phân đoạn mạch vành: đề xuất một phương pháp tiếp cận mới theo chiến lược "từ thô đến mịn," sử dụng các mô hình học sâu khác nhau, đặc biệt là hai mô hình Unet, để xử lý hiệu quả dữ liệu phức tạp, kích thước biến động, có chồng chéo, độ tương phản thấp và nhiễu cao. Kết quả phân đoạn đạt chất lượng tốt, phù hợp cho dữ liệu mạch vành phức tạp.
- Phát hiện bất thường trên mạch vành: từ kết quả bài toán phân đoạn, luận án đề xuất hai hướng tiếp cận:

1. Tiếp cận thuật toán duyệt cạnh: Phân tích hướng và độ dốc hướng trên đoạn mạch được phân đoạn để xây dựng thuật toán mới xác định bất thường (hẹp hoặc phình mạch).
2. Tiếp cận học sâu: Xây dựng mô hình CNN nhận đầu vào là các đoạn mạch đã phân đoạn (được trích cạnh bằng phương pháp Canny truyền thống và DexiNed học sâu, hoặc chưa trích cạnh) để phát hiện bất thường. Ngoài ra, luận án cũng kết hợp các mặt phẳng thông tin bằng phương pháp voting mềm để phát hiện bất thường trên đoạn mạch chưa phân đoạn.

Kết quả thực nghiệm chứng minh tính khả thi và hiệu quả của các phương pháp được đề xuất.

CHƯƠNG 1 TỔNG QUAN

Chương 1 luận án sẽ trình bày tổng quan về ảnh y khoa và phương pháp chụp ảnh y khoa dựa trên đó để có phương pháp tổng quát xử lý ảnh y khoa. Từ kiến thức tổng quát sẽ trình bày chi tiết về ảnh mạch vành và bệnh lý về ảnh mạch vành làm tiền đề từ đó giải quyết bài toán "Phân đoạn và phát hiện bất thường trên mạch vành" dựa trên dữ liệu cụ thể từ Đại học Chonnam Hàn Quốc cung cấp. Với những nội dung trình bày được công bố một bài báo ở tạp chí thuộc danh mục hội đồng chức danh nhà nước công nhận [CT4].

1.1 Ảnh y khoa

Ảnh y khoa là ảnh thu được với các kỹ thuật và quy trình được sử dụng để tạo ra ảnh của cơ thể người (hoặc các bộ phận của cơ thể) cho các mục đích lâm sàng khác nhau như các tiến trình và chẩn đoán y khoa bao gồm nghiên cứu về giải phẫu và chức năng bình thường [1] [2]. Theo nghĩa rộng hơn, nó là một phần của ảnh sinh học và kết hợp X-quang, nội soi, máy đo nhiệt, và kính hiển vi. Các kỹ thuật đo lường và ghi chép như điện não đồ (Electro Encephalo Graphy – EEG) và ghi dữ liệu tín hiệu não từ tính (Magneto Encephalo Graphy – MEG) không chỉ chủ yếu được thiết kế để tạo ra ảnh mà còn tạo ra dữ liệu khả dĩ được biểu diễn dưới dạng bản đồ, dạng này cũng có thể được xem như dạng ảnh y khoa. Trong tình huống lâm sàng, ảnh y khoa thường được xem như X-quang hoặc "ảnh lâm sàng". Nghiên cứu ứng dụng và diễn giải ảnh y khoa thường là bảo tồn X-quang và chuyên ngành y khoa liên quan đến tình trạng bệnh lý hoặc lĩnh vực khoa học y tế (khoa học thần kinh, tim mạch, tâm thần học, tâm lý học) đang được nghiên cứu. Nhiều kỹ thuật được phát triển cho ảnh y khoa cũng có các ứng dụng khoa học và công nghiệp. Mặc dù toán học được sử dụng một cách tổng quát để xử lý ảnh, nhưng lại không có tầm ảnh hưởng nhiều trong lãnh vực y sinh học cho đến khi phát triển kỹ thuật chụp cắt lớp (Computed Tomography – CT) cho X-quang (dẫn đến chụp cắt lớp có sự hỗ trợ của máy tính hoặc CAT) và chụp cắt lớp phát xạ đồng vị (dẫn đến chụp cắt lớp phát xạ Positron hoặc quét PET và chụp

cắt lớp phát xạ Positron đơn lẻ hoặc quét SPECT), sau đó MRI (Magnetic Resonance Imaging – chụp cộng hưởng từ) thông dụng nhất so với các phương pháp [1].

Bên cạnh tất cả các kỹ thuật đã được thiết lập tốt này, nhiều phương pháp đang được nghiên cứu cho các ứng dụng của siêu âm và điện não cũng như các kỹ thuật mới về ảnh quang học, chụp cắt lớp trở kháng và ảnh nguồn từ. Mặc dù các ảnh cuối cùng thu được từ nhiều kỹ thuật có những điểm tương đồng nhưng công nghệ được sử dụng và các thông số biểu thị trong ảnh rất khác nhau về đặc điểm cũng như tính hữu dụng trong y khoa, thậm chí các mô hình toán học và thống kê khác nhau đã được sử dụng. Một số kỹ thuật đã được phát triển để cho phép phần mềm quét CT, MRI và siêu âm tạo ra ảnh 3D cho bác sĩ. Thông thường, khi quét CT và MRI tạo ra ảnh 2D trên phim, sau đó sẽ nhiều lần để tạo ra ảnh 3D từ một mô hình xử lý [2].

Ảnh y khoa được các nhà khoa học xem là một phần của ảnh sinh học, đã được phát triển từ thế kỷ 19. Tổng quan ngắn gọn về ảnh y khoa như sau [3]:

- Năm 1895, Roentgen tình cờ phát hiện ra tia X. Chụp X-quang thông thường là kỹ thuật ảnh y khoa phổ biến nhất từ trước đến nay trong ngành khoa học. Từ năm 1896, các hạt nhân phóng xạ được dùng để trị liệu và nghiên cứu chất đánh dấu trao đổi chất hơn là ảnh, sau đó máy quét tuyến tính ảnh bằng tia γ được phát minh.
- Trong Thế chiến thứ 2 công nghệ Sonar được dùng và vào năm 1970 thì sóng siêu âm đã trở nên phổ biến rộng rãi trong y khoa.
- Vào thế kỷ 20, kiến thức toán học cho việc tái tạo ảnh chụp cắt lớp đã được hiểu và phương pháp chụp cắt lớp phát xạ positron (PET) và tia X được dùng chụp cắt lớp (CT) đã được phát triển. Cộng hưởng từ hạt nhân đã được sử dụng để tạo ảnh trong chụp cộng hưởng từ (MRI).
- Trong thế kỷ 21 những loại tia X, MRI, siêu âm tiếp tục được phát triển, đặc biệt là ảnh đang được đưa vào với kính hiển vi cũng như cấu trúc sinh học vĩ mô (ảnh nhiệt, chụp cắt lớp trở kháng điện, kỹ thuật quét đầu dò, v.v.).

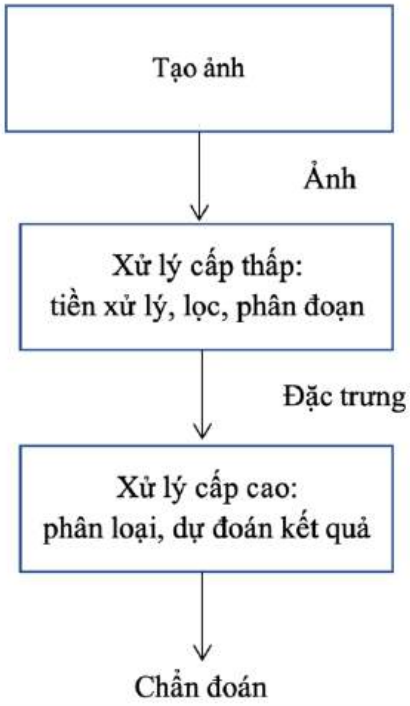
Ảnh y khoa là ảnh thu được sau khi tương tác của tất cả các dạng bức xạ với mô và thiết kế các hệ thống kỹ thuật để trích xuất thông tin liên quan đến lâm sàng, sau đó được biểu diễn dưới dạng ảnh. Ảnh y khoa bao gồm từ đơn giản nhất như chụp X-quang ngực đến các ảnh phức tạp hiển thị các hiện tượng theo thời gian như ảnh cộng hưởng từ chức năng (fMRI). Những thập kỷ qua đã chứng kiến phát triển vượt bậc của một công nghệ mới, mạnh mẽ để phát hiện, lưu trữ, truyền, phân tích và hiển thị ảnh y khoa kỹ thuật số. Công nghệ này đang giúp các nhà hóa sinh, nhà sinh học, nhà khoa học y tế và nhà vật lý học thu được các phép đo định lượng, tạo điều kiện thuận lợi cho việc xác nhận giả thuyết khoa học và chẩn đoán y khoa chính xác.

Trong tương lai, việc thu thập thông tin chức năng và trao đổi chất cùng với thông tin cấu trúc (ảnh) sẽ được tăng cường. Điều này có thể được thực hiện ở một mức độ nào đó với máy đánh dấu phóng xạ (ví dụ PET) và quang phổ cộng hưởng từ [4].

Mô hình xử lý ảnh y khoa

Việc phân tích và giải thích các ảnh y khoa đại diện cho hai trong số các nhiệm vụ phức tạp và tương ứng nhất; thường bao gồm nhiều bước xử lý. Tuy nhiên, không khó để khái quát quy trình này cho tất cả các phương thức xử lý ảnh y khoa, và mô hình xử lý ba cấp kết quả được minh họa trong hình 1.1.

Tạo ảnh là bước đầu tiên trong hệ thống. Một số phương thức tạo ảnh như trình bày ở trên, chẳng hạn như tia X, hoặc như phương thức tính toán phát xạ photon đơn sử dụng tái tạo ảnh như một kỹ thuật xử lý ảnh. Xử lý ảnh được thực hiện theo hai bước: bước xử lý cấp thấp và bước xử lý cấp cao. Các bước thực hiện như lọc, tăng cường ảnh và phân đoạn, trích xuất đặc trưng và phân loại, các bước xử lý trực tiếp trên các điểm ảnh thô, để đưa ra chẩn đoán. Các nhiệm vụ quan trọng nhất liên quan đến cấp. độ xử lý này là phân loại tính năng, phát hiện khối u và nói chung là chẩn đoán một số bệnh.



Hình 1.1 Mô hình cho hệ thống chẩn đoán bằng ảnh y khoa [5].

Các hoạt động xử lý ảnh cơ bản có thể được phân thành năm loại:

- Tiền xử lý: Tiền xử lý giúp hình dung rõ hơn các đường viền đối tượng có độ phân giải thấp. Các kỹ thuật phổ biến nhất bao gồm đăng ký ảnh chuyển động, chuyển đổi ảnh, bộ lọc hoặc toán tử Laplace.
- Lọc: Lọc bao gồm tăng cường, làm nét và phát hiện cạnh. Các kỹ thuật tăng cường bao gồm các bộ lọc tuyến tính hoặc phi tuyến, cục bộ hoặc toàn cục, hoặc dựa trên wavelet. Kỹ thuật làm nét có thể bao gồm các bộ lọc nghịch đảo hoặc Weiner. Các kỹ thuật phát hiện cạnh bao gồm biến đổi Haar, toán tử cục bộ, dự đoán và/hoặc các phương pháp phân loại.
- Phân đoạn: Phân đoạn có thể vừa dựa trên vùng vừa dựa trên đường cong. Có nhiều loại thuật toán phân đoạn khác nhau bao gồm các thuật toán cổ điển dựa trên vùng, thuật toán phân cụm, và mô hình phát hiện đường thẳng và cung tròn. Một vấn đề quan trọng trong ảnh y khoa là liệu có thể thực hiện phân đoạn cho nhiều lĩnh vực khác nhau bằng cách sử dụng các phương pháp tổng

quát từ dưới lên hay không khi mà không sử dụng bất kỳ kiến thức miền đặc biệt nào.

- Mô hình hóa hình dạng: Mô hình hóa hình dạng được thực hiện dựa trên các tính năng có thể được sử dụng độc lập hoặc kết hợp với các phép đo kích thước. Đối với ảnh y khoa, đôi khi hữu ích khi mô tả hình dạng của một vật thể chi tiết hơn hình dạng được cung cấp bởi một tính năng đơn lẻ nhưng cô đọng hơn là được phản ánh trong chính ảnh vật thể đó. Trong những trường hợp như vậy, bộ mô tả hình dạng thể hiện một cách nhỏ gọn hơn về hình dạng của một đối tượng.
- Phân loại: Phân loại dựa trên việc lựa chọn đặc trưng, đặc điểm kết cấu và quyết định liên quan đến lớp đặc trưng. Mỗi bất thường hoặc bệnh, hoặc có dấu hiệu bệnh được công nhận là thuộc một nhóm cụ thể và việc công nhận được thực hiện như một quá trình phân loại.

1.2 Mạch vành

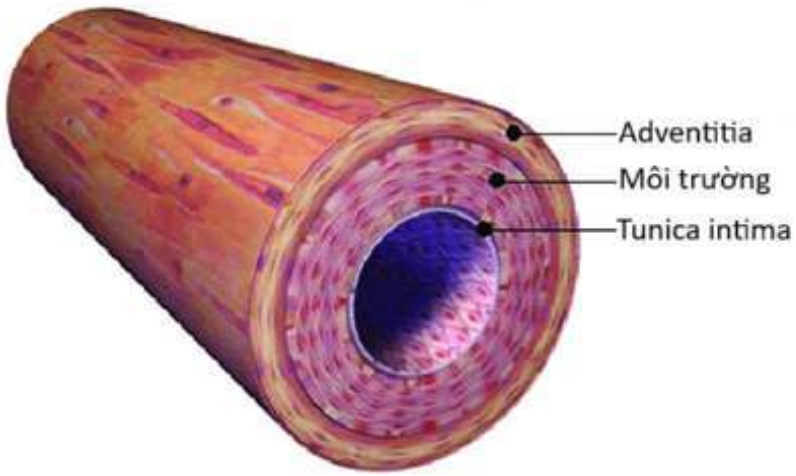
Động mạch vành phải và trái cung cấp máu cho tim [6], chúng là những nhánh đầu tiên của động mạch chủ, là động mạch chính trong cơ thể. Các động mạch này và các nhánh của chúng cung cấp máu cho tất cả các bộ phận của cơ tim. Chúng giúp tim có thể đập và bơm máu đi khắp cơ thể. Mỗi nhánh chứa các nhánh nhỏ hơn đi sâu vào bên trong cơ tim. Mỗi động mạch chứa nhiều nhánh:

- Động mạch vành phải (RCA): RCA cung cấp máu cho tâm nhĩ phải và tâm thất phải (nơi máu khử oxy đi trước khi đến phổi). Các nhánh của nó cung cấp cho các nút xoang nhĩ (SA) và nhĩ thất (AV). Các nút này gửi tín hiệu điện qua tim, để cơ tim biết khi nào co bóp. Các nhánh của RCA cũng cung cấp máu cho một phần ba vách liên thất, là bức tường giữa hai ngăn dưới của tim.
- Động mạch vành trái (LMCA): LMCA cung cấp máu cho tâm nhĩ trái và tâm thất trái. Đây là nơi máu đã được oxy hóa đến từ phổi trước khi tim bơm máu đến các phần còn lại của cơ thể. Các nhánh của nó cung cấp máu cho 2/3 vách liên thất.

Cấu trúc của các nhánh động mạch vành thay đổi tùy theo từng người. Một số ví dụ: Các động mạch vành thường được bao quanh bởi một lớp mỡ nhưng ở một số người, động mạch nằm trong chính cơ tim; nguồn cung cấp máu cho các nút SA và AV đến từ LCMA, không phải RCA, ở khoảng 10% số người; Đôi khi một động mạch vành duy nhất phát sinh từ động mạch chủ, sau đó chia thành các nhánh phải và trái. Hầu hết các biến thể này không có hại và không gây ra các triệu chứng. Nhưng trong một số trường hợp hiếm gặp (dưới 1% số người), những bất thường ở động mạch vành có thể dẫn đến các vấn đề nghiêm trọng hoặc thậm chí tử vong.

Các động mạch vành chính thường có đường kính từ 3mm đến 4mm. Nó nhỏ hơn một chút so với chiều rộng của ống hút. Kích thước của các động mạch thay đổi một chút tùy theo giới tính, trọng lượng cơ thể và thậm chí cả sắc tộc. Thành của tất cả các động mạch, kể cả động mạch vành, có ba lớp (hình 1.2):

- Tunica intima: Lớp bên trong chạm vào máu và giữ cho nó chảy trơn tru qua các động mạch.
- Môi trường: Lớp giữa đàn hồi, vì vậy nó mở rộng và co lại để duy trì huyết áp phù hợp trong động mạch.
- Adventitia: Lớp ngoài chứa các mạch nhỏ cung cấp oxy và chất dinh dưỡng từ máu đến các tế bào trong tim.



Hình 1.2 Ba lớp của mạch máu [7]

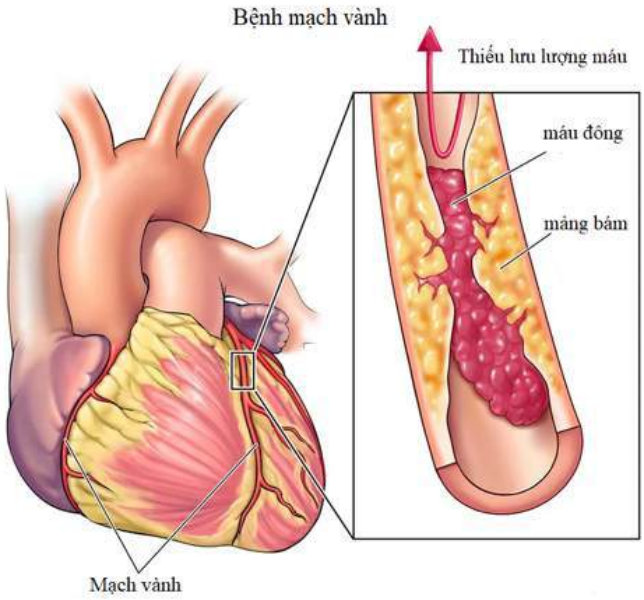
Bệnh động mạch vành (CAD) là tình trạng phổ biến nhất ảnh hưởng đến động mạch vành. CAD thường là kết quả của chứng xơ vữa động mạch, là sự tích tụ mảng bám bên trong động mạch. Các động mạch bị tắc ngăn máu đến tim, có thể dẫn đến cơn đau tim. Hội chứng mạch vành cấp tính là tình trạng mất đột ngột lưu lượng máu đến tim qua các động mạch vành. Nhồi máu cơ tim là một loại hội chứng mạch vành cấp tính. Giống như CAD, những tình trạng này cũng là kết quả của chứng xơ vữa động mạch (hình 1.3). Các tình trạng ít phổ biến hơn ảnh hưởng đến động mạch vành bao gồm:

- Chứng phình động mạch: Phình trong thành mạch máu.
- Bất thường bẩm sinh trong động mạch.
- Co thắt mạch vành: Đột ngột thắt chặt các cơ trong động mạch. Khi các cơ này thắt chặt hoặc co thắt, các động mạch tạm thời bị tắc nghẽn. Điều này có thể dẫn đến cơn đau ngực gọi là đau thắt ngực Prinzmetal.

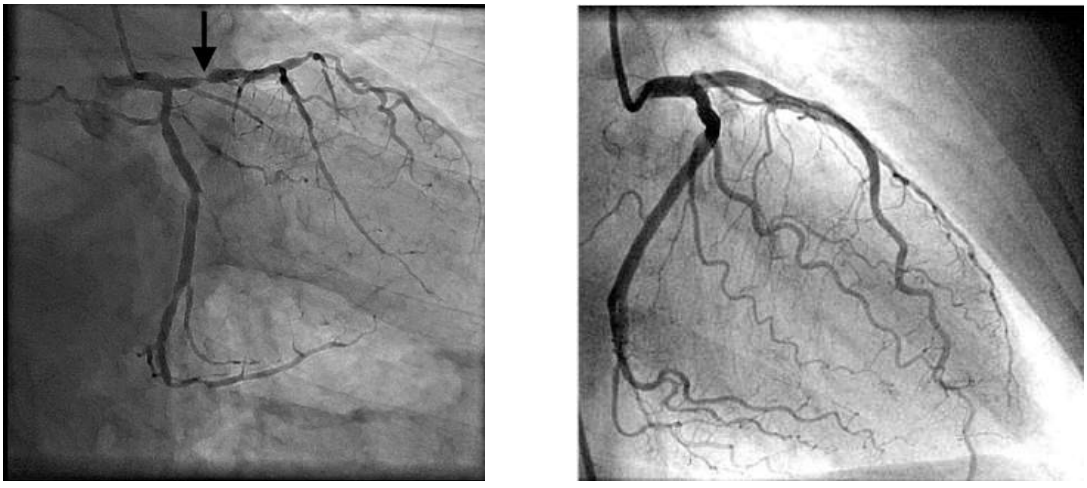
CAD là bệnh ở tình trạng mãn tính. Mảng bám tích tụ mất nhiều năm, thậm chí nhiều thập kỷ. Nhưng khi các động mạch hẹp lại, bệnh nhân có thể nhận thấy các triệu chứng nhẹ. Những triệu chứng này cho thấy tim đang bơm máu nhiều hơn để cung cấp máu giàu oxy cho cơ thể. Xơ vữa động mạch gây bệnh mạch vành. Xơ vữa động mạch là sự tích tụ dần dần các mảng bám trong các động mạch khắp cơ thể. Khi mảng bám ảnh hưởng đến lưu lượng máu trong động mạch vành, người bệnh sẽ mắc bệnh động mạch vành. Mảng bám bao gồm cholesterol, chất thải, canxi và fibrin (một chất giúp đông máu). Khi mảng bám tiếp tục tích tụ dọc theo thành động mạch, động mạch của người bệnh trở nên hẹp và cứng lại.

Mảng bám có thể làm tắc nghẽn hoặc làm hỏng động mạch, làm hạn chế hoặc ngừng lưu lượng máu đến một bộ phận nhất định của cơ thể người bệnh. Khi mảng bám tích tụ trong động mạch vành, cơ tim không thể nhận đủ máu. Vì vậy, trái tim không thể nhận được oxy và chất dinh dưỡng cần thiết để hoạt động bình thường. Tình trạng này được gọi là thiếu máu cơ tim. Nó dẫn đến khó chịu ở ngực (đau thắt ngực) và khiến người bệnh có nguy cơ bị đau tim.

Hình 1.3 mô tả bệnh hẹp động mạch. Với ảnh chụp X-quang động mạch vành, các bác sĩ có thể nhận biết được mạch máu có bị tắc nghẽn hay không, hay nên sử dụng phương pháp điều trị nào để phù hợp với bệnh nhân nhất. Tuy nhiên, rất khó để giải thích trực quan khi nhìn vào ảnh chụp X-quang do chồng chéo của các mạch máu quanh tim (hình 1.4 (b)) hay do tương phản giữa mạch máu và nền. Đây là một thách thức lớn trong nhiều năm qua.



Hình 1.3 Bệnh mạch vành [8].



(a) (b)

Hình 1.4 Hình X-quang động mạch vành:
(a) bệnh hẹp mạch máu và (b) chồng chéo của mạch máu.

Hiện nay, không có xét nghiệm xâm lấn hoặc không xâm lấn nào được sử dụng thường quy để xác định các mảng dễ bị tổn thương ở bệnh nhân [9]. Các mảng dễ bị tổn thương có thể bị vôi hóa hoặc không, do đó làm phức tạp việc xác định nguy cơ tim mạch bằng cách sàng lọc vôi hóa. Có một sự hấp dẫn hợp lý đối với phương pháp đánh giá trực tiếp các động mạch vành, thay vì dựa vào một biện pháp gián tiếp như tuổi tác, lượng cholesterol lưu thông trong máu và các yếu tố nguy cơ truyền thống khác. Những cải tiến trong công nghệ CT hiện nay cho phép hình dung không xâm lấn về vôi hóa trong thành động mạch vành ở bệnh nhân.

Hiện tại có hai phương pháp cơ bản tương đương để hình dung và định lượng vôi hóa động mạch vành—chụp cắt lớp vi tính chùm tia điện tử (EBCT) và chụp cắt lớp vi tính đa đầu dò (MDCT). Cả EBCT và MDCT đều là những hệ thống hình ảnh X-quang lớn và phức tạp. EBCT đã được sử dụng trong gần hai thập kỷ để phát hiện và định lượng vôi hóa mạch vành nhưng không phổ biến rộng rãi như MDCT. Bởi vì các hệ thống phải đủ nhanh để đóng băng chuyển động của tim nhằm thu được thông tin chính xác, một số hệ thống MDCT không được khuyến nghị để đo canxi mạch vành. Chụp CT bằng kỹ thuật tương đối đơn giản và thuận tiện cho bệnh nhân, bệnh nhân chỉ cần nằm yên trong máy chụp CT trong khoảng 10 phút. Không cần chuẩn bị đặc biệt cho xét nghiệm và không có hạn chế về loại thuốc dùng trước hoặc trong khi xét nghiệm. Bệnh nhân được yêu cầu nín thở trong 10 đến 30 giây, tùy thuộc vào nhịp tim và loại máy chụp CT. Tổng thời gian từ cửa đến cửa là khoảng 15 phút.

1.3 Bài toán

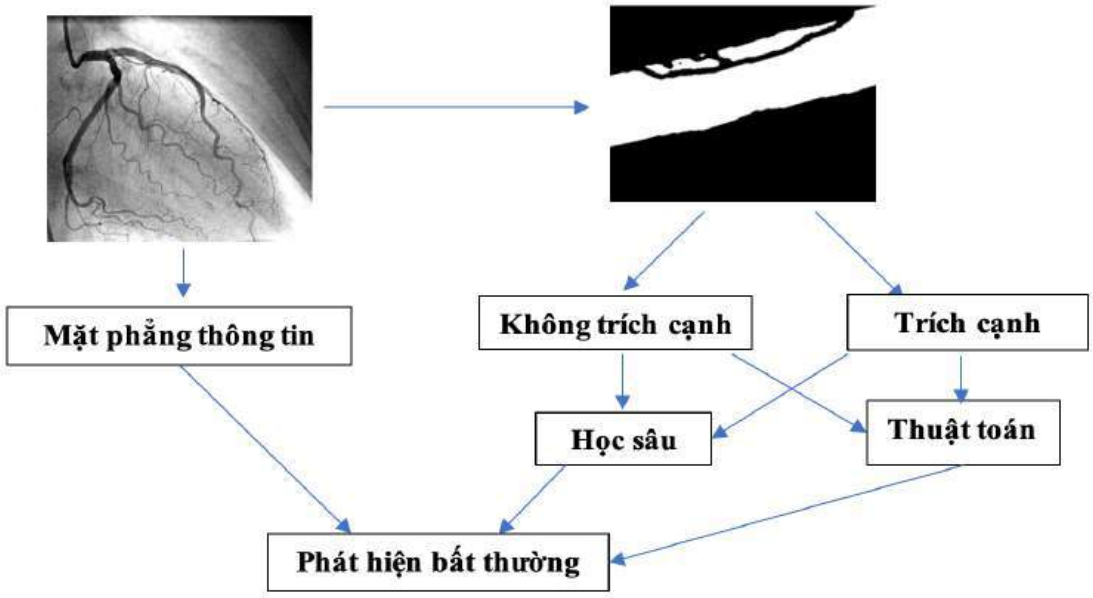
Bằng việc phân tích hình ảnh được chụp từ phương pháp thông tim (Cardiac Catheterization) - một phương pháp chẩn đoán sử dụng kỹ thuật chụp X-quang mạch máu bằng việc bơm vào mạch máu chất cản quang, để nghiên cứu về tim [8]. Bác sĩ có thể nhận biết được mạch máu có bị tắc nghẽn hay không, để sử dụng phương pháp điều trị phù hợp với bệnh nhân nhất. Tuy nhiên, do tính chất của hình ảnh X-quang, giữa mạch máu và nền thường có độ tương phản thấp, hình ảnh nhiễu từ bóng của xương sườn và các mô xung quanh đè lên. Ngoài ra, hình dạng mạch máu không xác

định, chiều rộng của mạch máu phụ thuộc vào loại mạch máu, chiều rộng thường thay đổi dọc theo mạch máu; cũng như thể trạng người bệnh, chủng tộc người bệnh, ….; đặc biệt thời điểm chụp ảnh cũng ảnh hưởng đến ảnh mạch máu, vì thời điểm chụp có máu đang đi qua sẽ thấy thành mạch, nhưng nếu thời điểm chụp mà máu đã đi qua nên thành mạch xẹp xuống thì mạch máu gần như trong suốt dẫn đến rất khó thấy rõ mạch máu. Nên việc trích xuất mạch máu từ chụp X-quang đã là một vấn đề thách thức.

Ảnh X-quang chụp mạch máu góp phần quan trọng trong y học, giúp cho quá trình phát hiện bệnh và điều trị của bệnh nhân được nhanh chóng và hoàn thiện. Do tính chất của ảnh X-quang, những mao mạch thường có màu sắc khá tối, gần với màu của nền. Do đó, khi thực hiện trích xuất mạch máu, ngoài động mạch và tĩnh mạch, nếu muốn trích xuất cả những mao mạch thì nhiễu sẽ xuất hiện càng nhiều, một tình huống không mong muốn trong xử lý ảnh, hình 1.4.

Vì với sự phức tạp của mạch vành (hình 1.4) như đã trình bày thì rất khó có thể phát hiện vùng bất thường trên mạch vành trực tiếp nên luận án đề xuất giải quyết bài toán "trích xuất mạch vành và phát hiện bất thường trên mạch vành hỗ trợ trong chẩn đoán" sẽ phải giải quyết thông qua 02 bài toán:

- Bài toán 1: trích xuất (phân đoạn) mạch vành để xác định biên mạch vành. Đây là bài toán từ ảnh mạch vành ban đầu, luận án xây dựng phương pháp trích xuất sao cho có ảnh mới, ảnh mới là ảnh nhị phân, trong ảnh chỉ còn cây mạch vành mà không có bất kỳ đối tượng nào khác.
- Bài toán 2: phát hiện vùng bất thường (nếu có) trên mạch vành, hình 1.5. Với dữ liệu đầu vào là đoạn mạch vành, luận án xây dựng phương pháp để xác định đoạn mạch này có bất thường hay không (bất thường ở đây là mạch bị hẹp hay bị phình)?



Hình 1.5 Phương pháp giải quyết bài toán phát hiện bất thường trên ảnh mạch vành.

1.4 Dữ liệu

Luận án sử dụng dữ liệu cung cấp từ bệnh viện Đại học Quốc gia Chonnam, Hàn Quốc. Dữ liệu này đã được hội đồng y đức bệnh viện cho phép, cũng như sự đồng ý của bệnh nhân. Dữ liệu gồm ban đầu của 48 bệnh nhân, mỗi ảnh màu (màu xám) có kích thước 512×512 điểm ảnh, hình 1.4, để trích xuất mạch vành (phân đoạn), luận án gọi là bộ dữ liệu A. Bộ dữ liệu A được sự hỗ trợ từ chuyên gia để có ground-truth cho kiểm định. Sau khi phân đoạn bộ dữ liệu A, luận án xác định các điểm nối giữa mạch chính và mạch thứ cấp, ở điểm nối sẽ cắt từng ảnh là các đoạn mạch vành. Ảnh của các đoạn mạch đã được các bác sỹ chuyên khoa đánh giá và chọn lựa để xây dựng bộ dữ liệu có mỗi ảnh là một đoạn mạch vành thứ cấp (bộ dữ liệu B).

Từ dữ liệu là các đoạn mạch: đã được phân đoạn và chưa phân đoạn (trong phương pháp phân đoạn đã xác định được các đoạn mạch – đây là dữ liệu đoạn mạch chưa phân đoạn) sẽ tiến hành xác định mạch vành có bất thường hay không (hình 1.6)? Bộ dữ liệu B ban đầu có 124 đoạn mạch có kích thước 100×100 điểm ảnh, trong đó có 102 ảnh bất thường và 22 ảnh bình thường. Do dữ liệu được thu nhận từ bệnh nhân nên số lượng ảnh bình thường sẽ ít hơn so với số lượng ảnh bất thường. Với bộ dữ

liệu B thì số lượng ít để tiến hành phân loại và đồng thời dữ liệu bị mất cân bằng, luận án dùng phương pháp sinh thêm dữ liệu thông qua các phương pháp biến đổi Affine (như: co, giãn, xoay, tịnh tiến, nhưng không sử dụng phương pháp biến dạng – vì biến dạng sẽ làm mất tính chất của ảnh mạch vành) dữ liệu để có bộ dữ liệu C có 1404 ảnh bất thường và 1115 ảnh bình thường. Sau đó luận án thu thập thêm dữ liệu từ bệnh viện để bộ dữ liệu D có 2906 ảnh bất thường và 3022 ảnh bình thường, bảng 1.1. Các dữ liệu sinh thêm đều được các chuyên gia của bệnh viện kiểm tra đánh giá để có thể sử dụng trong nghiên cứu.



Hình 1.6 Đoạn mạch vành sau khi được phân đoạn.

Bảng 1.1 Dữ liệu

Bộ dữ liệu	**Kích thước**	**Bình thường**	**Bất thường**	**Tổng cộng**
A	512×512	22	102	124
B	100×100	22	102	124
C	100×100	1115	1404	2519
D	100×100	3022	2906	5928

Trong số các bộ dữ liệu tin cậy được công bố, NCS đã khảo sát trên 03 bộ dữ liệu có liên quan; CADICA, CardigramplusC4D, và ARCADE:

- CADICA là bộ dữ liệu chụp động mạch vành xâm lấn có chú thích của 42 bệnh nhân. Trong hình ảnh đã được đánh giá mức độ tổn thương thường được thực hiện bằng ước tính trực quan, đây là yếu tố chủ quan và có sự khác biệt giữa các quan sát viên. Việc nhận dạng chính xác các tổn thương là rất quan trọng để chẩn đoán và điều trị chính xác. Bộ dữ liệu này không phù hợp với tiêu chí của luận án nên luận án không được sử dụng dữ liệu này.
- CardigramplusC4D Consortium là bộ dữ liệu tóm tắt từ các phân tích tổng hợp về bệnh động mạch vành và nhồi máu cơ tim, đây là bộ dữ liệu metadata, không phải là ảnh mạch vành nên luận án không được sử dụng dữ liệu này.
- ARCADE là bộ dữ liệu bao gồm tổng cộng 1000 ảnh (dữ liệu đã được dùng phương pháp tăng cường), trong đó có 500 ảnh dùng để huấn luyện, 200 ảnh dùng để đánh giá, và 300 ảnh dùng để kiểm thử. Mỗi ảnh là ảnh màu xám kích thước 512×512 điểm ảnh. Ảnh dữ liệu là một phần của mạch vành, không phải toàn bộ mạch vành. Trong bộ kiểm thử có 126 ảnh bất thường và 174 ảnh bình thường. Bộ dữ liệu ARCADE chỉ có nhãn cho từng ảnh là có bệnh hay không (bất thường: phình hay hẹp) mà không có ảnh groundtruth dùng cho đánh giá sau khi phân đoạn. Nên chỉ có thể dùng ảnh màu cho bài toán phân loại. Vì thế NCS dùng bộ dữ liệu này để đánh giá thêm với phương pháp dùng mặt phẳng thông tin, gồm mặt phẳng bit và mặt phẳng màu.

Dựa trên đặc tính của bài toán tiếp cận và sự sẵn sàng cung cấp dữ liệu, 02 bộ dữ liệu đầu chưa phù hợp để sử dụng. Do đó luận án sử dụng thêm bộ dữ liệu ARCADE [10] để đánh giá thêm. Bộ dữ liệu bao gồm tổng cộng 1000 ảnh (dữ liệu cũng được dùng phương pháp tăng cường), trong đó có 500 ảnh dùng để huấn luyện, 200 ảnh dùng để đánh giá, và 300 ảnh dùng để kiểm thử. Mỗi ảnh là ảnh màu xám kích thước 512×512 điểm ảnh. Ảnh dữ liệu là một phần của mạch vành (đoạn mạch vành), không phải toàn bộ mạch vành; hình 1.7. Trong bộ kiểm thử có 126 ảnh bất thường và 174 ảnh

bình thường. Bộ dữ liệu ARCADE chỉ có nhãn cho từng ảnh là có bệnh hay không (bất thường: phình hay hẹp) mà không có ảnh groundtruth dùng cho đánh giá sau khi phân đoạn.



Hình 1.7 Ảnh (một phần mạch vành) dữ liệu của bộ dữ liệu ARCADE.

1.5 Kết chương

Từ kiến thức về ảnh y khoa và các phương pháp xử lý ảnh y khoa, cũng như các tính chất đặc biệt phức tạp của ảnh mạch vành; luận án đề xuất phương pháp phân đoạn ảnh mạch vành phù hợp. Với những kiến thức trình bày thì nội dung được tóm lược công bố ở [CT4].

CHƯƠNG 2 CƠ SỞ LÝ THUYẾT

Chương 2 luận án trình bày các cơ sở lý thuyết được dùng trong luận án như cơ sở mạng neural nhân tạo làm nền tảng cho học sâu, mà đặc biệt là Unet; cũng như phương pháp trích khung xương. Những nội dung lý thuyết cơ sở này được sử dụng làm kiến thức nền tảng để giải quyết cụ thể hai bài toán: (1) phân đoạn mạch vành và (2) phát hiện bất thường trên mạch vành.

2.1 Phương pháp trích khung xương

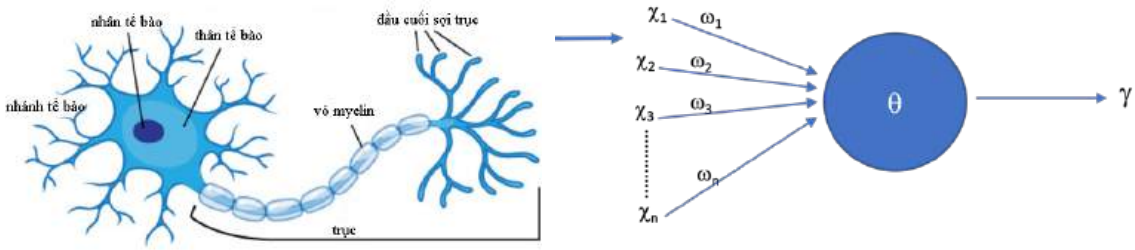
Xương được coi như hình dạng cơ bản của một đối tượng, với số ít điểm các điểm ảnh cơ bản và biểu diễn dạng đường có độ rộng một điểm ảnh. Ta có thể lấy được thông tin về hình dạng nguyên bản của một đối tượng thông qua xương. Việc trích khung xương đã có nhiều phương pháp được đề xuất và nghiên cứu [11], [12]. Thuật toán trích xuất khung xương do tác giả Zhang-Suen [13] đề xuất vào năm 1984, là thuật toán được sử dụng rộng rãi nhất làm nền tảng cho nhiều nghiên cứu sau này. Thuật toán Zhang-Suen dựa trên đường biên của đối tượng và được thiết kế có thể xử lý song song, có nghĩa là giá trị mới cho bất kỳ điểm ảnh nào có thể được tính toán chỉ dùng các giá trị đã biết từ trong vòng lặp ngay trước đó mà không cần quan tâm đến các giá trị ở các vòng lặp trước nữa, làm cho tốc độ của thuật toán rất nhanh [13].

2.2 Mạng neural nhân tạo

Động vật nói chung và con người nói riêng, để xử lý các thông tin, hoạt động điều khiển, điều hoà và phối hợp mọi hoạt động của các cơ quan và hệ cơ quan trong cơ thể nhằm tạo sự thích nghi với các thay đổi từ môi trường bên trong và bên, cần đến một mạng lưới mạng lưới thần kinh phức tạp với hàng nghìn tỷ của tế bào neural trao đổi xung điện ngắn.

Lấy cảm hứng vào từ hoạt động của mạng thần kinh, các thuật toán máy tính bắt chước các cấu trúc sinh học này và được gọi là mạng neural nhân tạo (Neural Network - NN), hình 2.1

Theo cách tiếp cận thông thường trong lập trình, ta cho máy tính biết phải làm gì, giải quyết các vấn đề lớn thành nhiều nhiệm vụ nhỏ, định nghĩa rõ ràng các nhiệm vụ mà máy tính có thể dễ dàng thực hiện. Ngược lại, trong một mạng neural, chúng ta không nói cho máy tính biết cách giải quyết vấn đề của chúng ta. Thay vào đó, mô hình sẽ học từ dữ liệu quan sát, rồi tìm ra giải pháp riêng cho vấn đề cần giải quyết [14].



Hình 2.1 Cấu trúc tổng quát của một lớp trong mạng neural nhân tạo

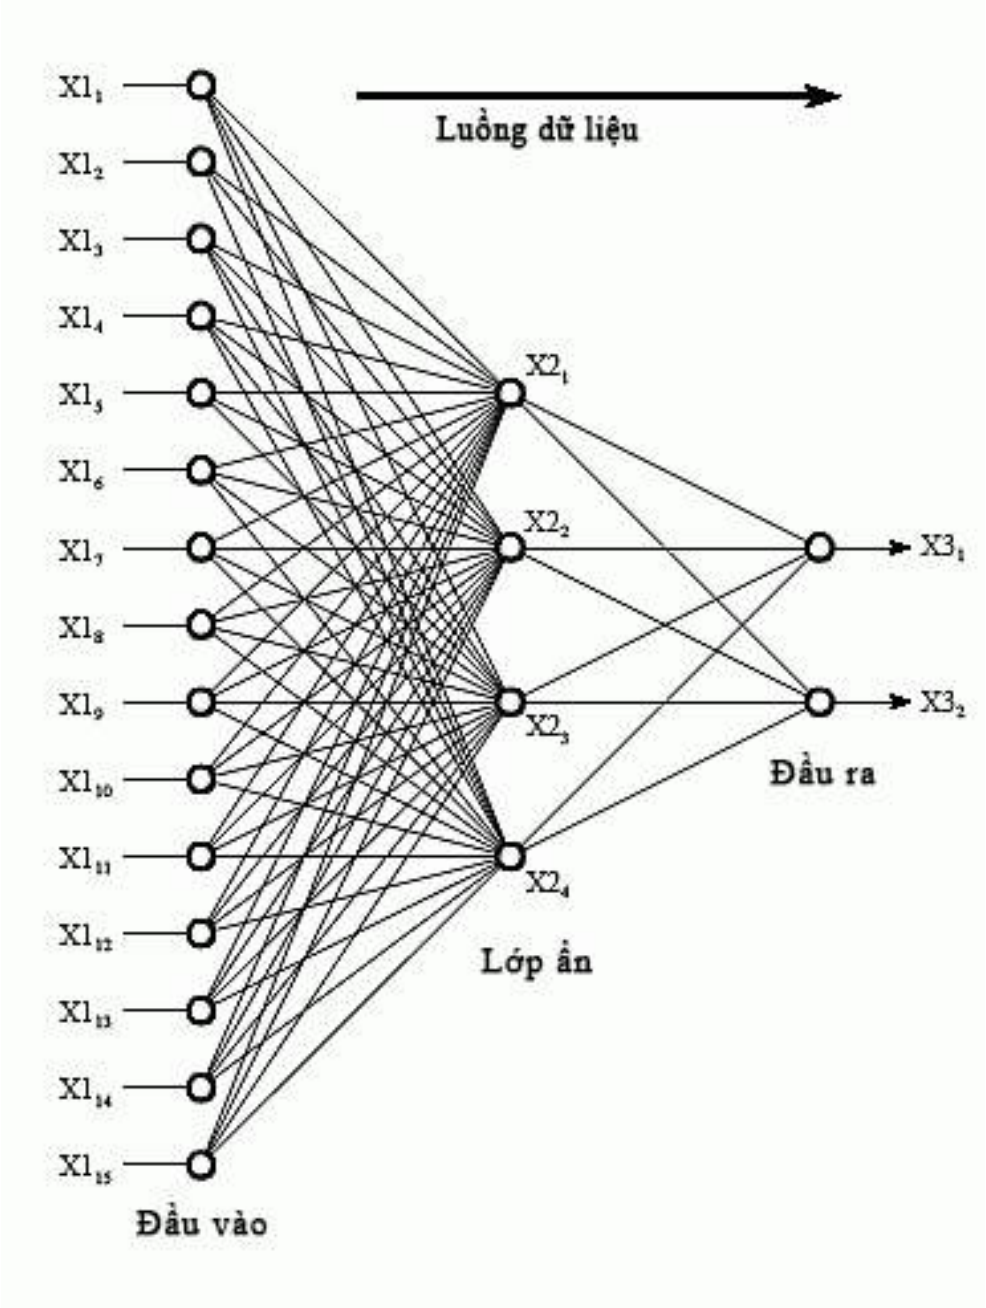
2.2.1 Kiến trúc tổng quát

Có nhiều cấu trúc mạng thần kinh khác nhau đã được xây dựng. Cấu trúc được sử dụng phổ biến nhất được hiển thị trong hình 2.2 [15]. Một mạng neural nhân tạo sẽ gồm 03 lớp cơ bản: lớp đầu vào, lớp ẩn (số lượng lớp ẩn là không giới hạn), lớp đầu ra. Mỗi lớp bao gồm một hoặc nhiều phần tử, được biểu thị trong sơ đồ này bằng các vòng tròn nhỏ. Các đường giữa các phần tử chỉ ra luồng thông tin từ phần tử này sang phần tử tiếp theo. Hình 2.2 thể hiện thông tin chỉ truyền từ đầu vào sang đầu ra (nghĩa là từ trái sang phải).

Tổng quan một mạng neural nhân tạo sẽ gồm:

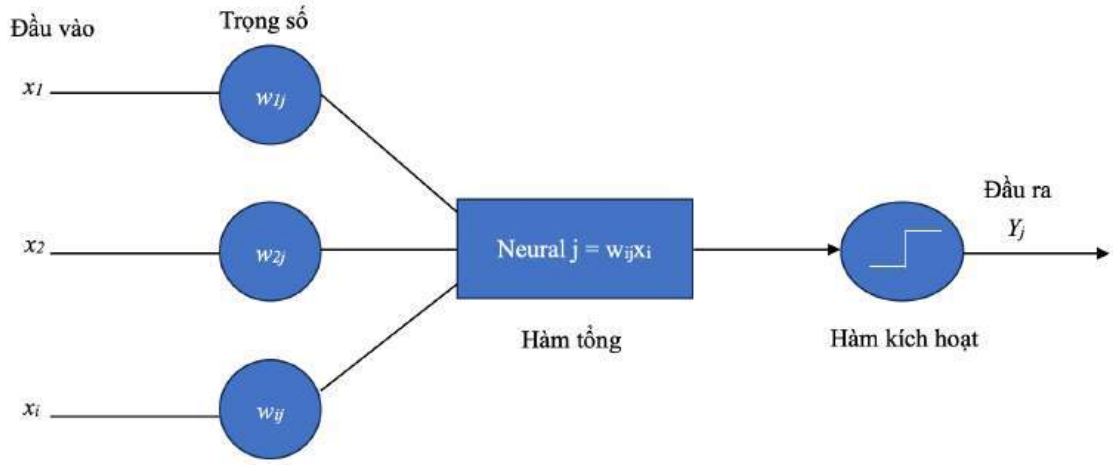
- Phần tử xử lý (Processing Elements – PE): Các PE còn gọi là neural, là các phần tử của mạng thần kinh, mỗi neural nhận các dữ liệu vào xử lý chúng và cho ra một kết quả duy nhất. Kết quả xử lý của một neural có thể làm đầu vào cho các neural khác.
- Lớp đầu vào: Là tầng bên trái cùng của mạng, nơi đầu vào của mạng sẽ nhận các thông tin thô. Mỗi đầu vào tương ứng với một thuộc tính của dữ liệu.

- Lớp ẩn: Là tầng nằm giữa tầng vào và tầng ra thể hiện cho việc suy luận logic của mạng. Gồm các neural nhận dữ liệu đầu vào từ các neural ở lớp trước đó và chuyển đổi các đầu vào này cho các lớp xử lý tiếp theo.
- Lớp đầu ra: Là tầng bên phải cùng của mạng, thể hiện cho các đầu ra của mạng.



Hình 2.2 Cấu trúc tổng quát neural.

Một lớp là sự kết hợp của hai hoặc nhiều neural và một mạng cụ thể có thể chứa một hoặc nhiều lớp như vậy. Với một lớp trong mạng neural có cấu trúc như hình 2.3.



Hình 2.3 Cấu trúc tổng quát của một lớp trong mạng neural nhân tạo.

Chi tiết một lớp trong mạng neural có các thành phần sau :

a. Weight - Trọng số liên kết $w_{i,j}$: Thể hiện trọng số liên kết giữa một neural thứ i trong một lớp trước với một neural j khác ở lớp sau. Quá trình học thực sự là quá trình cập nhật các giá trị trọng số để hàm lỗi để có kết quả tốt.

b. Hàm tổng (hay còn gọi là hàm kết hợp): Thường dùng để tính tổng của tích các đầu vào với trọng số liên kết của nó, giả sử lớp trước có n neural thì tại neural thứ j trong lớp tiếp theo, hàm kết hợp được tính theo công thức (2.1).

$$z_j = \sum_{1}^{n} w_{ij}.x_i \qquad (2.1)$$

Với x_i là thông tin đầu vào và w_{ij} là trọng số tương ứng cho kết quả z_j

c. Ngưỡng θ_j (còn gọi là độ lệch – bias): là sự sai khác giữa trung bình dự đoán của mô hình chúng ta xây dựng với giá trị chính xác đang cố gắng để dự đoán. Một mô hình với trị số bias cao đồng nghĩa với việc mô hình đó không quan tâm nhiều tới dữ liệu huấn luyện, khiến cho mô hình trở nên

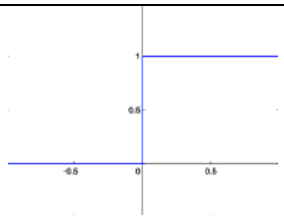
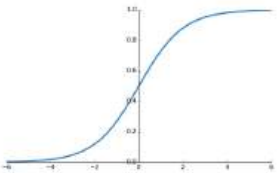
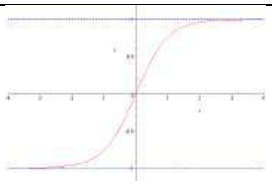
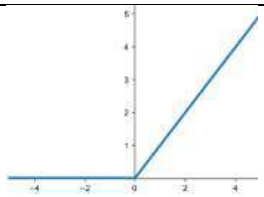
đơn giản quá. Điều này thường dẫn đến việc mô hình có mức độ lỗi cao cả trên tập huấn luyện và tập kiểm thử.

d. Hàm kích hoạt: Hàm này được dùng để giới hạn phạm vi đầu ra của mỗi neural. Hàm sẽ nhận đầu vào là kết quả của hàm tổng và ngưỡng, công thức (2.2). Có φ là hàm kích hoạt.

$$Y_j = \varphi(z_j + \theta_j) = \varphi\left(\sum_{1}^{n} w_{ij}.x_i + \theta_j\right) \quad (2.2)$$

Có nhiều loại hàm kích hoạt, trong đó các hàm kích hoạt khác nhau sẽ cho mục đích sử dụng khác nhau. Bảng 2.1 thể hiện các hàm kích hoạt thường dùng.

Bảng 2.1 Các loại hàm kích hoạt phổ biến.

Tên hàm	**Đồ thị**	**Định nghĩa**
Hàm ngưỡng (Threshold)		$\varphi(v) = \begin{cases} 1 \ nếu \ v \geq 0 \\ 0 \ nếu \ v < 0 \end{cases}$
Hàm Sigmoid		$\varphi(v) = \frac{1}{1 + \exp^{(-v)}}$
Hàm tiếp tuyến Hyperbolic (Hyperbolic Tangent)		$\varphi(v) = \tan \mathrm{h}(v)$
Hàm kích hoạt tuyến tính chỉnh lưu (Rectified Linear Unit - ReLU)		$\varphi(v) = \max(0, z_j + \theta_j)$

2.2.2 Quá trình học

Quá trình học của NN bao gồm các bước:

- Bắt đầu với các giá trị khởi tạo ngẫu nhiên cho các tham số (trọng số $w_{i,j}$ và các bias θ_j).
- Đưa tập dữ liệu đầu vào để thực hiện quá trình học của mạng NN.
- So sánh các giá trị dự đoán thu được với giá trị mong đợi và tính toán mức độ lỗi.
- Thực hiện quá trình quay lui để truyền mức độ lỗi này đến hàm để điều chỉnh các tham số nhằm tạo nên giá trị kết quả sẽ có mức độ lỗi giảm theo mong muốn.
- Tiếp tục lặp lại trong các bước trên cho đến khi mô hình nhận được một bộ tham số mà độ lỗi là thấp nhất có thể, đây được xem là mô hình tốt nhất thu được.

2.2.2.1 Hàm lỗi

Hàm lỗi [16] (loss function) là một phần quan trọng trong NN, được sử dụng để đo lường sự không nhất quán giữa giá trị dự đoán và giá trị thực tế. Đó là một giá trị không âm và cho biết mức độ tốt của mô hình học, mức độ tốt của mô hình học tăng cùng với việc giảm được giá trị của hàm lỗi.

Trong hầu hết các mô hình NN, hàm lỗi được tính như sự chênh lệch giữa kết quả thực tế và kết quả dự đoán, công thức (2.3). Với $\mathcal{L}_D$ là giá trị hàm lỗi tính trên toàn bộ dữ liệu D với hàm lỗi L xem xét sự khác biệt giữa giá trị dự đoán $f_w(x)$ của mô hình và giá trị thực tế y dựa trên độ đo phù hợp cho loại dữ liệu tương ứng với công thức (2.3).

$$\mathcal{L}_D(f_w) = \frac{1}{|D|} \sum_{(x,y)\in D} L(f_w(x), y) \tag{2.3}$$

Các hàm lỗi khác nhau sẽ đưa ra các giá trị lỗi khác nhau cho cùng một dự đoán, điều này dẫn đến sẽ ảnh hưởng đáng kể đến hiệu suất của mô hình. Các hàm lỗi khác nhau được sử dụng để giải quyết các loại nhiệm vụ khác nhau cho các loại dữ liệu khác nhau.

2.2.2.2 Gradient Descent

Gradient của một hàm được định nghĩa là một vector trong trường vector, giá trị độ lớn của Gradient cho biết mức độ biến thiên, hướng của vector cho biết hướng thay đổi giá trị. Tổng quát, Gradient của một hàm có thể được tìm thấy bằng cách áp dụng toán tử vector cho hàm vô hướng. Loại trường vector này được gọi là trường vector Gradient. Gradient của một hàm đa biến $f(x_1, x_2, \dots x_n)$ là một vector chứa tất cả các đạo hàm riêng phần của hàm f và được ký hiệu là Δf. Phần tử i trong Gradient là đạo hàm riêng phần của hàm f theo biến x_i [17].

Gradient Descent là thuật toán tối ưu hóa lặp bậc nhất để tìm cực tiểu cục bộ của một hàm khả vi. Ý tưởng là thực hiện các bước lặp lại theo hướng ngược lại của độ dốc (hoặc độ dốc gần đúng) của hàm tại điểm hiện tại, bởi vì đây là hướng dốc nhất. Ngược lại, bước theo hướng của Gradient sẽ dẫn đến cực đại cục bộ của hàm đó; quy trình sau đó được gọi là tăng dần độ dốc. Phương pháp này đặc biệt hữu ích trong máy học để giảm thiểu hàm lỗi [18].

Phương pháp Gradient Descent được Augustin-Louis Cauchy (là người đầu tiên) đề xuất vào năm 1847 [18]. Sau đó Jacques Hadamard đã độc lập đề xuất một phương pháp tương tự vào năm 1907 [19]. Các đặc tính hội tụ của nó đối với các bài toán tối ưu phi tuyến tính được Haskell Curry nghiên cứu lần đầu tiên vào năm 1944 [20], với phương pháp này ngày càng được nghiên cứu kỹ lưỡng và sử dụng trong những thập kỷ tiếp theo [21] [22].

Phương pháp Gradient Descent được dùng để giải bài toán khi cho hàm $f : \mathbb{R}^n \to \mathbb{R}$ là hàm khả vi, mục tiêu tìm x^* để thỏa (2.4).

$$f(x^*) = \min f(x), \forall x \in D \tag{2.4}$$

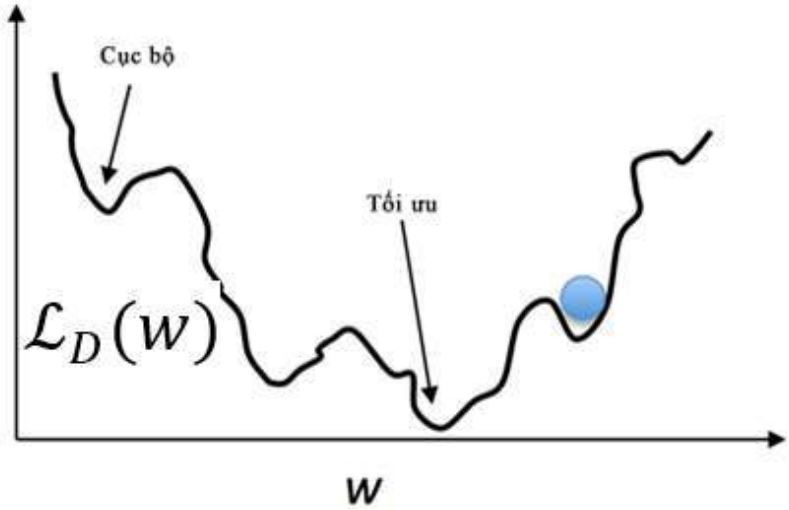
Với D là miền dữ liệu. Chúng ta có giải thuật của Gradient Descent được trình bày với các bước lặp, thuật toán 2.1. Thuật toán 2.1 có bốn bước, bước đầu tiên với giá trị $x^{(0)}$ của hàm $f(x), \forall x \in D$, chúng ta tính gradient $\nabla f(x^{(0)})$ ở bước thứ hai. Trong bước thứ ba, chúng ta tính $x^{(k+1)}$ mới theo công thức (2.5) với t_0 là hệ số học (giá trị này có thể là hệ số cố định hay có thể tính bằng công thức (2.6), khi dùng công thức (2.6) thì các giá trị học này có thể được thay đổi tùy theo trình trạng học của hệ thống (hệ số học thích ứng thay đổi theo dữ liệu và mô hình), hoặc có thể xây dựng hàm thay đổi theo giá trị nhận được qua các bước lặp. Khi giá trị $x^{(k+1)}$ và $x^{(k)}$ không thay đổi thì thuật toán dừng hoặc dừng khi quá số lần hữu hạn bước lặp đã được thiết lập.

Thuật toán 2.1 Các bước thực hiện Gradient Descent	
Input:	giá trị $x^{(0)}$ và hàm $f(x), \forall x \in D$
Output:	giá trị x^* sao cho $f(x^*) = \min f(x), \forall x \in D$
Bước 1: Bắt đầu tại một điểm $x^{(0)} \in D$, (giá trị bắt đầu). ***Bước 2:*** Tính giá trị Gradient tại điểm $x^{(k)}$ là $\nabla f(x^{(k)})$, với $k \geq 0$. Với giá trị k khởi tạo ban đầu là 0. ***Bước 3:*** Xác định giá trị mới $x^{(k+1)}$ theo công thức (2.5). Với t_k hệ số học, t_k có thể là hệ số cố định hay có thể dùng bằng công thức (2.6), hoặc có thể xây dựng hàm thay đổi theo giá trị nhận được qua các bước lặp. $$x^{(k+1)} = x^{(k)} - t_k \nabla f\left(x^{(k)}\right) \quad (2.5)$$ $$t_k = \arg\min_{t \geq 0} f\left(x^{(k)} - t \nabla f\left(x^{(k)}\right)\right) \quad (2.6)$$ ***Bước 4:*** Nếu điều kiện dừng thỏa thì dừng thuật toán; nếu chưa thì quay lại bước 2.	

2.2.2.3 Ứng dụng Gradient Descent trong NN

Gradient Descent sử dụng để cập nhật các trọng số trong mô hình NN nhằm cực tiểu hóa hàm lỗi trong quá trình học từ dữ liệu, hình 2.4. Giả sử ta cần tìm tham số $w \in$

$\mathbb{R}^n$ (w là bộ tham số của mô hình học) để tối thiểu hoá hàm lỗi $\mathcal{L}_D(w)$. Đầu tiên chúng ta sẽ phát sinh ngẫu nhiên giá trị $w^{(0)}$. Sau đó áp dụng giải thuật Gradient Descent để tìm giá trị $w^{(*)}$ sao cho $\mathcal{L}_D(w^{(*)})$ đạt giá trị cực tiểu, nghĩa là mô hình học sẽ học được nhiều thông tin nhất.



Hình 2.4 Đồ thị mối quan hệ hàm lỗi và trọng số.

2.2.2.4 Lan truyền ngược

Lan truyền ngược là một kỹ thuật được sử dụng để giúp mô hình học lại dữ liệu với các tham số sẽ được thay đổi sao cho giảm thiểu lỗi trong NN. Lỗi này được tính toán dựa trên hàm lỗi. Quá trình này sẽ truyền lại lỗi và điều chỉnh trọng số theo phương pháp đã xây dựng để giảm lỗi. Quá trình này được lặp lại nhiều lần cho đến khi đảm bảo rằng sự khác biệt giữa giá trị dự đoán và kết quả mong đợi là ít nhất (lỗi đã cực tiểu, có thể toàn cục, có thể cục bộ gần xấp xỉ toàn cục). Quá trình lan truyền ngược được thực hiện theo các bước sau:

Bước 1: Lan truyền tiến

Lần lượt tính các $x_i^{(t)}$ theo công thức (2.7).

$$z_i^{(t+1)} = \sum_{j=1}^{n^{(t)}} w_{ij}{}^{(t+1)}.x_j{}^{(t)} + \theta_i{}^{(t+1)}$$
$$x_i^{(t+1)} = \varphi\left(z_i{}^{(t+1)}\right) \quad (2.7)$$

Trong đó:

$n^{(t)}$: số lượng neural trong tầng t tương ứng.

$x_j{}^{(t)}$: neural thứ j của tầng t.

$w_{ij}{}^{(t+1)}$: trọng lượng của đầu vào $x_j{}^{(t)}$ đối với neural thứ j của tầng $(t+1)$.

$\theta_i{}^{(t+1)}$: hệ số bias của neural thứ i ở tầng $(t+1)$.

$x_i^{(t+1)}$: Đầu ra của neural $x_i^{(t)}$ ứng với hàm kích hoạt $\varphi\left(z_i{}^{(t+1)}\right)$ tương ứng.

Chúng ta hình thức hóa tham số của mỗi tầng thành một ma trận có các cột tương ứng với tham số mỗi neural thì ta có thể tính toán cho toàn bộ các neural trong một tầng bằng vector như công thức (2.8).

$$\begin{aligned} z^{(t+1)} &= W^{(t+1)} \cdot z^{(t)} \\ x^{(t+1)} &= \varphi\left(z^{(t+1)}\right) \end{aligned} \tag{2.8}$$

Bước 2: Tính đạo hàm theo z ở tầng ra. Viết lại theo dạng vector, thì đạo hàm được tính theo công thức (2.9).

$$\frac{\partial \mathcal{L}}{\partial z^{(N)}} = \frac{\partial \mathcal{L}}{\partial x^{(N)}} \frac{\partial x^{(N)}}{\partial z^{(N)}} \tag{2.9}$$

(với N là số lớp của mạng NN)

Bước 3: Lan truyền ngược

Tính đạo hàm theo z ngược lại từ $t = (N-1) \rightarrow 2$ (với N : số lớp của mạng NN) theo công thức (2.10).

$$\begin{aligned} \frac{\partial \mathcal{L}}{\partial z^{(t)}} &= \frac{\partial \mathcal{L}}{\partial z^{(\mathrm{t+1})}} \frac{\partial z^{(\mathrm{t+1})}}{\partial x^{(t)}} \frac{\partial x^{(t)}}{\partial z^{(t)}} \\ &= \left(\left(W^{(\mathrm{t+1})}\right)^T \frac{\partial \mathcal{L}}{\partial z^{(\mathrm{t+1})}}\right) \frac{\partial x^{(t)}}{\partial z^{(t)}} \end{aligned} \tag{2.10}$$

Với các $z^{(t)}$ được tính ở bước "lan truyền tiến" và $\frac{\partial \mathcal{L}}{\partial z^{(t+1)}}$ được tính ở vòng lặp ngay trước đó. Sau đó tính các đạo hàm theo (2.11)

$$\begin{aligned} \frac{\partial \mathcal{L}}{\partial W^{(t)}} &= \frac{\partial \mathcal{L}}{\partial z^{(t)}} \frac{\partial z^{(t)}}{\partial W^{(t)}} \\ &= \frac{\partial \mathcal{L}}{\partial z^{(t)}} \left(x^{(\mathrm{t}-1)}\right)^T \end{aligned} \tag{2.11}$$

Với $x^{(t-1)}$ được tính ở bước "lan truyền tiến" và $\frac{\partial \mathcal{L}}{\partial z^{(t)}}$ được xác định ở bước "lan truyền ngược". Từ đó theo thuật toán Gradient Descent, với một tốc độ học α, để giảm lỗi, ta thêm vào trọng số $W^{(t)}$ tại lớp thứ t một đại lượng theo công thức (2.12).

$$\Delta W^{(t)} = -\alpha \frac{\partial \mathcal{L}}{\partial W^{(t)}} \tag{2.12}$$

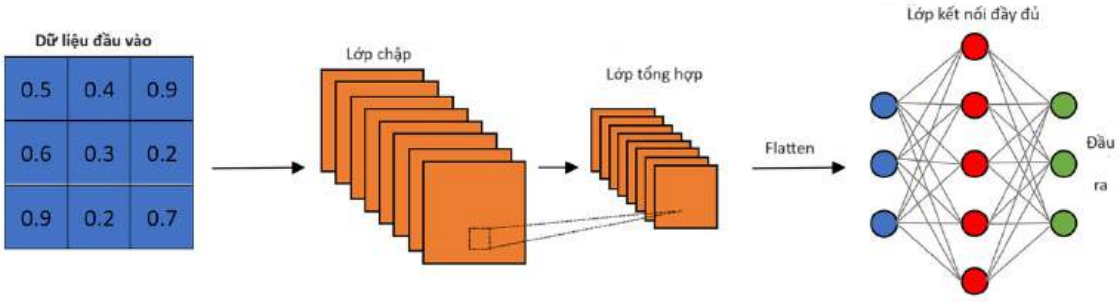
2.3 Học sâu

Học sâu là một phần của máy học, vì thế bản chất của học sâu cũng mang những tính chất của máy học, nhưng cho phép học được nhiều thông tin "sâu" hơn dựa vào những cải tiến của mô hình, thuật toán thông qua nhiều tầng ẩn hơn, mô hình học sâu có thể: (1) tự động trích xuất đặc trưng từ dữ liệu và (2) có thể liên kết thông tin ở gần và ở xa trong mô hình để có thể học được thông tin "sâu" hơn [13]. Với NN thông thường thì việc chọn phương pháp trích xuất đặc trưng sẽ là một bài toán phức tạp, người thiết kế NN phải hiểu rõ tính chất của dữ liệu ở bài toán cần giải quyết để chọn được phương pháp phù hợp, với phương pháp trích đặc trưng khác nhau sẽ cho kết quả học khác nhau với cùng một mô hình học. Vì thế có phương pháp trích đặc trưng tự động không phụ thuộc phương pháp trích đặc trưng thì có thể tập trung xây dựng mô hình học tốt hơn. Phương pháp trích đặc trưng tự động này còn cho phép trích thông tin từ "nông" đến "sâu" để mô hình học được nhiều thông tin nhất giải quyết bài toán tốt hơn. Quá trình học của một NN sẽ áp dụng phương pháp truyền thông tin đầu ra của neural này sẽ là thông tin đầu vào của neural kế tiếp; điều này dẫn đến những thông tin đến một neural nào đó thì thông tin này đã bị biến đổi khi đi qua các neural trước đó; nếu thiết kế được mô hình cho phép giữ được thông tin ban đầu mà kết hợp với

thông tin đã trải qua nhiều neural khác nhau thì khả năng hiểu được nhiều về dữ liệu sẽ "sâu" hơn.

2.3.1 Mạng neural tích chập

Mạng neural tích chập (Convolutional Neural Networks - CNN) là một trong những mô hình học sâu phổ biến hiện nay. CNN dùng phương pháp tích chập để trích đặc trưng của dữ liệu một cách tự động. Không những vậy, mỗi tầng sẽ được thiết kế các lớp chập khác nhau nên CNN sẽ học được thông tin từ dữ liệu "sâu" hơn. CNN được dùng trong nhiều bài toán như nhân dạng ảnh, phân tích video, ảnh MRI, hoặc các bài toán thuộc lĩnh vự xử lý ngôn ngữ tự nhiên …, hầu hết đều giải quyết tốt các bài toán này. CNN có kiến trúc cơ bản vẫn là mạng neural, nhưng được cải tiến cho trích đặc trưng tự động và kết hợp chúng thông qua lớp tích chập và tổng hợp, hình 2.5 Kiến trúc của CNN [15]



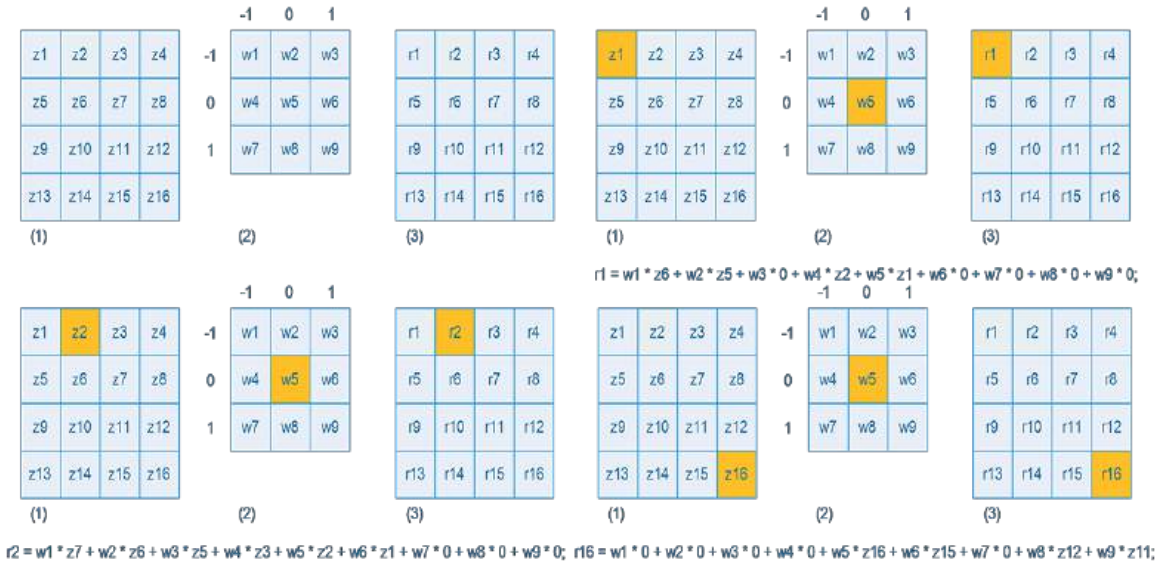
Hình 2.5 Kiến trúc của CNN.

2.3.2 Lớp tích chập

Lớp tích chập là lớp đầu tiên trích dùng để trích xuất các đặc trưng từ ảnh. Công thức tích chập giữa dữ liệu $f(x,y)$ và bộ lọc $k(x,y)$ (kernel) [14] theo công thức (2.13). Thông qua việc chập bộ lọc $k(x,y)$ trượt trên toàn bộ dữ liệu chúng ta sẽ có thông tin mới.

$$k(x,y) \otimes f(x,y) = \sum_{u=-m/2}^{m/2} \sum_{v=-n/2}^{n/2} k(u,v) f(x-u, y-v) \tag{2.13}$$

Ví dụ minh hoạ quá trình tính tích chập, hình 2.6. Ảnh minh hoạ theo thứ tự từ trái qua phải và từ trên xuống dưới. Ảnh cuối cùng là kết quả sau khi thực hiện di chuyển kernel hết toàn bộ ảnh. Ký hiệu: (1) ma trận đầu vào, (2) kernel, (3) feature map, hình 2.6. Thông thường thì kích thước của feature map sẽ nhỏ hơn ma trận đầu vào vì một phần là do kernel phải nằm trong ma trận đầu vào. Để giữ nguyên kích cỡ của feature map ta cần điều chỉnh với kỹ thuật padding.



Hình 2.6 Cách hoạt động của bộ lọc $k(x, y)$ để đưa ra bản đồ đặc trưng trên ma trận đầu vào $f(x, y)$.

2.3.3 Lớp tổng hợp

Lớp tổng hợp là lớp chúng ta dùng để:

Làm đơn giản hóa thông tin đầu ra để giảm bớt số lượng neural mà ta cần phải tính toán nhưng vẫn đảm bảo việc học của mô hình, từ đó giảm thiểu thời gian tính toán tránh tình trạng quá khớp với dữ liệu.

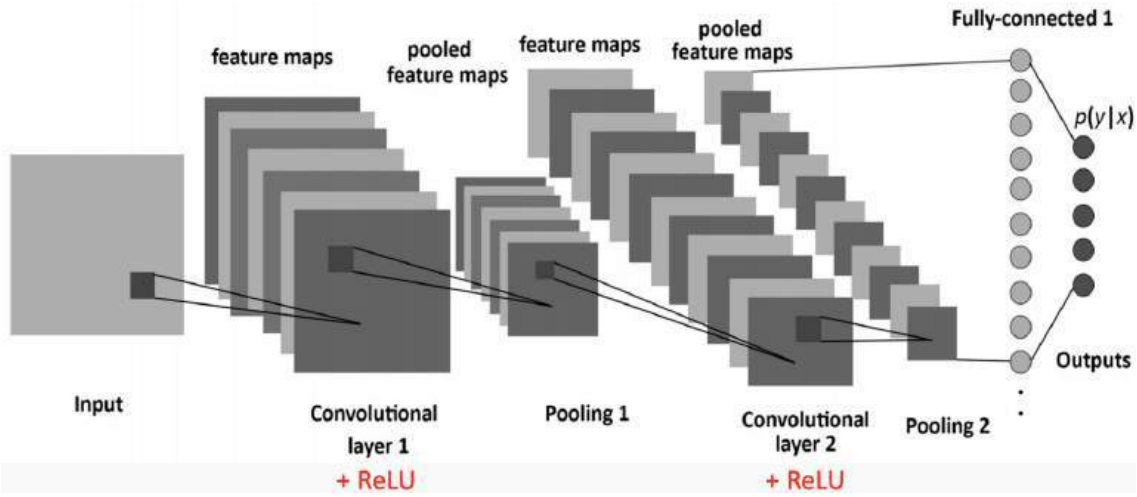
Lớp tổng hợp hoạt động gần giống với lớp tích chập, lớp này có một cửa sổ trượt gọi là cửa sổ trượt để trượt qua từng giá trị của ma trận dữ liệu đầu vào.

Có nhiều loại phương pháp tổng hợp như: max pooling (lấy giá trị lớn nhất trong vùng đầu vào), min pooling (lấy giá trị nhỏ nhất trong vùng đầu vào), average pooling (lấy giá trị trung bình trong vùng đầu vào), … [14] [23].

2.3.4 Các thành phần cơ bản của mạng neural tích chập

2.3.4.1 Hàm kích hoạt

Hàm kích hoạt là một ánh xạ từ dữ liệu các đầu vào của một neural với đầu ra tương ứng của neural đó, hình 2.7. Có nhiều hàm kích hoạt như: sigmoid, ReLU, tanh, leaky ReLU, Maxout, ELU…



Hình 2.7 Ví dụ CNN với hai lớp tích chập, hai lớp tổng hợp và hai lớp kết nối đầy đủ để quyết định phân loại hình ảnh [14].

a. Hàm sigmoid

Sigmoid là một hàm phi tuyến với đầu vào là các số thực và cho kết quả nằm trong khoảng [0, 1] và được xem là giá trị xác xuất trong một số bài toán. Trong hàm Sigmoid, một sự thay đổi nhỏ của dữ liệu đầu vào dẫn đến một kết quả đầu ra sẽ không thay đổi nhiều. Vì vậy, hàm này cho kết quả dữ liệu đầu ra "trơn" hơn và gần như liên tục so với dữ liệu đầu vào [24].

Hàm sigmoid là một hàm liên tục và đạo hàm của hàm này cũng khá đơn giản, công thức (2.14), nên dễ dàng áp dụng khi xây dựng mô hình, không những vậy việc cập

nhật tham số khi lan truyền ngược cũng dễ dàng. Tuy nhiên hàm sigmoid cũng sẽ gây ra một tình trạng "Vanishing Gradient", tình trạng này xảy ra khi thông tin thay đổi quá ít đi qua một neural sẽ không làm biến mất thông tin và triệt tiêu về zero.

$$f(x) = \frac{1}{1 + e^{-x}} \tag{2.14}$$

$$f'(x) = \frac{\partial f(x)}{\partial x} = f(x) * (1 - f(x))$$

b. Hàm ReLU

Hàm ReLU (Rectified Linear Unit) được dùng để tăng tốc quá trình huấn luyện, vì hàm ReLU đơn giản lọc các giá trị nhỏ hơn 0 (zero), công thức (2.15) [25], nên sẽ không gây ra hiện tượng "Vanishing Gradient". Tuy nhiên, ReLU cũng có một nhược điểm đó là với các dữ liệu có giá trị nhỏ hơn 0, qua hàm kích hoạt ReLU sẽ thành 0, hiện tượng này gọi là "Dying ReLU". Nếu các dữ liệu này bị chuyển thành 0 thì sẽ không có ý nghĩa với bước kích hoạt tuyến tính ở lớp tiếp theo và các hệ số tương ứng từ đấy cũng không được cập nhật tiếp. Hơn nữa, khi tỷ lệ học lớn, các trọng số có thể thay đổi theo cách làm tất cả neural dừng việc cập nhật. Theo lý thuyết thì hàm ReLU sẽ không có đạo hàm tại các điểm 0 nhưng thực tế thì sẽ thường bổ sung thêm đạo hàm của ReLU tại 0 bằng 0 và thông qua thực nghiệm thì thấy rằng xác suất để dữ liệu đầu vào của ReLU rơi vào 0 là rất nhỏ, và do hàm này không có chặn trên nên cũng có thêm nhược điểm là gây ra hiện tượng "Exploding Gradient" (bùng nổ Gradient, trong một mạng gồm n lớp ẩn, n đạo hàm sẽ được nhân với nhau. Nếu các đạo hàm lớn thì Gradient sẽ tăng theo cấp số nhân khi chúng ta truyền xuống mô hình cho đến khi cuối cùng chúng bùng nổ) nhưng thường sẽ ReLU sẽ hoạt động tốt trong thực tế.

$$f(s) = \max(0, s) \tag{2.15}$$

2.3.4.2 Hàm lỗi

Với mỗi loại dữ liệu, cũng như tính chất dữ liệu, hay mục tiêu học khác nhau cần sử dụng đúng hàm lỗi để huấn luyện được mô hình học tốt [26]. Những hàm lỗi thông

dụng hiện nay: cross-entropy, Mean Square Error, Mean Squared Logarithmic Error, Mean Absolute Error, Binary Cross-Entropy, Hinge, Squared Hinge, …

a. Cross-entropy

Cross-entropy là độ đo được xây dựng từ lý thuyết thông tin dựa vào khái niệm entropy. Đây là đại lượng cho biết sự khác biệt giữa hai phân phối xác suất của hai tập dữ liệu với biến ngẫu nhiên hoặc tập các sự kiện. Độ đo này có liên quan đến độ đo phân kỳ KL (Kullback-Leibler), nhưng khác với độ đo phân kỳ KL thì tính toán entropy tương đối giữa hai phân bố xác suất, trong khi cross-entropy sẽ tính tổng entropy giữa các phân phối, công thức (2.16) [27]. Khi xem xét trong miền không gian với dữ liệu rời rạc thì công thức (2.16) trở thành (2.17).

$$H(p,q) = -E_p[\log q] \tag{2.16}$$

$$H(p,q) = -\sum_{x \in D} p(x).\log\left(q(x)\right) \tag{2.17}$$

Với p, q là phân phối xác suất của hai tập dữ liệu lần lượt là: phân phối xác suất dữ liệu đúng và phân phối xác suất dữ liệu dự đoán; có E_p là kỳ vọng của p; D là tập dữ liệu.

b. Binary cross-entropy

Hàm cross-entropy nhị phân là một thu hẹp của hàm cross-entropy dùng để phân loại nhị phân, công thức (2.17) sẽ thành (2.18) [28].

$$H_p(q) = -\frac{1}{|D|}\sum_{i=1}^{|D|} x_i.\log\big(p(x_i)\big) + (1 - x_i).\log\left(1 - p(x_i)\right) \tag{2.18}$$

Với $|D|$ là số lượng phần tử của tập dữ liệu, và $p, q \in D$.

c. Mean Square

Sai số bình phương trung bình (Mean Square Error – MSE) là giá trị sai số bình phương trung bình giữa tham số dự đoán và tham số quan sát được, công thức (2.19).

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2 \tag{2.19}$$

Với y_i và $\hat{y}_i$ lần lượt là giá trị thực tế và giá trị dự đoán từ mô hình.

d. Mean Squared Logarithmic

Sai số logarit của bình phương trung bình (Mean Squared Logarithmic Error – MSLE) cho biết sự khác biệt tương đối giữa giá trị dự đoán và giá trị thực tế được chuyển đổi logarit. MSLE cho đánh giá tốt đối với các ngoại lệ khi có lỗi nhỏ hoặc lỗi lớn, đôi khi lỗi lớn thì MSE sẽ có thể gây ảnh hưởng mô hình (MSLE sẽ xử lý được những khác biệt nhỏ giữa các giá trị dự đoán và thực tế nhỏ gần giống như những khác biệt lớn giữa các giá trị thực tế lớn và giá trị dự đoán.). MSLE được tính theo công thức (2.20).

$$L(y, \hat{y}) = \frac{1}{|D|}\sum_{i=1}^{|D|}(\log(y_i + 1) - log(\hat{y}_i + 1))^2 \tag{2.20}$$

e. Với $y_i \in y$ và $\hat{y}_i \in \hat{y}$.

e. Mean Absolute

Lỗi tuyệt đối trung bình (Mean Absolute Error – MAE) là một phương pháp đo lường sự khác biệt giữa hai biến liên tục. Giả sử rằng X và Y là hai biến liên tục thể hiện kết quả dự đoán của mô hình và kết quả thực tế. chúng ta có độ đo MAE được tính theo công thức (2.21).

$$MAE = \frac{1}{|D|}\sum_{i=1}^{|D|}|y_i - \hat{y}_i| \tag{2.21}$$

f. Hinge

Một cách khác để xem xét cho bài toán phân lớp nhị phân đó là hàm Hinge. Trong thực tế, hàm Hinge thường thể hiện tốt hơn cross-entropy trong các bài toán phân loại nhị phân, công thức (2.22).

$$\mathcal{L}_n(w,b) = \max(0,1 - y_n z_n) \quad \text{với } z_n = w^T x_n + b \tag{2.22}$$

Với mỗi cặp hệ số (w,b) và cặp dữ liệu có nhãn (x_n, y_n).

g. Squared Hinge

Hàm Hinge có nhiều phiên bản mở rộng. Một phiên bản phổ biến của Hinge đó là Squared Hinge, hàm này có tác dụng làm mịn bề mặt của đồ thị hàm lỗi và dễ thao tác hơn về mặt toán học. Hàm Hinge có kết quả tốt trong bài toán phân lớp nhị phân thì Squared Hinge cũng sẽ cho kết quả tương tự. Từ công thức (2.22), thành phần $(1 - y_n z_n)$ được bình phương thì đây chính là Squared Hinge.

h. Cosine

Hàm Cosine cho biết hai giá trị x_1, x_2 giống nhau hay không giống nhau theo công thức (2.23).

$$Cosine(x,y) = \begin{cases} 1 - \cos(x_1, x_2), & nếu\ y = 1 \\ \max(0, \cos(x_1, x_2) - margin), & nếu\ y = -1 \end{cases} \tag{2.23}$$

với $x = (x_1, x_2)$

2.3.4.3 Hàm tối ưu

Các thuật toán tối ưu là cơ sở để xây dựng mô hình mạng neural "học" được tối ưu: thông tin học, thời gian, mức độ hội tụ, … Có nhiều hàm tối ưu được xây dựng như: RMSprop, Adam, SGD, … [29].

a. RMSprop

RMSprop giải quyết vấn đề tỷ lệ học giảm dần của Adagrad bằng cách chia tỷ lệ học cho trung bình của bình phương Gradient, công thức (2.24) [25].

$$E[g^2]_t = 0.9E[g^2]_{t-1} + 0.1g_t^2 \tag{2.24}$$
$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}}\, g_t$$

Với $g_t = \nabla_\theta L(\theta)$ là gradient của hàm lỗi $L(\theta)$.

b. Adam

Tối ưu Adam [25] là một thuật toán kết hợp kỹ thuật của RMS prop và momentum. Thuật toán sử dụng hai internal states momentum (m) và squared momentum (v) của Gradient cho các tham số. Sau mỗi batch huấn luyện, giá trị của m và v được cập nhật lại sử dụng trung bình trọng số theo mũ, công thức (2.25) [25]. Các lợi ích của thuật toán Adam [25]:

- Không khó khăn để cài đặt.
- Hiệu quả.
- Ít bộ nhớ.
- Thích hợp với các bài toán có độ biến thiên không ổn định và dữ liệu huấn luyện phân mảnh.

Các siêu tham số được biến thiên một cách hiệu quả và yêu cầu ít điều chỉnh, công thức (2.25).

$$g_n \leftarrow \nabla L(\theta_{n-1})$$
$$m_n \leftarrow \left(\frac{\beta_1}{1-\beta_1^n}\right) m_{n-1} + \left(\frac{1-\beta_1}{1-\beta_1^n}\right) g_n \tag{2.25}$$
$$v_n \leftarrow \left(\frac{\beta_2}{1-\beta_2^n}\right) v_{n-1} + \left(\frac{1-\beta_2}{1-\beta_2^n}\right) g_n \odot g_n$$
$$\theta_n \leftarrow \theta_{n-1} - \alpha * m_n/(\sqrt{v_n} + \epsilon)$$

Với g_n là gradient của hàm lỗi $L(\theta)$ (θ là tham số của mô hình học), trong đó β_1, β_2 và ϵ là các siêu tham số. Giá trị α là tỉ lệ học, m_n và v_n lần lượt là moment thứ nhất và thứ hai. Phép toán $\odot$ là tích Hadamard của hai ma trận.

c. SGD

Thuật toán SGD (Stochastic Gradient Descent) là thuật toán tối ưu hóa cơ bản theo họ Gradient. Thuật toán này dựa trên nền tảng lý thuyết vững chắc để xây dựng, ổn định trong quá trình huấn luyện, kết quả đạt được tốt so với các thuật toán khác. Ý tưởng của thuật toán khá đơn giản, đó là "tính giá trị Gradient của mỗi tham số, và đi một bước nhỏ theo chiều của Gradient" để giá trị lỗi giảm. Nếu chúng ta lặp đi lặp lại quá trình này, và ngẫu nhiên chọn một tập batch trong tập huấn luyện, mô hình chúng ta sẽ được cải tiến dần đến điểm hội tụ, công thức (2.26) [25]. Thuật toán giải quyết được đối với dữ liệu lớn mà phương pháp GD không làm được. Thuật toán tối ưu này được sử dụng thường xuyên [25].

$$v_t = \gamma v_{t-1} + \eta \nabla_\theta J(\theta) \qquad (2.26)$$
$$\theta = \theta - v_t$$

2.4 Unet

Unet là một mạng lưới thần kinh tích chập được phát triển từ mô hình CNN với mục đích ban đầu dành cho phân đoạn hình ảnh y khoa, được xây dựng bởi Olaf Ronneberger, Philipp Fischer, Thomas Brox vào năm 2015 [30].

Unet là một trong những kiến trúc CNN tiêu chuẩn cho các nhiệm vụ phân loại hình ảnh, bài toán chúng ta không chỉ cần phân loại toàn bộ hình ảnh theo lớp mà còn có thể phân chia các khu vực của hình ảnh theo lớp. Ngoài ra, Unet cho phép huấn luyện theo kiểu từ đầu đến cuối với rất ít hình ảnh nhưng lại vượt trội về hiệu năng.

Các phương pháp khác sử dụng kỹ thuật cửa sổ trượt, tức là mỗi điểm ảnh được phân loại riêng lẻ (còn được gọi là tích chập), điều này khá mất thời gian. Unet đã cải thiện đáng kể hoạt động của CNN. Unet chỉ cần một số lượng nhỏ mẫu cho huấn luyện, điều nay không giống như các mạng tích chập khác cần sử dụng hàng nghìn mẫu huấn

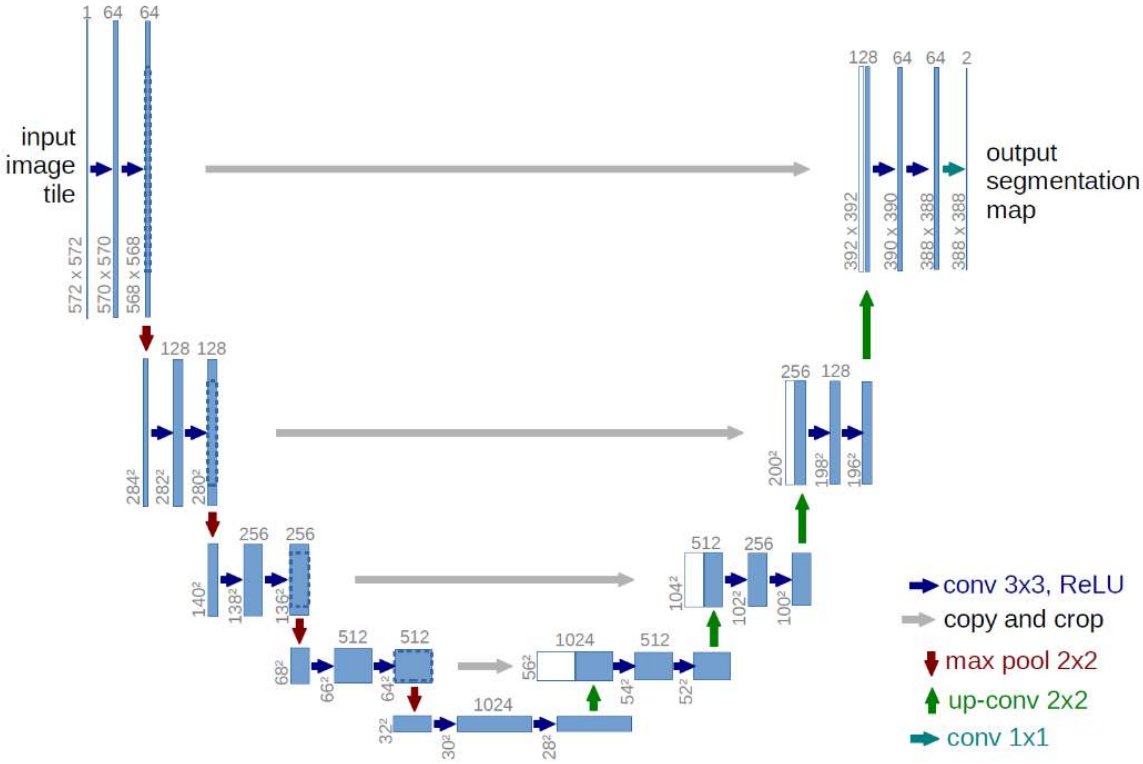
luyện. Để giải quyết vấn đề dữ liệu ít thì Unet cho phép tăng cường dữ liệu huấn luyện với thuộc tính biến dạng đàn hồi ngẫu nhiên được sử dụng. Ảnh thu được sẽ gần giống hệt như ảnh ban đầu và cũng đã được phân loại chính xác cùng với các biến dạng. Đây là một ưu điểm quan trọng của kiến trúc Unet.

Về kiến trúc, mô hình Unet có hình chữ "U" đúng như tên gọi của nó; gồm 2 phần là: phần đầu tiên thì quá trình xử lý sẽ làm giảm kích thước của dữ liệu (down-sampling), phần thứ hai thì quá trình xử lý sẽ làm tăng kích thước của dữ liệu (up-sampling), hình 2.8. Việc giảm kích thước dữ liệu sẽ học được các thông tin phổ quát, đến giai đoạn tăng kích thước sẽ học được các thông tin chi tiết; quá trình đi qua hai nhánh sẽ học từ thông tin phổ quát đến thông tin chi tiết làm cho Unet có khả năng học được các thông tin nhập nhằng gần tương tự và đặc biệt Unet không sử dụng lớp kết nối đầy đủ mà dùng phương pháp đệm (Padding method), điều này giúp kiến trúc có thể phân đoạn hình ảnh được hoàn toàn, đặc biệt là ảnh y khoa.

Tổng quát kiến trúc Unet gồm hai phần [30]:

- Encoder: Tập trung nhiều hơn vào các thuộc tính hơn là các vị trí của các thuộc tính và có kiến trúc điển hình của CNN, bao gồm việc lặp lại của các khối, mỗi khối bao gồm:
    - Lớp tích chập thứ nhất có nhân kích thước 3×3 và hàm kích hoạt là ReLU có cửa sổ trượt 3×3.
    - Lớp tích chập thứ hai có nhân kích thước 3×3 và hàm kích hoạt là ReLU có cửa sổ trượt 3×3.
    - Lớp tổng hợp chọn giá trị lớn nhất để giảm kích thước dữ liệu với kích thước cửa sổ 2×2.
    - Trong đó bản đồ đặc trưng (độ sâu của ảnh) sẽ tăng gấp đôi sau khi thực hiện tích chập đầu tiên của mỗi khối. Cổ chai (Bottleneck): đây là phần của mạng nằm giữa encoder và decoder. Cổ chai được xây dựng đơn

giản với hai lớp tích chập với nhân kích có thước 3×3 và kèm dropout (điều này giúp mô hình tránh được vấn đề quá khớp).



Hình 2.8 Kiến trúc Unet với đầu vào là ảnh xám 572×572 [27].

- Decoder: nhằm mục đích là khôi phục lại kích thước của ảnh gốc, bao gồm việc lặp lại của các khối, mỗi khối bao gồm:
    - Tích chập tăng kích thước (nhằm tăng kích thước dữ liệu) sử dụng chuyển đổi tích chập có kích thước cửa sổ là 2×2 giúp giảm một nửa bản đồ đặc trưng và tăng kích thước ảnh.
    - Sau đó ghép với bản đồ đặc trưng, mà bản đồ đặc trưng được cắt một nửa tương ứng từ encoder.
    - Lớp tích chập thứ nhất có kernel kích thước 3×3 (số lượng nhân tích chập giảm một nữa so với khối trước đó) và hàm kích hoạt ReLU có cửa sổ trượt là 3×3.

- Lớp tích chập thứ hai có kernel kích thước 3×3 (số lượng nhân tích chập giảm một nữa so với khối trước đó) và hàm kích hoạt ReLU có cửa sổ trượt là 3×3.
- Ở lớp cuối cùng, tích chập 1×1 được sử dụng để ánh xạ mỗi vector thuộc tính thành phần tới số lớp mong muốn.

Luận án đề xuất sử dụng mô hình Unet vì Unet không sử dụng một lớp kết nối đầy đủ nào như các mô hình khác trong học sâu. Ở kiến trúc Unet việc kết nối do nửa thứ hai của chữ "U" đảm nhận, do đó việc sử dụng Unet có thể chấp nhận dữ liệu đầu vào là ảnh kích thước bất kỳ. Điều này sẽ dễ dàng hơn cho việc phân đoạn và không bị ảnh hưởng bởi kích thước dữ liệu đầu vào.

Ngoài ra Unet sử dụng phương pháp đệm (Padding method), kiến trúc này giúp cho hình ảnh có thể được phân đoạn hoàn toàn. Trong việc phân đoạn ảnh y khoa, độ phân giải ảnh có thể bị ảnh hưởng bởi GPU; vì thế với phương pháp đệm của của mô hình có thể giải quyết vấn đề này [30].

Mục tiêu của Unet được thiết kế ban đầu cho các phân đoạn ảnh y tế, và việc không bị ảnh hưởng bởi kích thước ảnh dữ liệu đầu vào, hay GPU làm ảnh hưởng độ phân giải thì Unet là sự lựa chọn tốt, có thể giải quyết các vấn đề của bài toán đề ra trong luận án.

2.5 Kết chương

Dựa trên cơ sở lý thuyết của NN, CNN và Unet có thể xây dựng mô hình Unet đáp ứng bài toán phân đoạn ảnh mạch vành theo hướng tiếp cận từ thô đến mịn, cũng như xây dựng mô hình phân loại mạch vành theo hai hướng tiếp cận: xây dựng thuật toán và học sâu để giải quyết hai toán đặt ra trong luận án.

CHƯƠNG 3 BÀI TOÁN PHÂN ĐOẠN MẠCH VÀNH

Chương 3 luận án trình bày tổng hợp các hướng tiếp cận đã được nhiều nhà nghiên cứu dùng để giải quyết bài toán phân đoạn mạch vành. Từ những phương pháp này kết hợp tính chất của mạch vành được trình bày trong chương 1, luận án đã đề xuất phương pháp phân đoạn đối tượng có tính chất kích thước khác biệt (cùng một đối tượng có vùng lớn, có vùng nhỏ) và nền rất phức tạp dựa trên ý tưởng xử lý từ thô đến mịn kết hợp phương pháp học sâu với những mô hình xử lý cho kích thước lớn rồi dùng kết quả này phân đoạn cho kích thước nhỏ bằng mô hình học sâu khác. Kết quả được công bố trên tạp chí SCIE [CT2]. Kết quả chương 3 chính là dữ liệu để giải quyết bài toán ở chương 4.

3.1 Các hướng tiếp cận

Hiện nay trên thế giới đã xuất hiện rất nhiều thuật toán được sử dụng để phân đoạn mạch máu. Trong khi một số phương pháp sử dụng kỹ thuật nhận dạng mẫu dựa trên mức xám ví dụ như phân ngưỡng các thành phần liên thông, các phương pháp khác lại ứng dụng mô hình toán học của mạch máu để trích xuất những đường biên của mạch máu. Trong nhiều trường hợp, tùy thuộc vào chất lượng ảnh ví dụ như xuất hiện của nhiễu, một vài phương pháp sẽ yêu cầu thêm bước tiền xử lý trước khi tiến hành phân đoạn mạch máu. Luận án tóm lược bài toán phân đoạn mạch máu thành ba hướng tiếp cận chính [31]:

- Hướng tiếp cận dựa trên kỹ thuật nhận dạng mẫu
- Hướng tiếp cận dựa trên mô hình
- Hướng tiếp cận dựa trên thông minh nhân tạo

Các hướng tiếp cận sẽ khác nhau tùy thuộc vào ảnh đầu vào và cách đánh giá của tác giả đối với bộ dữ liệu. Với nhiều hướng tiếp cận như trên, những phương pháp phân đoạn mạch máu hiện đại thường xuyên kết hợp nhiều kỹ thuật để tạo nên kết quả tốt nhất.

3.1.1 Hướng tiếp cận dựa trên các kỹ thuật nhận dạng mẫu

Nhận dạng mẫu là kỹ thuật dùng để phát hiện hay phân loại đối tượng dựa trên những tính chất đặc trưng của chúng. Trong xử lý ảnh, kỹ thuật nhận dạng mẫu được thực hiện để phát hiện cấu trúc mạch máu và đặc trưng của nó một cách tự động. Hướng tiếp cận dựa trên kỹ thuật nhận dạng mẫu được chia thành nhiều loại, ví dụ như phương pháp tiếp cận đa phân giải (multi-scale approaches), phương pháp tiếp cận dựa trên khung xương của mạch máu (skeleton-based approaches) hoặc là phương pháp tiếp cận theo từng vùng (region growing approaches).

Phương pháp tiếp cận đa phân giải được thực hiện phân tích trên nhiều cấp độ phân giải khác nhau của ảnh. Sarwal và Dhawan [32] tái tạo cấu trúc của động mạch vành từ ba góc chụp ảnh khác nhau bằng cách kết hợp những điểm nối. Phương pháp trên dựa trên ý tưởng kết nối dựa trên phương trình tuyến tính đơn giản và gắn nhãn phù hợp. Để cải thiện độ chính xác của những điểm nối, tiến trình được thực hiện ở ba độ phân giải khác nhau. Mạch máu lớn được trích xuất ở quy mô thấp, ngược lại những mạch máu nhỏ cả các nhánh sẽ được trích xuất ở những quy mô lớn hơn. Ưu điểm chính của kỹ thuật này là tăng tốc độ khi xử lý. Các cấu trúc chính (là cấu trúc mạch máu) được trích xuất từ các ảnh có độ phân giải thấp trong khi các cấu trúc phức tạp hơn được trích xuất ở độ phân giải cao. Một ưu điểm khác là tăng tính mạnh mẽ. Sau khi phân chia các cấu trúc mạch máu ở độ phân giải thấp, cấu trúc yếu, chẳng hạn như các chi nhánh, trong vùng lân cận của cấu trúc mạch máu có thể được phân đoạn ở độ phân giải cao hơn. Tại mỗi cấp độ khác nhau, có thể phát hiện được nhiều đoạn mạch máu khác nhau. Do đó, khuyết điểm lớn nhất của phương pháp này là quá trình kết nối những đoạn mạch đã được phân đoạn tại mỗi cấp độ có độ phân giải khác nhau sẽ rất mất thời gian. Các tác giả đã kết hợp bộ lọc định hướng không phân tách (Decimation-free Directional Filter Bank - DDFB) và bộ lọc đồng nhất (Homographic Filtering - HF) để tăng cường ảnh chụp mạch vành bằng X-quang cho phân đoạn. Nhóm tác giả dựa trên cơ sở mạch máu chỉ chảy theo một hướng trên nhánh mạch, bộ lọc DDFB phù hợp để tăng cường mạch máu theo hướng và bán kính khác nhau. Khi kết hợp với bộ lọc HF, phương pháp có thể chuẩn hóa độ sáng trên

toàn ảnh và tăng độ tương phản. Chiến lược từ thô đến mịn để phân đoạn từ mạch lớn đến mạch nhỏ với thuật toán Otsu được áp dụng để trích xuất các mạch vành chính ở kích thước khác nhau. Đặc biệt, dựa trên thông tin của các mạch chính được sử dụng, tác giả giới thiệu một phương pháp mới để trích xuất các điểm nối trên nhánh mạch và cấp độ các điểm nối. Dựa vào điểm nối để xác định vị trí và trích xuất các mạch nhỏ [33]. Chenxin Sui [34] sử dụng ma trận Hess để phân đoạn mạch vành dựa trên phương pháp tăng vùng qua hai giai đoạn song hành rồi phân tích tìm khung xương của mạch vành.

Phương pháp tiếp cận dựa trên khung xương dùng để trích xuất đường trung tâm của mạch máu. Cây mạch máu được tạo ra bằng việc kết nối những đường trung tâm. Có nhiều phương pháp khác nhau được sử dụng để trích xuất những đường trung tâm này. Kawata và cộng sự [35] đã phát hiện những căn bệnh liên quan đến mạch máu trên bộ dữ liệu là ảnh CT 3D có độ phân giải cao. Phương pháp này chia ra thành hai phần chính: (1) trích xuất đường trung tâm của mạch máu và (2) phát hiện hình dạng lồi hoặc lõm của thành mạch máu. Những hình dạng này đại diện cho chứng bệnh phình hay hẹp của mạch máu. Tuy nhiên, phương pháp phổ biến nhất vẫn là áp dụng ngưỡng cho ảnh, sau đó kết hợp với quá trình làm mỏng dần cho đến khi độ dày của nó là một điểm ảnh và cuối cùng nối những đoạn thẳng này với nhau. Cấu trúc cây mạch máu thường được sử dụng phổ biến trong môi trường 3D. Đồng thời, nếu muốn tái tạo một ảnh cây mạch máu hoàn chỉnh, ta cần phải sử dụng thêm nhiều phương pháp khác.

Bắt đầu từ các điểm ban đầu, ***kỹ thuật phát triển vùng*** sẽ phân đoạn ảnh bằng cách tuyển chọn những điểm ảnh vào cùng một vùng dựa trên các tiêu chí cho trước. Hai tiêu chí quan trọng cho việc lựa chọn những điểm ảnh thích hợp là giá trị mức xám tương tự và không gian gần nhau giữa các điểm ảnh [36]. Nghĩa là, nếu hai điểm ảnh nằm gần nhau có giá trị tương tự nhau thì thuộc cùng một vùng. Bằng kỹ thuật phát triển vùng, O'Brien and Ezquerra [37] cũng đã trình bày phương pháp tự động phát hiện động mạch vành trong ảnh y sinh dựa trên các ràng buộc về thời gian, không

gian và cấu trúc. Nhược điểm lớn nhất của thuật toán này là bị ảnh hưởng lớn từ những điểm ban đầu. Do đó, nếu người dùng nhập sai những giá trị này, khả năng không phân đoạn được là rất lớn. Một phương pháp trừ nền thích ứng dựa trên các vùng (Patch-Based Adaptive Background Subtraction Method - PABSM) được tác giả [38] đề xuất để tự động tăng cường mạch trong chụp phim X-quang mạch vành. Đầu tiên, các điểm ảnh được bằng đặc trưng Gabor. Sau đó dùng một bộ phân loại để tách ảnh thành vùng mạch máu thô và vùng không mạch máu. Quá trình co giãn được áp dụng cho ảnh nhị phân để có nhiều vùng mạch máu hơn. Cuối cùng tổng hợp nền dựa trên các vùng được sử dụng để hoàn chỉnh vùng mạch máu bị loại bỏ. Ma [39] đề xuất một phương pháp phân đoạn mạch vành dựa trên phương pháp tăng vùng. Một quy tắc được đề xuất để phân đoạn mạch là kết hợp vector Hessian và vùng đang tăng với khu vực tìm kiếm. Để cải thiện hơn nữa chất lượng phân đoạn mô hình tối ưu hóa việc loại bỏ một số vùng nhỏ bị tách rời.

3.1.2 Hướng tiếp cận dựa trên mô hình

Ngoài việc sử dụng đặc trưng từ các tính chất của bộ dữ liệu, những nhà khoa học đã cố gắng xây dựng mô hình của mạch máu để trích xuất chúng. Có nhiều loại mô hình như Mô hình biến dạng (Deformable Model), Mô hình tham số (Parametric Model), hay Mô hình mẫu (Template Model) …

Mô hình biến dạng là kỹ thuật tìm đường biên của đối tượng bằng cách sử dụng các đường cong tham số bị biến dạng dưới tác dụng của lực bên trong và bên ngoài. Tác giả McInerney và Terzopoulos [40] dùng các mô hình biến dạng trong phân tích ảnh y khoa. Còn Rueckert [41] sử dụng mô hình biến dạng để theo dõi động mạch chính trong ảnh MR tim mạch. Hệ thống theo dõi hình dạng của động mạch trong chu kỳ tim để nghiên cứu vấn đề co dãn của động mạch.

Mô hình tham số là mô hình dùng các đối tượng tìm tham số cần quan tâm để mô tả cho đối tượng. Trong bài toán phân đoạn mạch máu, các đối tượng được mô tả như một tập các ellipsoid chồng chéo nhau [42]. Pellot [43] cũng sử dụng mô hình elip biến dạng để ước tính các mạch máu bất thường và phân nhánh mạch máu. Tất cả các

tham số của mô hình được ước lượng từ ảnh, do đó yêu cầu người nghiên cứu phải có trình độ tri thức cao về mạch máu cũng như kiến thức chuyên sâu về các mô hình tham số và thực hiện nghiên cứu nhiều lần để xác định chính xác giá trị của các tham số.

Một phương pháp phân đoạn mạch máu dựa trên khái niệm ràng buộc ở giữa/bên trong khung hình mới được đề xuất để tự động phân đoạn mạch trong chuỗi ảnh chụp X-quang mạch vành. Một phép toán lọc hình thái học được áp dụng để loại bỏ cấu trúc phía dưới khi có chuyển động hô hấp từ chuỗi ảnh ban đầu. Sau đó xem xét ràng buộc giữa các khung hình với phân tích thành phần chính mạnh (Robust Principal Component Analysis - RPCA) để loại bỏ các cấu trúc gần như tĩnh khỏi chuỗi ảnh. Bước tiếp theo ràng buộc ở giữa khung hình từ RPCA sẽ được sử dụng để làm tốt hơn khi quá trình trích xuất mạch máu được tiến hành. Cuối cùng kết hợp đa đặc trưng để cải thiện độ tương phản mạch máu để có kết quả phân đoạn mạch máu với phương pháp dựa trên ngưỡng [44]. Phương pháp này có hiệu quả khi loại bỏ các cấu trúc không phải mạch máu, giảm các chuyển động và ánh sáng không đồng đều khác gây ra nhiễu. Ngoài ra, phương pháp được đề xuất cho kết quả tức thời với mỗi ảnh mà không cần tối ưu hóa lại mô hình.

3.1.3 Hướng tiếp cận dựa trên thông minh nhân tạo

Hướng tiếp cận dựa trên thông minh nhân tạo sẽ sử dụng thông tin đã được học để hướng dẫn quá trình phân đoạn mạch máu. Thông tin được sử dụng tùy vào những trường hợp khác nhau và do con người quyết định. Thông tin có thể là các tính chất của kỹ thuật thu thập ảnh, chẳng hạn như chụp CT, MRI hay MRA. Ngoài ra, vẫn có một số ứng dụng sử dụng mô hình mạch máu như là một loại thông tin, ví dụ như đường trung tâm có cường độ mức xám cao hơn, … Trong khi đó, Stansfield [45] đã áp dụng kiến thức trong ngành giải phẫu học để giải thích biểu đồ các mạch máu chụp xung quanh tim. Các hệ thống sử dụng thông tin là kiến thức tiên tiến về giải phẫu học được thực hiện đơn giản hơn nhờ những thuật toán xử lý ảnh cấp thấp như phân ngưỡng, làm mỏng, … Phương pháp tiếp cận dựa trên thông minh nhân tạo có độ

chính xác cao, nhưng độ phức tạp lại lớn hơn nhiều so với những phương pháp khác. Tác giả xây dựng hai mô hình Unet được gọi là Unet main và Unet branch [46] [47] [48] [49]. Mô hình Unet main dùng để phân đoạn tìm các mạch chính trong ảnh mạch vành. Từ kết quả này sẽ dùng phương pháp [33] để xác định điểm rẽ nhánh của mạch nhỏ, sau khi có tập điểm rẽ nhánh sẽ tạo các ảnh con là mạch thứ cấp. Các ảnh con này sẽ là dữ liệu đầu vào của mô hình Unet branch cho phân đoạn mạch thứ cấp.

Một hệ thống dựa trên học sâu trong hướng tiếp cận thông minh nhân tạo được đề xuất để phân đoạn mạch máu. Các phương pháp hiện tại sử dụng CNN chủ yếu dựa vào các hình dáng cục bộ được học trên ảnh, mà không xem xét đến cấu trúc đồ họa của hình dạng mạch máu. Sử dụng hiệu quả mối quan hệ bền chặt tồn tại giữa các vùng lân cận mạch máu có thể giúp cải thiện độ chính xác của việc phân đoạn. Tác giả kết hợp mạng neural đồ thị vào một kiến trúc CNN thống nhất để cùng khai thác cả hình thức cục bộ và cấu trúc mạch máu toàn cục [50].

Do cấu trúc giải phẫu phức tạp nên việc phân đoạn động mạch vành tự động từ ảnh chụp cắt lớp mạch vành 3D (Coronary Computed Tomography Angiography - CCTA) là vô cùng khó khăn. Với ưu điểm của LSTM (long short-term memory) để lập mô hình cấu trúc cây cơ bản, tác giả [51] đã đề xuất một mô hình hồi quy có cổng tích chập ConvGRU (Convolutional Gated Recurrent Unit) mới để học cấu trúc cơ bản của động mạch vành. Mô hình ConvGRU có cấu trúc cây xem xét các tương quan không gian cục bộ trong dữ liệu đầu vào dựa trên tích chập được sử dụng cho trạng thái đầu vào và trạng thái chuyển trạng thái, nên sẽ phù hợp cho việc phân tích ảnh. Một khung phân đoạn có cấu trúc cây được trình bày bao gồm một FCN (Fullyconvolutional Network) để trích xuất đặc trưng phân biệt đa tỷ lệ và dùng cho dự đoán cuối cùng, và một lớp ConvGRU có cấu trúc cây để lập mô hình cấu trúc giải phẫu. Khung đề xuất được đánh giá tích cực dựa trên bốn tập dữ liệu CCTA 3D và phương pháp chính xác và hiệu quả hơn so với các phương pháp tiếp cận phân đoạn động mạch vành khác.

Động mạch vành có hình ống mỏng cấu trúc có độ tương phản tương đối thấp và thấy chồng chéo các đối tượng. Tác giả [52] đề xuất phương pháp dựa trên học sâu mới là sử dụng mạng phức hợp đa kênh. Vì xuất hiện các đối tượng trong cả hai ảnh trực tiếp (sau khi tiêm chất cản quang) và ảnh mặt nạ (trước khi tiêm chất cản quang), các mạch máu chỉ xuất hiện khi cơ thể còn sống. Tác giả xem xét các ảnh mặt nạ để phân biệt các cấu trúc mạch máu thực sự từ các đối tượng thấy được. Sau đó dùng thông tin của hai loại ảnh để nâng cao thông tin cấu trúc mạch máu. Thứ bậc các tính năng sau đó sẽ được tự động học để mô tả đặc điểm của không gian liên kết giữa mạch máu và nền để có được kết quả phân đoạn cuối cùng. Ngoài ra, một kết hợp dày đặc giữa ảnh trực tiếp và ảnh mặt nạ được xử lý chính xác căn chỉnh ban đầu. Kết quả thử nghiệm chứng minh rằng phương pháp hiệu quả và mạnh mẽ để phân đoạn động mạch vành, so với một số phương pháp hiện đại.

Việc phân đoạn các động mạch vành trong ảnh mạch X-quang bằng CNN có triển vọng nhưng bị hạn chế bởi yêu cầu gán nhãn chính xác tất cả các điểm ảnh trong một số lượng lớn ảnh huấn luyện, điều này cực kỳ tốn công sức, đặc biệt là đối với các cây mạch vành phức tạp. Để giảm chi phí, tác giả [53] đề xuất một phương pháp huấn luyện mới được giám sát yếu, học từ các nhãn giả nhiễu được tạo ra từ việc tăng cường mạch máu tự động, thay vì gán nhãn chính xác hoàn toàn thủ công. Tác giả đề xuất phương pháp học có thể tự điều chỉnh quá trình học (Annotation-Refining Self-Paced Learning Framework - AR-SPL) để sửa các lỗi tiềm ẩn bằng cách sử dụng dữ liệu được gán nhãn có gợi ý. Kết quả cho thấy phương pháp đề xuất đạt được:

1) Độ chính xác có thể so sánh được với việc học có giám sát hoàn toàn, điều này cũng vượt trội hơn đáng kể so với các phương pháp học được giám sát yếu khác;

2) Giảm đáng kể chi phí gán nhãn;

3) Một quy trình hiệu quả, dẫn đến hiệu suất vượt trội.

Tác giả Su Yang [49] và cộng sự xây dựng mô hình học sâu cụ thể là CNN để phân đoạn mạch vành, chủ yếu là mạch chính, cho dữ liệu riêng có 3302 mạch máu chính từ 2042 bệnh nhân. S. Xia [54] và cộng sự phát triển một mô hình phân rã ma trận

mới với độ dốc thưa thớt trong biểu diễn tensor. Sau đó xây dựng hàm năng lượng với đầu vào của mạch phân cấp được sử dụng để phát hiện mạch và phân đoạn mạch cho mạch chính trên dữ liệu riêng là video. Iyer, K. [55] và nhóm nghiên cứu thiết kế một CNN, cụ thể là AngioNet, để phân đoạn mạch vành chính trong ảnh chụp X-quang mạch vành. Cải tiến chính trong mạng này là đề xuất mạng xử lý ảnh động mạch (Angiographic Processing Network – APN) giúp cải thiện đáng kể hiệu suất phân đoạn trên nhiều đường trục mạng, với hiệu suất tốt nhất khi sử dụng Deeplabv3+. Mục đích của APN là tạo ra một đường dẫn từ đầu đến cuối để xử lý trước và phân đoạn ảnh. Dữ liệu của nhóm tự thu thập từ 161 bệnh nhân được chụp 280 ảnh mạch vành trái (LCA) và 182 ảnh mạch vành phải (RCA).

Y. Shen [56] đề xuất một khung chung cho phân đoạn mạch vành dựa trên phương pháp học sâu và thiết lập cấp độ. Mạng tích chập đầy đủ 3 chiều (fully convolutional network – FCN) được sử dụng để tìm các đặc điểm ngữ nghĩa 3D của mạch vành, cung cấp điểm khởi đầu. Hơn nữa, một cổng Attention được thêm vào nhằm mục đích tăng cường mạch và ngăn chặn các vùng không liên quan. Đầu ra của 3D FCN với cổng Attention được tối ưu hóa theo mức để làm mịn biên để phù hợp hơn với phân đoạn.

Bin Kongn [51]đề xuất một mô hình đơn vị hồi quy tích chập có cấu trúc cây mới (convolutional gated recurrent unit – ConvGRU) để tìm hiểu cấu trúc giải phẫu của mạch vành để xem xét các mối tương quan không gian cục bộ trong dữ liệu đầu vào vì các phép tích chập cũng được sử dụng cho đầu vào đến trạng thái. Để tiến hành phân đoạn theo điểm ảnh ba chiều, khung phân đoạn có cấu trúc cây sẽ được sử dụng: bao gồm một mạng tích chập hoàn toàn (FCN) để trích xuất tính năng phân biệt đa quy mô và dự đoán cuối cùng, cũng như lớp ConvGRU có cấu trúc dạng cây để mô hình hóa cấu trúc giải phẫu.

Ma [39] đề xuất một phương pháp phân đoạn mạch vành dựa trên phương pháp tăng vùng. Một quy tắc được đề xuất để phân đoạn mạch là kết hợp vector Hessian và

vùng đang tăng với khu vực tìm kiếm. Để cải thiện hơn nữa chất lượng phân đoạn mô hình tối ưu hóa việc loại bỏ một số vùng nhỏ bị tách rời.

Tao Wan [57] đề xuất một phương pháp học sâu mới để tự động trích xuất động mạch vành từ chuỗi các ảnh mạch vành. Mạng lưới thần kinh tích chập hoàn toàn theo thời gian được thiết kế để phân chia toàn bộ cây mạch từ các chuỗi chuyển động hiệu quả. Một phương pháp xử lý hậu kỳ được cải tiến sau đó sẽ tinh chỉnh các kết quả phân đoạn bằng cách tận dụng tốt khả năng kết nối không gian và sự gắn kết thời gian giữa các ảnh mạch vành.

S. Mulay [58] trình bày một kỹ thuật chuyển đổi kiểu chuẩn hóa phiên bản thích ứng biên dựa trên học sâu để phân đoạn các động mạch vành. Kỹ thuật được đề xuất kết hợp chuyển kiểu chuẩn hóa phiên bản thích ứng với mạng khởi động cực kỳ dày đặc và mô-đun chú ý khối tích chập để có được hiệu suất phân đoạn động mạch tốt nhất.

Gao [59] trình bày một khung tổng thể mới để phân đoạn mạch vành, tác giả sử dụng các tính năng dựa trên bộ lọc và học sâu để xây dựng các mô hình bằng cách sử dụng cây quyết định tăng cường độ dốc và bộ phân loại rừng theo chiều sâu. Tác giả sử dụng 130 ảnh mạch vành. Xây dựng vectơ đặc trưng 37 chiều dựa trên: (1) số liệu thống kê về phản hồi lọc đa tỷ lệ trong các miền hình thái, không gian và tần số; và (2) các bản đồ đặc trưng thu được từ các mạng lưới thần kinh sâu đã qua huấn luyện.

[60] Zhao đề xuất trước tiên trích xuất toàn bộ chuỗi nhị phân mạch vành (cây mạch nhị phân) bằng phương pháp dựa trên học sâu. Sau đó trích xuất đường trung tâm của ảnh nhị phân cây mạch máu và tách nó thành các đoạn động mạch khác nhau. Cuối cùng, bằng cách trích xuất cấu trúc liên kết động mạch cơ bản.

Caixia Dong [61] đề xuất một mạng sâu 3D đa quy mô, đa Attention mới cho phân đoạn mạch vành với tên gọi là CAS-Net. Mô-đun kết hợp đặc trưng theo Attention (attention-guided feature fusion – AGFF) để kết hợp hiệu quả các tính năng phân cấp liền kề trong giai đoạn mã hóa và giải mã nhằm nắm bắt thông tin ngữ nghĩa tiềm ẩn hiệu quả hơn. Mô-đun kế tiếp là nâng cao tính năng nhận biết tỷ lệ (scale-aware

feature enhancement – SAFE) với mục đích điều chỉnh linh hoạt các trường tiếp nhận để trích xuất hiệu quả hơn, từ đó nâng cao khả năng biểu diễn tính năng của mạng. Mô-đun thứ ba là mô-đun tổng hợp đặc trưng đa tỷ lệ (multi-scale feature aggregation – MSFA) để tìm hiểu cách trình bày ngữ nghĩa đặc biệt hơn nhằm tinh chỉnh mạch vành. Thử nghiệm trên dữ liệu có 119 ảnh cho thấy tốt hơn so với Unet3D.

Nannini G [62] dùng 281 ảnh mạch vành để huấn luyện kiến trúc dựa trên Unet qua hai giai đoạn: giai đoạn đầu tiên sử dụng Unet 2,5D được huấn luyện trên các lát cắt trục, vành và sagittal để phân đoạn sơ bộ, ở giai đoạn thứ hai sử dụng Unet 3D đa kênh để sàng lọc. Xử lý hậu kỳ hình học được thực hiện: các đường tâm mạch được trích xuất và điểm quanh co được định lượng bằng số lượng các nhánh có ba điểm uốn cong trở lên với sự thay đổi hướng tạo thành một góc >45°. Điểm CAC dựa vào độ suy giảm hình ảnh. CAC được phát hiện bằng cách đặt ngưỡng cụ thể của bệnh nhân, sau đó áp dụng thuật toán tăng vùng để sàng lọc.

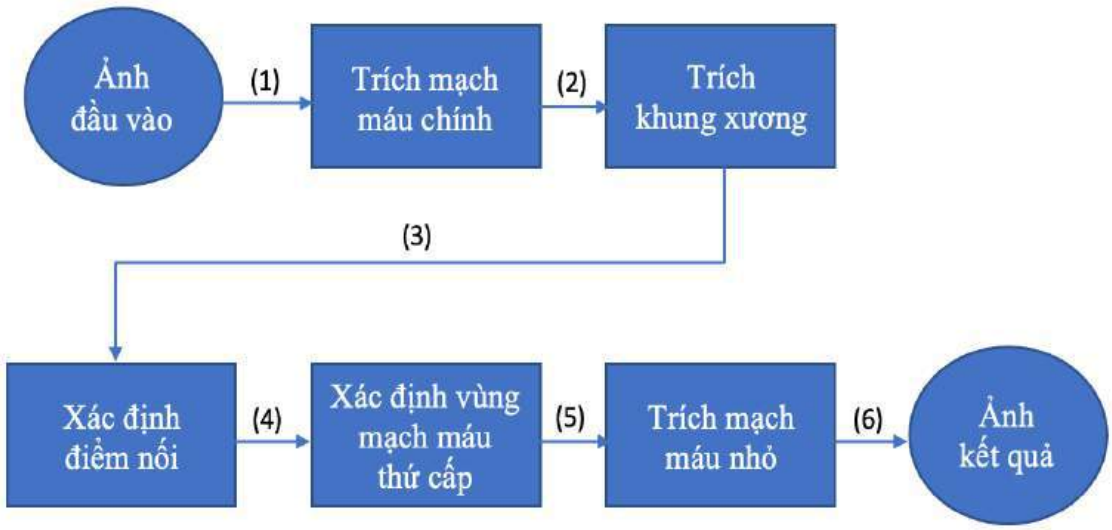
3.2 Mô hình đề xuất

Với tính chất mạch vành là: máu sẽ chảy theo một hướng, cấu trúc mạch vành phân cấp từ mạch chính đến các mạch phụ. Vì thế luận án đề xuất dùng hướng tiếp cận bài toán là phân đoạn mạch máu từ thô đến mịn. Nghĩa là luận án sẽ trích xuất những phần có tính chất chắc chắn là mạch máu. Sau đó, từ phần "thô" đã phát hiện trước đó, lần lượt tìm những mạch máu mảnh nhỏ hơn trong một khu vực giới hạn nhất định (mạch nhánh), hay có thể hiểu việc cần làm ở bước này là trích xuất những mạch máu nhỏ mịn hơn.

Sau khi nghiên cứu cơ sở dữ liệu của bộ ảnh chụp mạch vành. Luận án quan sát thấy ảnh xuất hiện rất nhiều nhiễu, trong khi độ tương phản giữa mạch máu và nền rất thấp, đặc biệt ở những vùng mạch máu nhỏ. Do đó, nếu sử dụng một thuật toán duy nhất để phân đoạn sẽ không hiệu quả. Ngoài ra, cấu trúc mạch vành rất phức tạp, độ rộng mạch thay đổi tùy thuộc vào thời điểm chụp ảnh, lượng máu dịch chuyển khác nhau. Nhưng với cấu trúc mạch máu theo một chiều từ trên xuống dưới và nhỏ dần,

luận án sẽ xây dựng khung xương mạch máu để phân đoạn các mạch máu nhỏ hơn và gom chúng lại tạo thành một cây mạch máu hoàn chỉnh.

Unet là một trong những mô hình học sâu hiệu quả cho phân đoạn ảnh y khoa. Tuy nhiên, với dữ liệu mạch chính, mạch phụ có các tính chất khác nhau nên không thể dùng một mô hình Unet duy nhất phân đoạn để có kết quả tốt nhất nên luận án đề xuất mô hình xử lý từng phần, hình 3.1, mỗi phần sẽ là một mô hình Unet tương ứng. Đầu tiên, luận án tiến hành trích xuất mạch máu chính cùng với những đặc trưng cơ bản như khung xương và những điểm nối. Khung xương được định nghĩa là đường trung tâm của mạch máu. Điểm nối là những điểm giao nhau giữa các đoạn mạch máu trong khung xương. Sau đó, dựa vào mạch máu chính, luận án tiếp tục thực hiện quá trình trích xuất toàn bộ những mạch máu kết nối với mạch máu chính thông qua điểm nối, hay còn gọi là mạch máu thứ cấp. Cuối cùng, ta có được kết quả phân đoạn mạch máu.



Hình 3.1 Mô hình đề xuất phân đoạn mạch vành.

Nếu chỉ dùng một mô hình Unet mà tăng cường tham số cũng như các tầng thì chi phí huấn luyện sẽ cao. Vì đồng thời phải học tất cả thông tin từ tính chất của mạch chính đến thông tin của tính chất mạch phụ; không những vậy, những mạch phụ còn chồng chéo, nhiễu nhiều ở nền.

Luận án đề xuất mô hình gồm hai giai đoạn như sau:

- Giai đoạn 1: trích mạch máu chính gồm ba bước
    - Phân đoạn mạch máu chính dựa vào Unet main
    - Trích khung xương
    - Xác định điểm nối
- Giai đoạn 2: trích mạch máu thứ cấp gồm ba bước
    - Chọn vùng mạch máu
    - Sử dụng Unet branch để trích mạch máu thứ cấp
- Giai đoạn 3: Tái tạo đầy đủ cây mạch máu

3.3 Xây dựng mô hình

3.3.1 Trích mạch máu chính

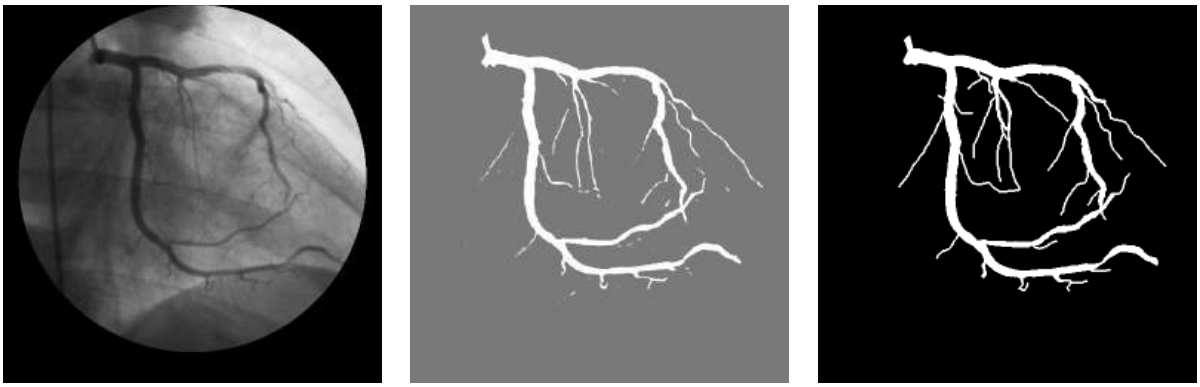
Việc trích xuất mạch máu chính là một trong những bước quan trọng giúp ta có thể phát hiện toàn bộ mạch máu nhỏ. Như chúng ta đã biết, những nhánh mạch máu thường có đường nét không rõ ràng, mảnh hơn và nhỏ hơn nhiều so với mạch chính. Do đó, thực hiện tốt quá trình trích xuất mạch chính tạo thuận lợi cho quá trình phát hiện những mạch máu nhỏ sau này.

3.3.1.1 Phân đoạn mạch máu chính

Tại bước này, luận án sử dụng mô hình đã được huấn luyện của Unet với thiết kế riêng cho việc phân đoạn mạch chính, luận án gọi là Unet main, thuật toán 3.1. Thuật toán 3.1 gồm ba bước chính. Bước đầu tiên đọc ảnh mạch vành, sau đó chuẩn hóa kích thước để dữ liệu đầu vào sẽ giống nhau về kích thước ở bước hai (do những bộ dữ liệu khác nhau được lấy ảnh mạch vành từ những thiết bị khác nhau sẽ cho kích thước khác nhau), dựa trên mô hình Unet main đã được huấn luyện trước đó để phân đoạn mạch vành (mô hình này có nhiệm vụ giữ lại các điểm ảnh là mạch vành với màu trắng và những điểm ảnh khác sẽ chuyển màu xám). Kết quả của bước ba là ảnh mạch vành được phân đoạn như hình 3.2. Vì mô hình Unet main tập trung vào phân

đoạn mạch chính nên sẽ không có kết quả chính xác với mạch thứ cấp, như hình 3.2(b) (kết quả phân đoạn cho mạch chính) và 3.2(c) (ảnh groundtruth) nhưng với mạch chính thì chính xác hoàn toàn.

Thuật toán 3.1 Trích xuất mạch máu chính
Input: Ảnh y khoa mạch máu *img*. *Output:* Kết quả phân đoạn mạch máu chính *img_main.*
Bước 1: Đọc ảnh đầu vào. *img = read_image()* ***Bước 2***: Chuẩn hóa kích thước ảnh phù hợp. *img_resize = norm(Img)* ***Bước 3***: Sử dụng mô hình Unet main phân đoạn mạch máu. *img_main = Unet1.Segmentation(img_resize)*



(a) Ảnh ban đầu (b) Kết quả của Unet main (c) Ảnh ground truth

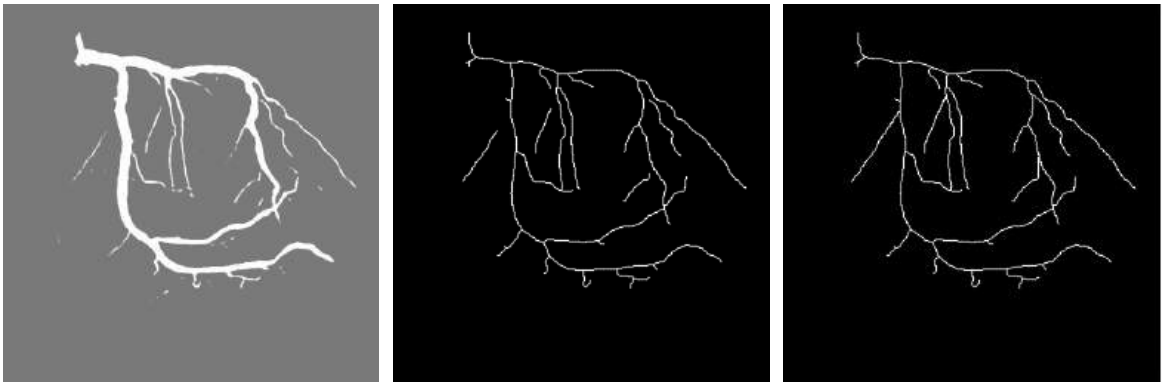
Hình 3.2 Ảnh mạch máu khi sử dụng Unet để trích xuất.

3.3.1.2 Trích khung xương

Để trích khung xương từ ảnh nhị phân mạch vành, luận án sử dụng thuật toán Zhang-Suen [13] vì thời gian lấy khung xương của thuật toán nhanh và khung xương tương đối phù hợp với hình dáng của mạch máu.

Để xác định các điểm nối, luận án cần xác định khung xương của các mạch máu. Tuy nhiên các mạch máu sau khi phân đoạn sẽ có thể bị đứt đoạn do thời điểm chụp ảnh,

lượng máu dịch chuyển khác nhau nên vùng mạch máu không đồng đều, hoặc do bác sĩ cầm thiết bị lấy ảnh không ổn định. Để giải quyết bài toán, luận án đề xuất cải tiến thuật toán Zhang-Suen [13], thuật toán 3.2 (cải tiến chính ở bước 4 của thuật toán 3.2). Ở ba bước đầu tiên thuật toán 3.2 tiến hành nhị phân hóa ảnh kết quả từ thuật toán 3.1 ở trên, sau đó loại bỏ các thành phần nhỏ ở bước hai (bước xử lý này cho phép giảm bớt các thành phần nhiễu của kết quả phân đoạn – đây là một cải tiến nhỏ để tập trung trích khung xương của một thành phần duy nhất), bước thứ ba là dùng phương pháp Zhang-Suen để trích khung xương. Bước cuối cùng đó là bước cải tiến chính, bước này xác định các thành phần liên thông, những thành phần liên thông nào quá nhỏ (dưới ngưỡng α so với kích thước mạch) luận án sẽ loại bỏ. Thông qua hướng của thành phần liên thông nhỏ và nơi gần thành phần liên thông nhỏ của thành phần liên thông lớn để xác định kết nối các thành phần này với nhau để có được khung xương hoàn chỉnh. Thuật toán 3.2 cho kết quả như hình 3.3, nếu chỉ dùng thuật toán Zhang-Suen nguyên gốc (hình 3.3(b)) sẽ không có được khung xương hoàn chỉnh của mạch vành như thuật toán cải tiến (hình 3.3(c)).



(a) Ảnh ban đầu (b) Ảnh lấy khung xương Zhang-Suen (c) Ảnh lấy khung xương Zhang-Suen (cải tiến)

Hình 3.3 Kết quả áp dụng thuật toán Zhang-Suen cải tiến.

Thuật toán 3.2 Trích khung xương mạch máu từ ảnh nhị phân
Input: Ảnh phân đoạn mạch máu chính *img_main.* *Output:* Khung xương mạch máu *skeleton_main*.

Bước 1: Nhị phân ảnh *img_main*.

binary_img_main = get_binary_image(img_main)

Bước 2: Xóa bỏ các thành phần có kích thước điểm ảnh nhỏ hơn ngưỡng γ.

binary_img_main = remove_component(binary_img_main, γ)

Bước 3: Áp dụng thuật toán Zhang-Suen.

skeleton_ZS = get_skeleton_Zhang_Sue(binary_img_main)

Bước 4: Tiến hành kết nối các đoạn rời rạc của khung xương *skeleton_ZS (***cải tiến của luận án***)*:

Tìm các thành phần liên thông *components* của *skeleton_ZS.*

Với *components* xác định: thành phần liên thông lớn nhất *main_component* và các thành phần còn lại *small_ components.*

Loại bỏ các *small_ components[j]* mà size(*small_ components[j])*< α

Khởi tạo *skeleton_main = main_ component*

Với mỗi *small_ components[i]*:

Tìm hướng kết nối *direct_* với *main_ component*

Kết nối *small_components[i]* với *main_component* theo hướng *direct_*

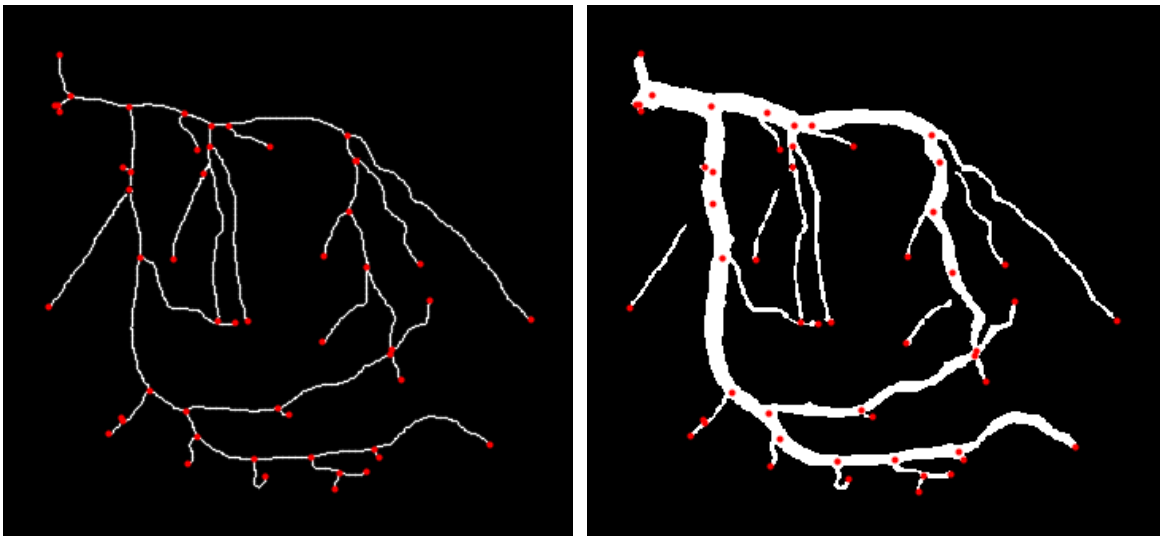
Cập nhật *skeleton_main*

3.3.1.3 Xác định điểm nối

Với kết quả từ thuật toán 3.2, luận án tiến hành xác định các điểm quan trọng *joint* (bao gồm các điểm nối và các điểm bắt đầu, kết thúc của mạch máu) bằng đề xuất thuật toán 3.3, thuật toán này có hai bước chính. Bước đầu tiên đặt nhãn giá trị của điểm ảnh): nếu điểm ảnh thuộc nền thì sẽ đặt nhãn là 0, nếu điểm ảnh thuộc khung xương mạch vành thì: nếu có ít hơn 03 lân cận cùng giá trị thì đặt nhãn là 1, còn lại nhãn là 2 cho từng điểm ảnh. Bước cuối cùng duyệt tất cả các điểm ảnh có nhãn là 2, sẽ tìm các lân cận của điểm ảnh này cũng có nhãn là 2, dựa vào dữ liệu này sẽ tìm được điểm *centroid* và đây là một điểm *joint*. Thuật toán 3.3 cho kết quả như hình

3.4(a), sau đó chúng ta đưa các điểm *joint* vào ảnh không trích khung xương như hình 3.4(b).

Thuật toán 3.3 Xác định các joint của mạch máu
Input: Khung xương mạch máu *skeleton_main*. *Output:* Mảng A gồm các *joint.*
Bước 1: Trên khung xương, ta tiến hành đánh nhãn *label* cho các điểm ảnh tại (i,j) như sau: $label(i,j)$ $= \begin{cases} 0: \text{Giá trị điểm ảnh tại (i,j) bằng 0 (là nền)} \\ 1: \text{Giá trị điểm ảnh tại (i,j) bằng 1 và có 2 lân cận có giá trị bằng 1} \\ 2: \text{Trường hợp còn lại.} \end{cases}$ ***Bước 2:*** Tiến hành tìm các điểm *join*: While $(i,j) \in$ *skeleton_main* và $label(i,j) == 2$: Loang tìm tất cả các điểm lân cận với (i,j) có *label* = 2 và tính vị trí trung tâm *centroid* của các điểm trên. Lưu lại *centroid* như một *join*. Cập nhật *joint* vào A.



(a) Điểm nối trên khung xương (b) Điểm nối trên mạch chính

Hình 3.4 Những điểm nối giữa các nhánh mạch máu.

3.3.2 Trích mạch máu thứ cấp

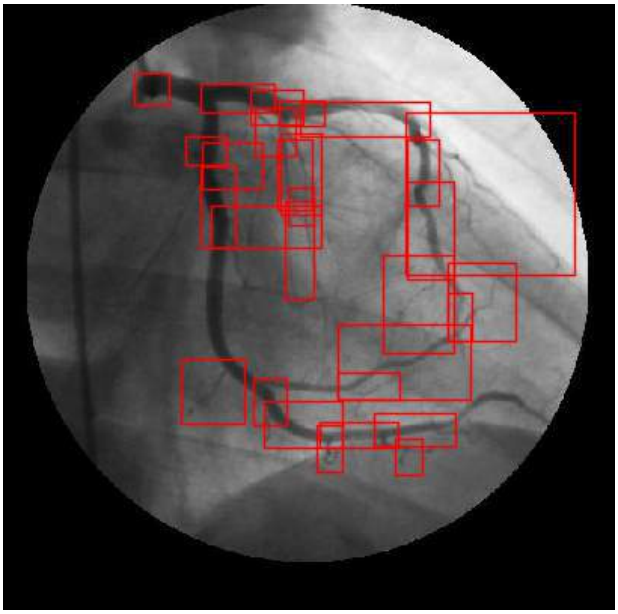
Mặc dù kết quả thực hiện khi sử dụng Unet để phân đoạn, mạch máu về trực quan được trích xuất tương đối tốt, nhưng những mạch máu nhỏ hơn, chúng vẫn còn đứt nét không rõ ràng. Các mạch phụ sẽ kết nối với mạch chính tại các điểm nối, nên từ các điểm nối, luận án trích xuất một hình chữ nhật có kích thước M×N để làm ảnh dữ liệu đầu vào cho bài toán phân đoạn tìm mạch phụ, thuật toán 3.4 và thuật toán 3.5.

3.3.2.1 Chọn vùng mạch máu

Luận án xây dựng thuật toán chọn vùng để trích mạch máu thứ cấp từ các điểm *joint* giữa các đoạn mạch máu, thuật toán 3.4**.** Một cửa sổ được cắt vùng ảnh bao gồm hai điểm: *point i* và *point j*, với chiều rộng là $w = |(x_i - x_j)|$ và chiều dài là $h = |(y_i - y_j)|$.

Tuy nhiên, việc trích hình chữ nhật từ những điểm nối ban đầu không tốt với quá trình phân đoạn. Vì vậy, luận án mở rộng một khoảng bằng Δp điểm ảnh để đảm bảo kết quả tốt hơn, như hình 3.5. Thuật toán gồm hai bước chính, bước đầu tiên từ từng các điểm *joint* tìm lân cận xung quanh để đảm bảo hình chữ nhật cắt được vùng mạch

thứ cấp từ điểm *joint* ở mạch chính. Sau khi có lân cận của từng điểm *joint* thì bước hai của thuật toán sẽ xác định hình chữ nhật đủ lớn để bao đoạn mạch thứ cấp.



Hình 3.5 Tạo cửa sổ từ các *joint*.

Thuật toán 3.4 Chọn vùng mạch máu
Input: Mảng *A* lưu các *joint*. Khung xương *skeleton_main*. Nhãn *label.* *Output*: Mảng *B* có *M* phần tử, mỗi phần tử lưu tọa độ khung hình chữ nhật chứa các mạch máu.
Bước 1: Tìm các đoạn mạch máu *edges* Khởi tạo *edges = []* Duyệt các *joint* trong *A*: *edge = []* Repeat Tìm lân cận *neightbor* của *joint* có *label* ≠ 0 và 1 Cập nhật lại *joint = neighbor* Thêm *joint* vào *edge.* Until *neightbor* ∈ *A* Thêm *edge* vào *edges.*

Bước 2: Xác định hai điểm trái trên và phải dưới của hình chữ nhật

For *edge* ∈ *edges*:

Lấy hai điểm *point1* và *point2* từ *edge* sao cho *point1* là điểm trái trên và *point2* là điểm phải dưới chứa toàn bộ đoạn mạch máu.

B[i].point1 = point1

B[i].point2 = point2

Endfor

3.3.2.2 Sử dụng Unet branch để trích mạch máu thứ cấp

Luận án sử dụng mô hình đã được huấn luyện của Unet với thiết kế riêng cho việc phân đoạn mạch máu phụ, luận án gọi là Unet branch, thuật toán 3.5. Với các đoạn mạch thứ cấp sau khi được cắt từ thuật toán 3.4 thì kích thước sẽ không đồng nhất nên thuật toán 3.5 sẽ phải điều chỉnh kích thước cho phù hợp, sau đó sẽ phân đoạn các đoạn mạch thứ cấp bằng mô hình Unet branch (đây là mô hình Unet được thiết kế cho phân đoạn các đoạn mạch thứ cấp). Sau khi có kết quả sẽ biến đổi ảnh kết quả về kích thước ban đầu (khi chưa điều chỉnh kích thước – ánh xạ ngược).

Thuật toán 3.5 Trích mạch máu thứ cấp
Input: Mảng *B* có *M* phần tử, mỗi phần tử lưu tọa độ khung hình chữ nhật chứa các mạch máu. Ảnh mạch vành *img*. *Output:* Phân đoạn các mạch máu phụ *edges_segment.*

For *i=1 to M do*
edge_segment = img.drop(B[i])
edge_segment = resize(edge_segment)
edges_segment_temp[i] = Unet2. Segmentation(edge_segment)
edges_segment[i] = undo_resize(edges_segment_temp[i])
Endfor

3.3.3 Tái tạo đầy đủ cây mạch máu

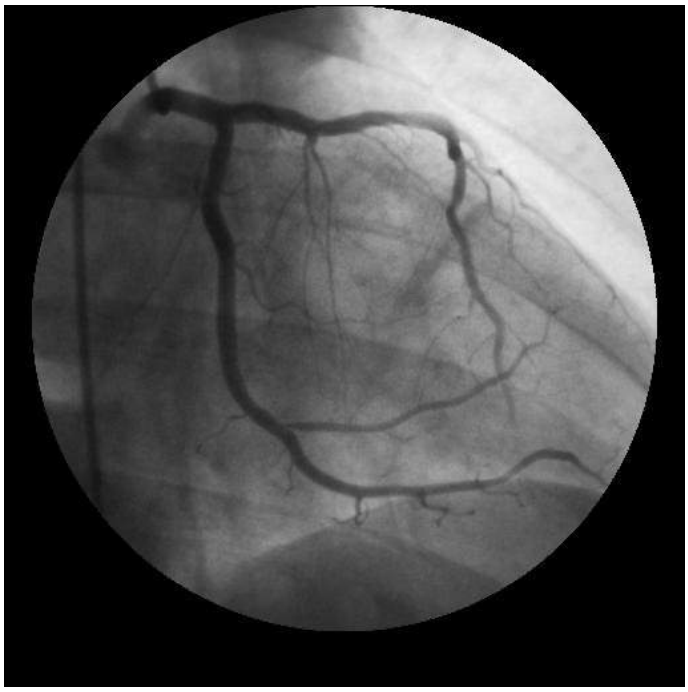
Luận án tái tạo đầy đủ cây mạch máu từ các mạch máu con và mạch máu chính bằng thuật toán 3.6. Thuật toán này dựa trên các vị trí của điểm *joint* để ráp các đoạn mạch của mạch thứ cấp lên trên mạch chính.

Thuật toán 3.6 Tái tạo đầy đủ cây mạch máu
Input: Mạch máu chính *img_main* và các đoạn mạch máu phụ *edges_segment*. *Output*: Mạch máu hoàn chỉnh *Res*.

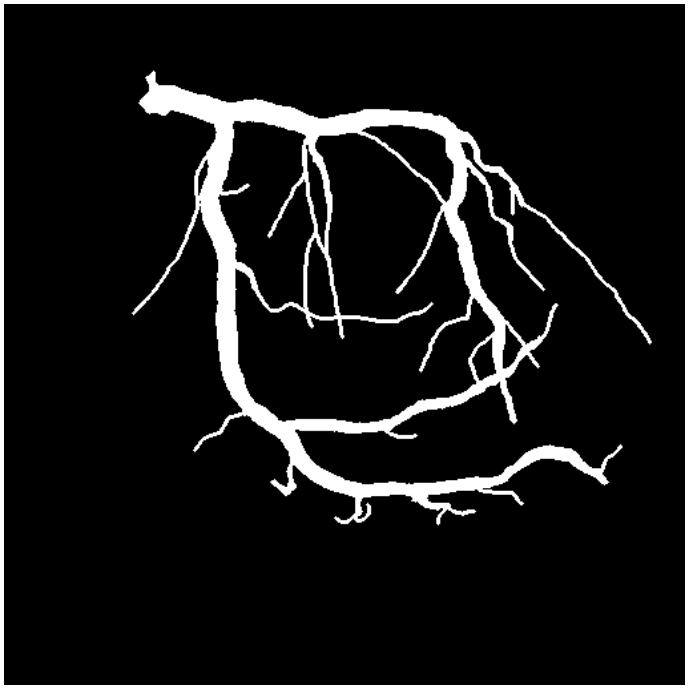
Res = img_main
For *i=1 to M do*
Res = Res ∪ edges_segment[i]
Endfor

3.4 Thực nghiệm

Luận án xây dựng bộ dữ liệu và *ground truth* như hình 3.6 và hình 3.7 tương ứng để tiến hành đánh giá độ chính xác của phương pháp thực hiện. Dữ liệu xây dựng được chuyên gia kiểm tra tính đúng đắn. Ngoài ra luận án dùng phần mềm SketchUp [63] để tính toán và đo đạc các biến đổi của ảnh để phân tích các biến đổi giúp làm giàu bộ dữ liệu ảnh X-quang.



Hình 3.6 Ảnh đầu vào có kích thước 512×512.



Hình 3.7 Ảnh ground truth.

3.4.1 Môi trường thực nghiệm

Luận án đã thực nghiệm ở môi trường máy tính thực hiện huấn luyện mạng Unet main và Unet branch có cấu hình gồm: 2 bộ vi xử lý CPU Intel® Xeon® E5-2630 (2.3Ghz); 128GB Ram; 4 GPU NVIDIA Geforce GTX 1080Ti - Vram 11GB (CUDA 6.1); hệ điều hành Linux Ubuntu Server 18.04. Với ngôn ngữ Python 3.

3.4.2 Phân đoạn mạch máu bằng Unet

Sau quá trình thực nghiệm nhiều lần, luận án lựa chọn tham số cho các thuật toán đã xây dựng như bảng 3.1, bảng 3.2, bảng 3.3.

Bảng 3.1 Giá trị các tham số mô hình Unet main.

Tham số	**Giá trị**	**Ý nghĩa**
Filter1	64	Số bộ lọc của lớp tích chập đầu tiên
Activation1	ReLU	Hàm kích hoạt sau mỗi lớp tích chập
learning_rate1	1e-4	Tham số hệ số học của thuật toán tối ưu hàm lỗi
output_activation1	sigmoid	Hàm kích hoạt tại lớp ngoài cùng

Bảng 3.2 Giá trị các tham số mô hình Unet branch.

Tham số	**Giá trị**	**Ý nghĩa**
Filter2	16	Số bộ lọc của lớp tích chập đầu tiên
Activation2	ReLU	Hàm kích hoạt sau mỗi lớp tích chập
learning_rate2	1e-4	Tham số hệ số học của thuật toán tối ưu hàm lỗi
output_activation2	sigmoid	Hàm kích hoạt tại lớp ngoài cùng

Bảng 3.3 Giá trị các tham số thuật toán xây dựng khung xương mạch máu.

Tham số	Giá trị	Ý nghĩa
γ	116	Kích thước tối thiểu là mạch máu
Δp	20	Mở rộng trích hình chữ nhật từ điểm nối

3.5 Kết quả và đánh giá

Luận án đã sử dụng độ đo Dice để đánh giá kết quả các thuật toán để phân đoạn ảnh dựa trên hình ảnh ground truth.

Đánh giá hiệu suất phân đoạn mạch vành với Unet dựa trên chiến lược từ thô đến mịn để phân đoạn lặp lại và bao gồm các phương pháp tiếp cận khác. Hình 3.8 minh họa kết quả phân đoạn của phương pháp mà luận án đề xuất. Qua phân tích thực nghiệm, phương pháp phân đoạn các mạch vành lớn cho kết quả tốt. Hiệu suất phân đoạn mạch vành không phụ thuộc kích thước đạt 80,17%. Ngoài ra, phương pháp được đề xuất trong luận án còn phát hiện được một số lượng lớn các mạch máu nhỏ và mỏng. Luận án có kết quả như bảng 3.4. Cuối cùng, phương pháp có hiệu suất trung bình của phân đoạn mạch vành là 76,40%. Luận án cũng so sánh hiệu suất của phương pháp được đề xuất với Unet cơ sở và các kỹ thuật khác trong [8] [64] [30] trên cơ sở dữ liệu của luận án. Hình 3.9 thể hiện sự so sánh các kết quả phân đoạn. Bảng 3.5 mô tả tóm tắt hiệu suất phân đoạn mạch vành theo hệ số Dice. Các kết quả thí nghiệm được mô tả là giá trị trung bình ± độ lệch chuẩn. Kết quả của luận án cho thấy phương pháp đề xuất thật sự hiệu quả hơn các phương pháp trước đó. Hướng tiếp cận từ thô đến mịn với hai mô hình Unet đã mang lại kết quả khả quan.

Bảng 3.4 Kết quả độ chính xác từng ảnh và trung bình.

Ảnh	Độ chính xác theo Dice (%)
1	74,26%
2	73,64%

3	79,43%
4	80,17%
5	75,53%
6	75,34%
…	…
Trung bình	76,40%



(a) Ảnh ban đầu (b) Ảnh kết quả (c) Ảnh ground truth

Hình 3.8 Kết quả quá trình phân đoạn ảnh trong cơ sở dữ liệu.

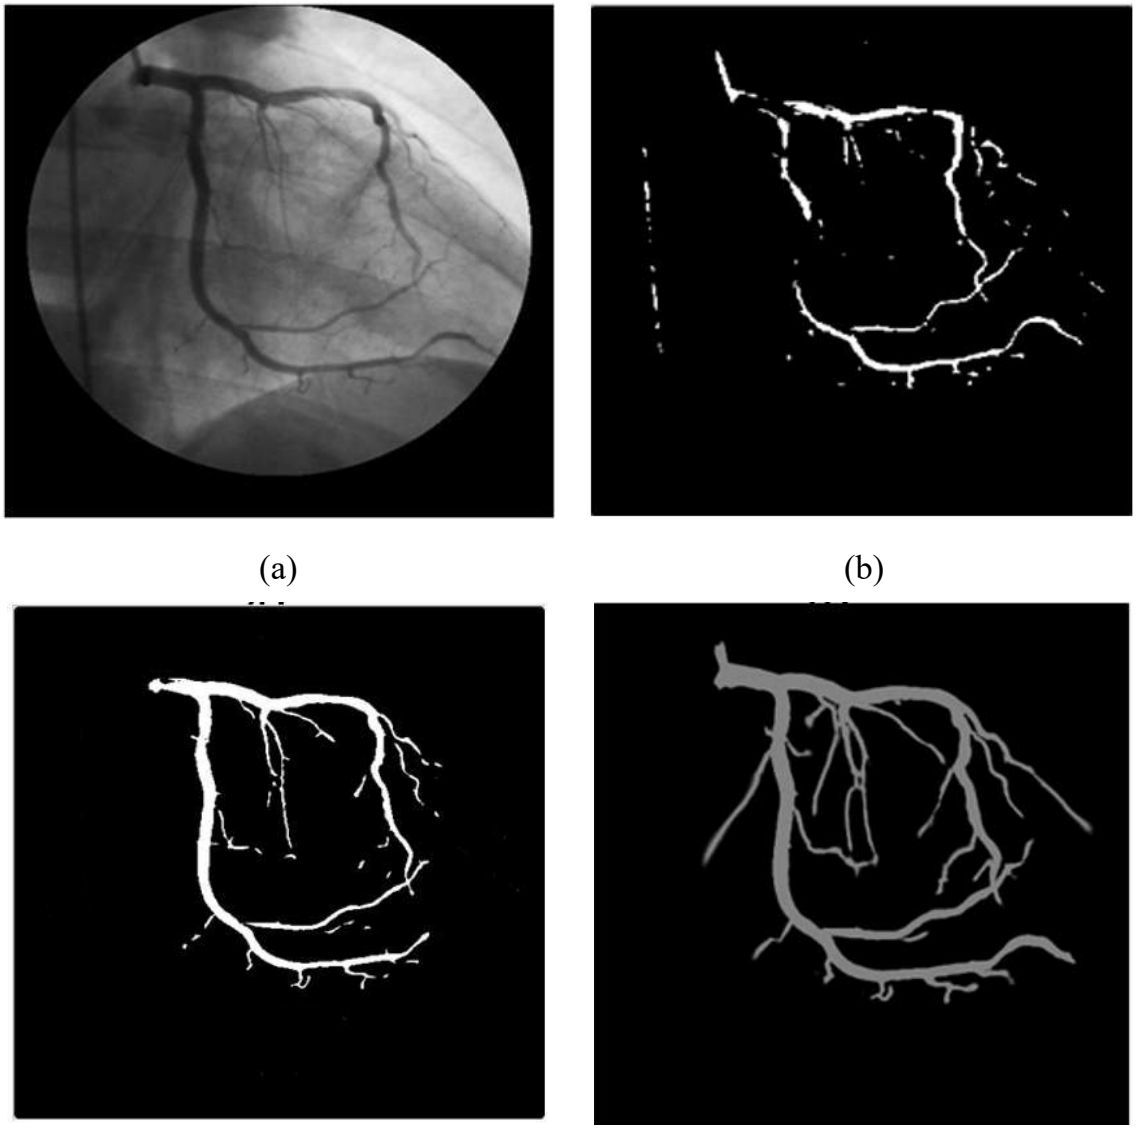
Bảng 3.5 So sánh các phương pháp khác.

Phương pháp	**Độ chính xác theo Dice (%)**
DFB based segmentation [64]	45,50 ± 1,31%
Coarse-to-fine based DFB and Otsu [33]	71,34 ± 0,80%
Baseline Unet [30]	73,64 ± 1,32%
Phương pháp đề xuất	**76,40 ± 1,02%**

Từ hình 3.9 và bảng 3.5, luận án cho thấy rằng phương pháp đề xuất với cách tiếp cận phân cấp dựa trên chiến lược học sâu và từ thô đến mịn có kết quả phân đoạn tốt hơn và vượt trội hơn các phương pháp tiêu chuẩn. Trong hình 3.9, phương pháp phân

đoạn dựa trên DFB [64] dẫn đến đoạn mạch bị đứt đoạn hơn và không cải thiện được các mạch nhỏ so với cách tiếp cận của luận án một cách chính xác. Hơn nữa, phương pháp này không thể phát hiện các mạch nhỏ có cường độ thấp và các mạch lớn bị thiếu các thành phần. Phương pháp của luận án phát hiện các mạch lớn và nhỏ cùng một lúc; ngay cả trong trường hợp tồn tại sự khác biệt lớn về cường độ giữa các mạch lớn (là vật thể có độ tương phản cao) và các mạch nhỏ (là vật thể có độ tương phản thấp), phương pháp dựa trên DFB không thể trích xuất đáng kể các mạch nhỏ. Phương pháp đề xuất trong [8] có thể trích xuất các mạch máu lớn rất tốt, nhưng dẫn đến bỏ sót các mạch máu nhỏ, mỏng và các mạch có độ tương phản thấp so với nền. Phân tích thực nghiệm chỉ ra rằng Unet cơ sở mang lại độ chính xác cao hơn so với phương pháp DFB và Otsu truyền thống. Tuy nhiên, phương pháp Unet cơ sở cũng dẫn đến việc bỏ sót những mạch nhỏ. Phân đoạn dựa trên chiến lược Unet và từ thô đến mịn dựa trên phương pháp được đề xuất của luận án mang lại hiệu suất tối ưu.

Phương pháp của luận án được đề xuất để khắc phục vấn đề đó bằng cách phát hiện riêng biệt các mạch lớn và mạch nhỏ dựa trên kỹ thuật phân cấp thông qua mô hình Unet main và branch. Vì các mạch lớn luôn có độ tương phản nền cao hơn các mạch nhỏ nên mô hình Unet phù hợp để trích xuất chúng. Phân đoạn dựa trên chiến lược từ thô đến mịn đảm bảo rằng phương pháp này có thể trích xuất chính xác các mạch lớn. Trong giai đoạn tách mạch nhỏ, trước tiên luận án giảm tác động của các mạch lớn và tăng cường độ tương phản trên vùng bao gồm các mạch nhỏ để giải quyết vấn đề độ tương phản thấp trên các vùng mạch nhỏ. Khi các vùng mạch nhỏ tăng độ tương phản, chúng được Unet branch phát hiện và phân đoạn dễ dàng hơn. Điều này rất quan trọng để trích xuất các mạch nhỏ. Kết quả thực nghiệm cho thấy phương pháp của luận án khắc phục được những hạn chế của các phương pháp tiêu chuẩn, chẳng hạn như cường độ ánh sáng mạch nhỏ và nhiễu ...

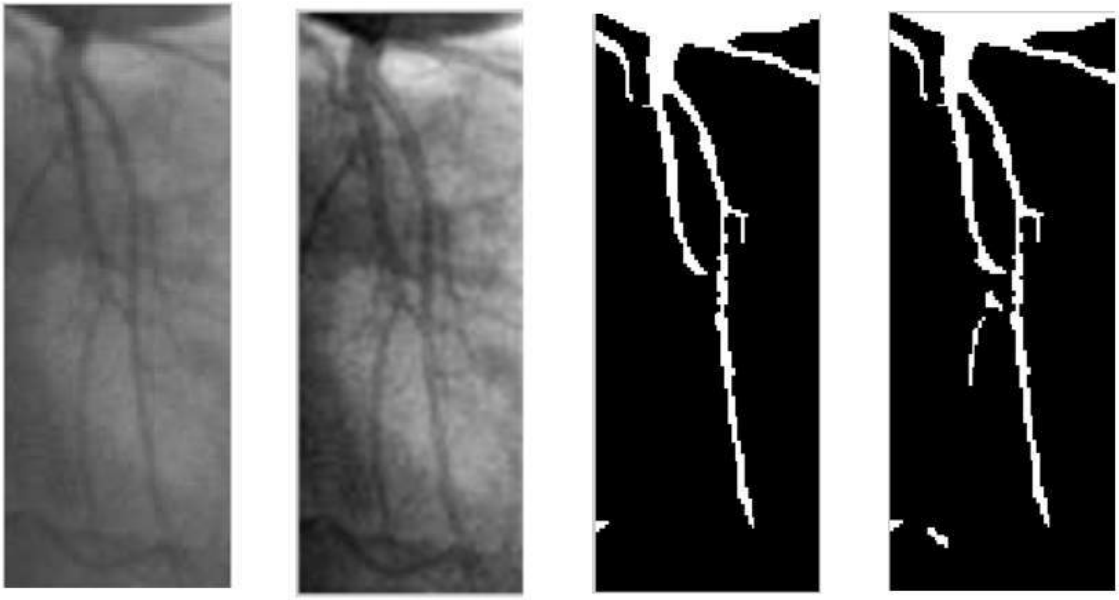


Hình 3.9 So sánh kết quả phân đoạn: (a) ảnh đầu vào; (b) kết quả trong [64] (c) kết quả trong [33]; (d) kết quả của phương pháp của luận án.

Tuy nhiên, hầu hết các lỗi đều xảy ra khi xử lý các mạch nhỏ. Những lỗi này xảy khi có tăng cường độ tương phản khác nhau và phụ thuộc chất lượng của ảnh. Đặc biệt, phương pháp truyền thống có nâng cao độ tương phản thì có sai sót sẽ tăng do cả nền cũng được tăng cường. Trong dữ liệu của luận án, có một số hình ảnh mạch nhỏ bị ảnh hưởng bởi ánh sáng và nhiễu, chẳng hạn như điều kiện ánh sáng yếu, độ tương phản thấp (tại thời điểm chụp ảnh do máu dịch chuyển trong mạch, hoặc điều kiện

môi trường). Hình 3.10 cho thấy hình ảnh mạch máu nhỏ bị ảnh hưởng bởi khi có tăng cường độ sáng và độ tương phản. Một số nhánh mạch nhỏ bị thiếu.

Nghiên cứu của luận án có những hạn chế khác, đó là hạn chế về số lượng của bộ dữ liệu về chụp X-quang mạch vành, đây là nhược điểm của phương pháp học sâu. Học sâu dựa trên phân đoạn hình ảnh y khoa đòi hỏi kích thước dữ liệu phải có đủ đến một mức nhất định để đạt được độ chính xác cao hơn các phương pháp truyền thống, mặc dù luận án sử dụng Unet là mô hình học sâu có thể đáp ứng với dữ liệu đầu vào không cần nhiều. Và mạch thứ cấp thứ hai có thể phải xem xét nên có thể phải xây dựng thêm mô hình giải quyết cho mạch thứ cấp thứ hai. Nếu mạch vành được chụp tại thời điểm máu đã tuần hoàn ra khỏi hết vị trí chụp thì ảnh mạch rất khó để phân đoạn chính xác. Đặc biệt với người được chụp mạch vành nếu quá nhiều mỡ, mỡ bao xung quang mạch vành thì đây là cũng là nguyên nhân tạo rất nhiều nhiễu xung quanh mạch vành. Hoặc thời điểm chụp mạch vành, người được chụp không giữ tư thế ổn định sẽ gây rung động nhiễu trong ảnh.



(a) (b) (c) (d)

Hình 3.10 Lỗi phân đoạn ảnh mạch nhỏ do ảnh hưởng của ánh sáng
(a) ảnh đầu vào; (b) ảnh tăng cường độ tương phản;
(c) kết quả sử dụng Unet có tăng cường độ tương phản;
(d) kết quả từ phương pháp của luận án không tăng cường độ tương phản.

3.6 Kết chương

Luận án xây dựng thành công phương pháp phân đoạn mạch vành theo hướng tiếp cận từ thô đến mịn với 02 mô hình Unet main để phân đoạn mạch chính và Unet branch cho mạch nhánh, từ mạch chính luận án xây dựng thuật toán trích khung xương Zhang-Suen cải tiến để trích khung xương cho mạch chính, sau đó tìm các điểm nối. Từ các điểm nối xây dựng thuật toán xác định vùng có mạch nhánh, dữ liệu này được phân đoạn với mô hình Unet branch. Kết quả phân đoạn từ hai mô hình sẽ được tái tạo cây mạch máu. Kết quả nghiên cứu bài toán phân đoạn mạch vành đã công bố được một bài báo khoa học với tên "Coronary Vessel Segmentation by Coarse-to-Fine Strategy using U-Nets" ở tạp chí SCIE "BioMed Research International" [CT2].

CHƯƠNG 4 BÀI TOÁN PHÁT HIỆN BẤT THƯỜNG TRÊN MẠCH VÀNH

Chương 4, luận án trình bày phương pháp giải quyết bài toán phát hiện bất thường trên ảnh mạch vành. Phương pháp được đề xuất dựa trên phân tích đặc tính của ảnh mạch vành và các hướng tiếp cận cho nghiên cứu của nhiều chuyên gia. Luận án đề xuất hai hướng tiếp cận chính: (1) xây dựng thuật toán duyệt trên cạnh của đoạn mạch vành, thuật toán này (thuật toán duyệt cạnh) sẽ xem xét sự biến thiên của hướng chuyển động trên cạnh mạch vành để quyết định là đoạn mạch vành có bất thường hay không? (2) Mô hình học sâu dựa trên dữ liệu đầu vào có tiền xử lý hay không để huấn luyện xác định đoạn mạch có bất thường hay không. Dữ liệu được xử lý bằng cách trích cạnh để loại bỏ bớt thông tin không cần thiết có thể giúp mô hình học sâu học được nhiều thông tin chắc chắn hơn. Luận án sử dụng hai phương pháp trích cạnh: Canny (phương pháp truyền thống) được đáng giá là hiệu quả trích cạnh tốt nhất trong các phương pháp truyền thống, và DexiNed (phương pháp học sâu trích cạnh) là phương pháp học sâu tốt nhất cho trích cạnh để xem xét tính hiệu quả của giải pháp phân loại. Không những vậy, luận án còn sử dụng các mặt phẳng thông tin kết hợp phương pháp voting mềm trên mô hình học sâu để phát hiện bất thường trên mành vành. Kết quả nghiên cứu được công bố 03 bài báo: 01 bài báo công bố trên tạp chí SCIE [CT1], 01 bài báo công bố trên tạp chí Scopus [CT3], 01 bài báo công bố trên hội nghị IEEE thuộc range B [CT5]. Dữ liệu đầu vào được sử dụng cho các phương pháp chính là kết quả của phương pháp phân đoạn ở chương 3.

4.1 Các hướng tiếp cận

Các phương pháp phát hiện bất thường (mạch phình hay hẹp) trên mạch vành được chia làm hai hướng tiếp cận chính: (1) nhóm tác giả xây dựng thuật toán dựa trên các tính chất của mạch vành kết hợp các phương pháp truyền thống, (2) dùng các phương pháp máy học mà đặc biệt là học sâu để giải quyết. Hiện nay tất cả các nghiên cứu đều chỉ có nghiên cứu phát hiện mạch bị hẹp là chủ yếu. Những nghiên cứu này đi theo hai hướng: xác định vị trí mạch vành bị hẹp trực tiếp từ ảnh ban đầu; hoặc xác

định mạch vành có bị hẹp hay không từ ảnh mạch vành đã được phân đoạn, ảnh mạch vành này chỉ còn lại biên của mạch vành.

- Nhóm sử dụng thuật toán kết hợp phương pháp truyền thống: tác giả F. Cervantes-Sanchez và cộng sự [65] dùng bộ lọc Gauss để tăng cường ảnh phát hiện mạch máu dựa trên giả định mạch máu có thể xấp xỉ với đường cong Gauss dựa trên các mẫu; rồi kết hợp thuật toán Gen để phát hiện chỗ mạch bị hẹp. Dựa trên nghiên cứu này, I. Cruz-Aceves [66] cải tiến với phương pháp phân loại Bayes kết hợp bộ lọc Gauss dựa trên tiến hóa vi phân. Tác giả Sethuraman Sankaran và đồng nghiệp ước lượng quang thông rồi xác định cây khung của cây mạch vành để huấn luyện mô hình rừng ngẫu nhiên cho việc xác định nơi hẹp của mạch vành [67]. Mạch vành được tăng cường dựa vào phương pháp Hess, sau đó nhóm tác giả Tao Wan [68] trích khung xương mạch vành bằng phương pháp đồng mức kết hợp xem xét bán kính của mạch rồi cải tiến kết quả bằng cách xem xét các cực trị để có thể xác định vị trí mạch bị hẹp. Đồng thời nhóm tác giả Chenxin Sui [69] phân đoạn mạch máu từ ma trận Hess và song hành cùng thuật toán tăng vùng sẽ xác định được khung xương của mạch vành. Từ các điểm trên khung xương, tác giả tính khoảng cách đến thành mạch để xem các vị trí này có phải là điểm mà mạch vành bị hẹp hay không. M. A. Gil-Rios đề xuất Phương pháp với các bước trích xuất tính năng và lựa chọn tính năng tự động được điều khiển bởi thuật toán phân phối biên đơn biến Boltzmann. Việc phân loại dữ liệu được thực hiện bằng cách sử dụng máy vector hỗ trợ [70].
- Nhóm sử dụng phương pháp học sâu: trong những năm gần đây học sâu đã và đang là một trong những công cụ hữu ích cho việc phát hiện nơi mạch vành bị hẹp, cụ thể là tác giả Karol Antczak và cộng sự [71] đã xây dựng mô hình mạng neural tích chập để xác định vị trí mạch vành bị hẹp trực tiếp từ ảnh mạch vành thông qua hai giai đoạn; giai đoạn đầu tác giả cắt hình cây mạch vành thành các hình nhỏ, mỗi hình nhỏ chứa một đoạn mạch vành; giai đoạn hai sẽ áp dụng mô hình CNN đã được huấn luyên dựa trên dữ liệu được tăng cường

để xác định vị trí hẹp trên mạch vành nếu có. Tác giả Chao Cong [72] sử dụng ba mô hình cho ba giai đoạn: giai đoạn một chọn góc xem với mô hình Inception V3; giai đoạn kế tiếp tác giả chọn lựa các ứng viên có thể là mạch vành bị hẹp bằng InceptionV3 kết hợp LSTM; giai đoạn cuối cùng các ứng viên này được phân loại bằng mô hình kép InceptionV3 với ImageNet. Từ ảnh ban đầu chụp X-Quang mạch vành ban đầu sẽ được dùng để tạo các ảnh nhỏ là từng phần của mạch vành (các đoạn mạch vành). Nhóm tác giả Emmanuel Ovalle-Magallanes [73] đã xây dựng mô hình học chuyển giao với các mô hình thành phần gồm: VGG16, ResNet50, và InceptionV3 để xác định vị trí hẹp trên mạch vành nếu có. Mô hình học chuyển giao kết hợp thêm các kỹ thuật network-cut và fine-tuning để tăng hiệu quả qua quá trình tối ưu dựa trên 20 cấu hình khác nhau của mô hình. Ba mô hình được dùng trong học chuyển giao đã được fine-tune dựa trên ba chiến lược: chỉ dùng dữ liệu thật, chỉ dùng dữ liệu nhân tạo, và dữ liệu nhân tạo kết hợp dữ liệu thật. Nhóm tác giả Wei Wu [74] và cộng sự đề xuất một phương pháp dựa trên CNN với một ràng buộc mới về thời gian trên các chuỗi chụp X-quang mạch. Cụ thể, tác giả phát triển một bộ phát hiện ứng viên dựa trên Unet. Từ các ứng viên tác giả đề xuất một mô-đun seq-fps tùy chỉnh khai thác tính nhất quán theo thời gian của các khung hình liên tiếp để giảm số lượng kết quả dương tính giả. Các thí nghiệm được tiến hành với dữ liệu có 148 chuỗi chụp X-quang mạch vành. Cùng với ý tưởng dùng Unet thì Chen Zhao [75] đã cải tiến hàm lỗi dựa trên hệ số Dice thông qua chuẩn L2 để phân đoạn mạch vành, rồi tìm khung xương của mạch vành đã được phân đoạn để tính bán kính, khoảng cách bán kính này sẽ là thông số xác định vị trí hẹp của mạch vành. Tác giả Jong Hak Moon và cộng sự [76] nhận biết vị trí mạch vành bị hẹp với dữ liệu đầu vào là video trên cơ sở phát hiện các keyframe nhất quán để phát hiện mạch vành hẹp hay không. Quá trình trích keyframe nhất quán dựa tăng cường độ tương phản rồi dùng bộ lọc Frangi kết hợp ngưỡng Otsu. Kết quả này sẽ được mô hình CNN phân loại những đoạn mạch là ứng viên có khả năng bị tắc để phân loại chính xác. Với tác giả

Ovalle-Magallanes E. và cộng sự [77] sự xây dựng mô hình với ba khối Attention kết hợp, mỗi khối là một loại Attention khác nhau, để phát hiện nơi mạch vành bị hẹp, mà dữ liệu đầu vào là các đoạn mạch vành. Đồng thời tác giả Ovalle-Magallanes E. [78] cũng đề xuất một mô hình tạo sinh mới dựa trên Bezier phân cấp (Hierarchical Bezier-based Generative Model - HBGM) mới để cải thiện quy trình huấn luyện CNN nhằm phát hiện chứng hẹp động mạch vành, các đơn vị Attention khối chập cũng được thêm vào trong kiến trúc (Convolutional Block Attention Module - CBAM). Ở đây, các bản vá hình ảnh nhân tạo được tạo ra để mở rộng cơ sở dữ liệu gốc, tăng tốc độ hội tụ mạng. Tác giả A.H. Nandhu Kishore [79] và cộng sự xây dựng phương pháp dựa trên hình thái học và phân ngưỡng để phân loại mạch vành có hẹp hay không trên dữ liệu riêng có 25 ảnh chụp mạch vành. Kun Pang [80] đề xuất mô hình Stenosis-DetNet dựa trên mạng phát hiện đối tượng. Mô-đun tổng hợp tính năng trình tự và mô-đun căn chỉnh tính nhất quán trình tự được thiết kế để tối đa hóa thông tin theo thời gian nhằm đạt được kết quả phát hiện mạch vành hẹp chính xác. Mô-đun tổng hợp tính năng trình tự hợp nhất tất cả các tính năng của ứng cử viên và sử dụng thông tin tạm thời để nâng cao các tính năng này. Mô-đun canh chỉnh nhất quán trình tự tối ưu hóa các kết quả ban đầu bằng cách sử dụng thông tin dịch chuyển động mạch vành và các đặc điểm ảnh của các ảnh liền kề sẽ dẫn đến phát hiện cuối cùng về tình trạng hẹp động mạch vành. Algarni [81] xây dựng mô hình phân đoạn và chẩn đoán bệnh động mạch vành tự động. Đầu tiên xử lý trước các ảnh đầu vào bằng bộ lọc Wiener đã được sửa đổi để loại bỏ cả các pixel nhiễu bên trong và bên ngoài khỏi ảnh. Sau đó, tăng cường độ tương phản bằng cách sử dụng độ cong chính tối đa được tối ưu hóa để bảo toàn thông tin cạnh, từ đó góp phần tăng độ chính xác của phân đoạn. Hơn nữa, khi nhị phân hóa các ảnh được thực hiện bằng phương pháp ngưỡng Otsu. Sau đó bài toán phân đoạn mạch vành được thực hiện bằng cách triển khai Unet lồng nhau dựa trên cơ chế Attention, có chế này khắc phục những khó khăn khi có giao của các mạch ở tình huống chồng chéo gây ra. Độ

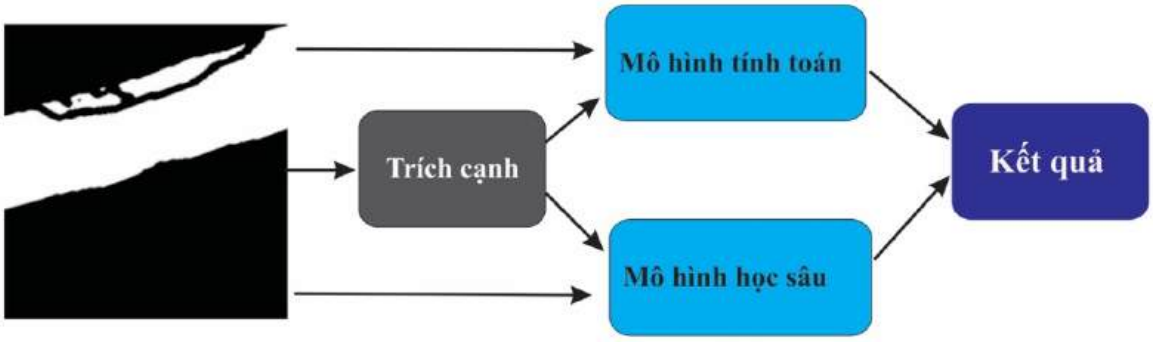
chính xác phân đoạn tăng lên bằng cách thực hiện ước tính góc. Cuối cùng, kiến trúc dựa trên VGG-16 được triển khai để trích xuất ba đặc điểm từ hình ảnh được phân đoạn nhằm thực hiện phân loại hình ảnh phân đoạn thành các lớp bình thường hay bất thường. K. Kavipriya [82] đề xuất một khung tính toán để phân đoạn mạch vành và xác định vị trí hẹp trong mạch vành. Từ các phương pháp tính toán thống nhất của Jerman, tập đồng mức, tinh chỉnh cấu trúc mạch vành được phát triển để trích xuất các đặc điểm của mạch vành để phân đoạn và phát hiện tình trạng hẹp của mạch vành. Wahab Sait [83] sử dụng CNN mà cụ thể là YOLO V7 để trích xuất đặc trưng. Rồi tối ưu hóa các siêu tham số của mô hình Unet++ bằng Aquila để dự đoán bệnh mạch vành. Michał Jungiewicz [84] sử dụng Vision Transformer là một trong những biến thể của CNN cho phép học được nhiều thông tin hơn để phát hiện hẹp của động mạch vành.

4.2 Đề xuất mô hình tổng quát

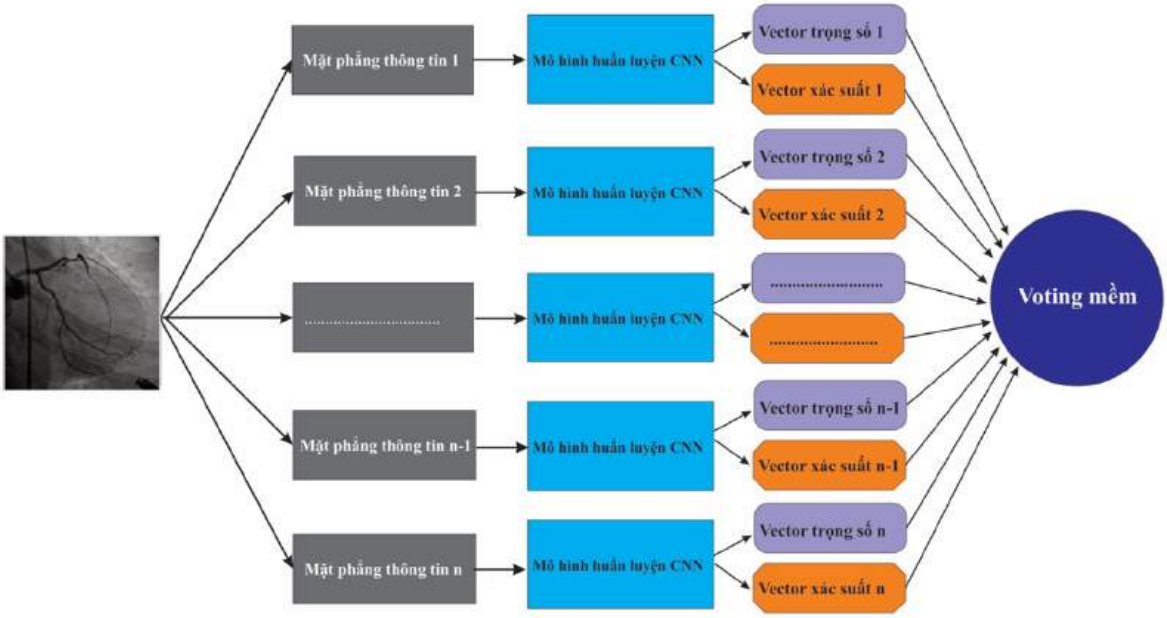
Do ảnh chụp mạch vành rất phức tạp nên luận án chọn hướng tiếp cận dùng dữ liệu ảnh là đoạn mạch vành. Đoạn mạch này có được từ quá trình phân đoạn mạch vành, có hai loại dữ liệu được sử dụng: (1) đoạn mạch vành đã được phân đoạn và (2) đoạn mạch vành chưa phân đoạn (vẫn là ảnh màu và là màu xám) để phát hiện điểm bất thường (mạch hẹp hay phình) trên mạch vành. Luận án thực hiện xây dựng hai hướng giải quyết chính để phát hiện và xác định bất thường trên ảnh mạch vành:

- Hướng giải quyết thứ nhất: gồm hai hướng tiếp cận xây dựng thuật toán với kiến thức xử lý ảnh và hướng tiếp cận máy học, mà cụ thể là học sâu, hình 4.1, với dữ liệu đầu vào là các đoạn mạch đã được phân đoạn.
- Hướng giải quyết thứ hai: do các tính chất trên ảnh được tạo thành từ các thông tin của các mặt phẳng ảnh tổng hợp lại. Đây là thông tin hữu ích để có thể xem xét tính chất bất thường trên mạch vành hay không. Dựa vào ý tưởng này, luận án dùng các thông tin của các mặt phẳng thông tin (mặt phẳng màu, mặt phẳng bit) để huấn luyện mô hình học sâu nhằm phát hiện bất thường trên mạch vành

(nếu có) làm hướng giải quyết thứ hai. Để đảm bảo thông tin của dữ liệu, luận án sử dụng đoạn ảnh mạch vành chưa phân đoạn (ban đầu) để lấy thông tin mặt phẳng ảnh, hình 4.2.



Hình 4.1 Mô hình hướng giải quyết thứ nhất cho phát hiện bất thường trên mạch vành.



Hình 4.2 Mô hình hướng giải quyết thứ hai cho phát hiện bất thường trên mạch vành.

Do mạch vành sau khi phân đoạn sẽ có có mật độ các điểm ảnh màu đen sẽ rất nhiều (sẽ gây bất lợi về mất cân bằng) nên luận án đề xuất trước khi xử lý theo theo hướng giải quyết thứ nhất thì luận án sẽ dùng thêm phương pháp tiền xử lý trích cạnh. Để

trích biên của đoạn mạch vành, luận án cũng dùng hai hướng tiếp cận: thuật toán trích cạnh thông thường Canny và hướng tiếp cận học sâu để có đánh giá tổng quát kết quả phân loại bất thường của đoạn mạch vành.

4.3 Hướng tiếp cận chưa tiền xử lý ảnh

4.3.1 Xây dựng thuật toán dựa trên kiến thức xử lý ảnh

Các ảnh mạch vành được chụp từ nhiều tư thế, cũng như vị trí khác nhau, điều này dẫn đến việc xây dựng thuật toán sẽ phức tạp, do đó luận án sẽ chuẩn hóa vị trí đoạn ảnh mạch vành bằng cách đưa ảnh đoạn mạch vành có thành mạch nằm ngang (gần song song với trục hoành), hình 4.4 Từ ảnh đoạn mạch vành nằm ngang, luận án xây dựng thuật toán duyệt theo hai thành mạch (hai biên – trên và dưới) để xác định các vị trí ứng viên có thể bất thường: phình, hay hẹp, hình 4.3, để có kết quả như hình 4.5. Phương pháp này được đặt tên là "phương pháp duyệt thành mạch vành", mô hình 4.1.



Hình 4.3 Sơ đồ khối của thuật toán đề xuất.

Mô hình 4.1

Bước 1: Xác định thông số chuẩn hoá vị trí thành mạch vành và xoay ảnh mạch vành (thuật toán 4.1)

Bước 2: Xác định ứng viên bất thường (thuật toán .)

Bước 3: Xác định vùng bất thường (thuật toán 4.3)

Thuật toán 4.1 Thuật toán tìm góc xoay và xoay ảnh

Input: Ảnh cần chuẩn hóa theo vị trí, I

Output: ảnh được chuẩn hóa, I_R

Bước 1: Xác định 04 góc của mạch máu: trái-trên, trái-dưới, phải-trên, phải-dưới.

- Duyệt từ trên xuống và từ trái sang phải của ảnh I, xác định được vị trí đầu tiên có giá trị điểm ảnh là màu trắng. Đó là vị trí trái-trên (LU).
- Duyệt từ trên xuống và từ phải sang trái của ảnh I, xác định được vị trí đầu tiên có giá trị điểm ảnh là màu trắng. Đó là vị trí phải-trên (RU).
- Duyệt từ dưới lên và từ trái sang phải của ảnh I, xác định được vị trí đầu tiên có giá trị điểm ảnh là màu trắng. Đó là vị trí trái-dưới (LD).
- Duyệt từ dưới lên và từ phải sang trái của ảnh I, xác định được vị trí đầu tiên có giá trị điểm ảnh là màu trắng. Đó là vị trí phải-dưới (RD).

Bước 2: Xác định hai điểm giữa (p1 và p2) của từng cặp bắt đầu và kết thúc của mạch. Tọa độ hai điểm p1 và p2 là (x1, y1) và (x2, y2) thì p3(x2, y1) hình 4.4 (a)

$$p1.x = LU.x$$
$$p1.y = (LU.y + LD.y)/2$$
$$p2.x = RU.x$$
$$p2.y = (RU.y + RD.y)/2$$
$$p3.x = RU.x$$
$$p3.y = RU.y$$

Bước 3: Tính góc α giữa 02 vector $\overrightarrow{p1p2}$ và $\overrightarrow{p1p3}$.

$$\alpha = \arccos(\cos(\alpha))$$

$$\cos(\alpha) = \frac{\overrightarrow{p1p2}.\overrightarrow{p1p3}}{|\overrightarrow{p1p2}|.|\overrightarrow{p1p3}|}$$

với điều kiện $\alpha < 90^0$

Bước 4: Xác định hướng xoay:

nếu p2.y > p3.y thì xoay theo chiều kim đồng hồ (direction = 0),

else quay ngược chiều kim đồng hồ (direction =1).

Bước 5: Xoay ảnh I_R theo góc α với direction tương ứng, hình 4.4 (b)

Bước 6: Trả ảnh kết quả sau xoay I_R.

Thuật toán 4.2 Thuật toán xác định ứng viên bất thường

Input: Ảnh đã được chuẩn hóa vị trí I_R

Output: vùng ứng viên $UP_{candidate}$ và $LO_{candidate}$ (nếu có)

Bước 1: Xác định đường cơ sở của mạch máu (đường cơ sở là đường nối 02 điểm giữa 2 đầu mạch, hình 4.4 (b).

baseline.left = p1;
baseline.right = p2;

Bước 2: Tìm d_r, d_l (hình 4.4 (b)) là khoảng cách từ đường cơ sở đến 02 biên mạch máu (biên trên và biên dưới). Xác định $d_{max} = \max(d_r, d_l)$.

Bước 3: Duyệt biên trên I_R.upper của mạch máu từ trái sang phải tìm ứng viên bất thường.

Mỗi điểm ảnh p thuộc I_R.upper:

Bước 3.1 Tính khoảng cách d từ điểm xem xét p đến đường cơ sở.

Bước 3.2 Nếu $|d - d_{max}| > T_{candidate}$ (Với $T_{candidate}$ là giá trị ngưỡng), thêm p vào một mảng tạm thời. Ngược

lại, nếu kích thước của mảng tạm thời lớn hơn một ngưỡng, thì thêm mảng tạm thời vào mảng chứa ứng cử viên bất thường trên $UP_{candidate}$.add(p).

Bước 4: Tìm ứng viên bất thường cho biên dưới $LO_{candidate}$ giống ở bước 3.

Bước 5: Trả ra 02 mảng $UP_{candidate}$ và $LO_{candidate}$ chứa các ứng viên bất thường cho biên trên và biên dưới.

Thuật toán 4.3 Thuật toán tìm điểm bất thường.

Input: mảng dữ liệu từ thuật toán 4.2, $UP_{candidate}$ và $LO_{candidate}$.

Output: vị trí bất thường.

Bước 1: Xác định điểm ứng viên (vị trí hẹp nhất của mỗi ứng viên vùng hẹp và vị trí rộng nhất của mỗi ứng viên vùng phình mạch) và lưu chúng vào mảng điểm.

Bước 2: Sắp xếp các điểm theo thứ tự tăng dần dựa trên việc so sánh khoảng cách từ các điểm đó đến đường cơ sở, được lưu trữ trong mảng SortedPoints. Sử dụng mảng indexList để lưu chỉ mục cũ của các phần tử trong mảng điểm. (Trong đó, indexList [i] là chỉ số của SortedPoint [i] trong mảng điểm).

Bước 3: Lặp lại từng điểm p trong mảng đã sắp xếp. Gọi d_p là khoảng cách giữa p và đường cơ sở.

Bước 3.1. Tính khoảng cách từ đường cơ sở đến điểm tương ứng ở biên bên kia của mạch máu (d_0). Tính tỷ lệ $R = d_p / d_0$.

Bước 3.2. Nếu $R \leq$ threshold 1 hoặc R> threshold 2. Thực hiện như sau:

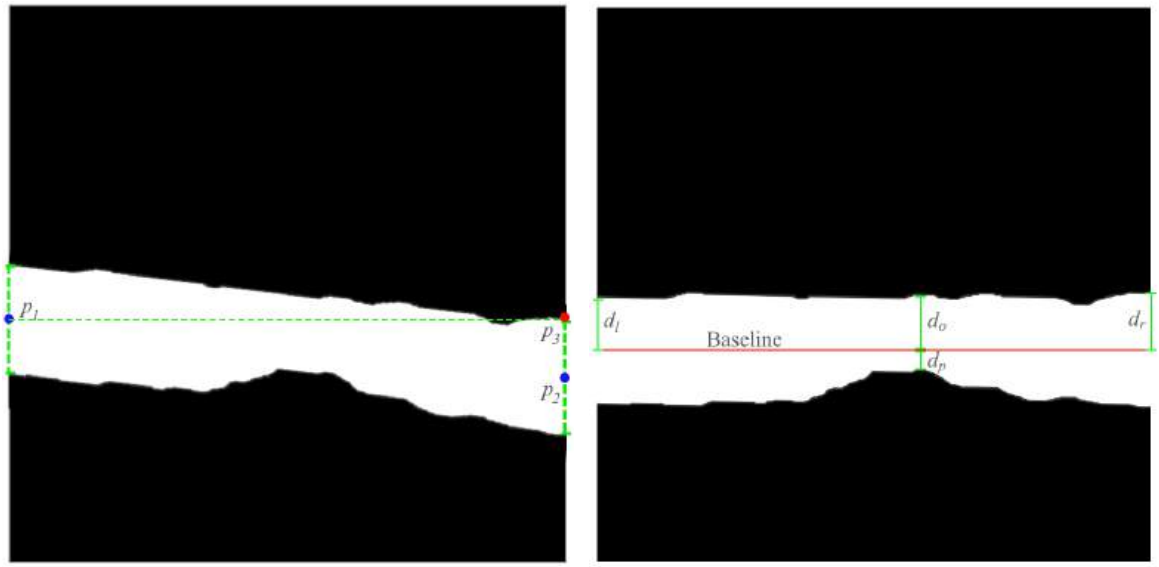
Bước 3.2.1. Tính: n_l, n_r là khoảng cách từ đường cơ sở đến hai lân cận của điểm p ở mảng không được sắp xếp dựa trên mảng indexList.

Bước 3.2.2. Tính: $R_l = d_p/n_l$ và $R_r = d_p/n_r$.

Nếu R_l hoặc R_r lớn hơn $T_{aneurysym}$ (ngưỡng cho một ứng viên phình động mạch) thì p là bất thường. Nếu R_l hoặc R_r nhỏ hơn $T_{stenosis}$ (ngưỡng cho một ứng viên hẹp) thì p là bất thường. Vùng chứa p là vùng bất thường.

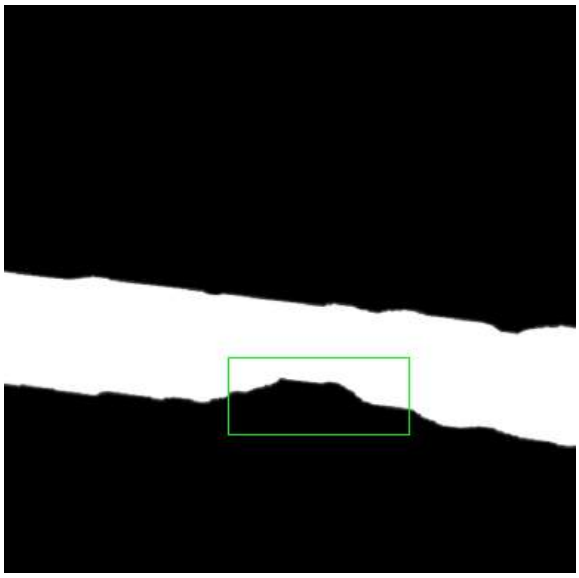
Bước 4: Đánh dấu vùng bất thường trên ảnh đã được xoay I_R.

Bước 5: Đánh dấu vùng bất thường trên ảnh ban đầu và trả ảnh ra I.



(a) (b)

Hình 4.4 Chuẩn hóa vị trí mạch vành: (a) ảnh ban đầu; (b) sau khi chuẩn hóa.



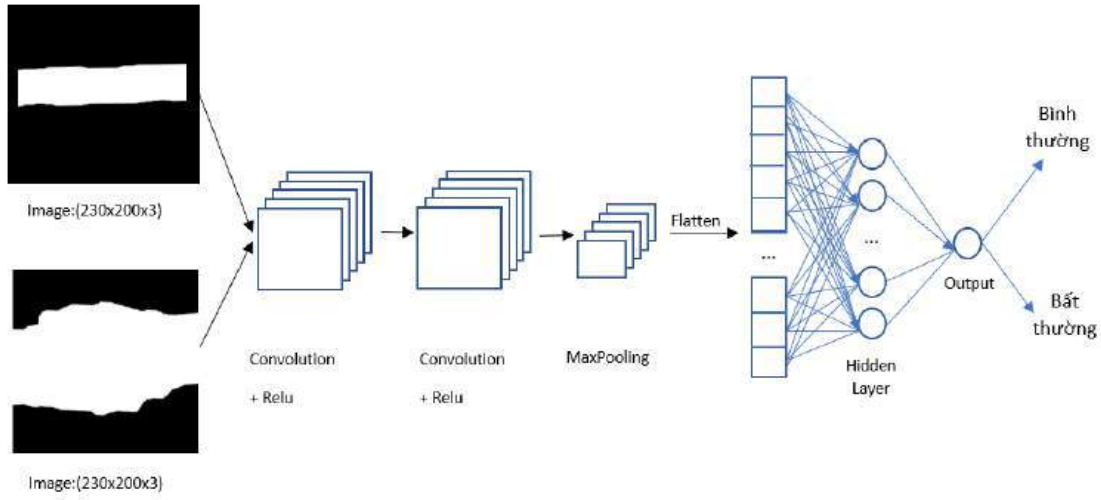
Hình 4.5 Kết quả xác định bất thường.

4.3.2 Học sâu

Nhiều nghiên cứu đã đề xuất sử dụng mô hình CNN để phát hiện hẹp mạch máu trên các bộ dữ liệu khác nhau trong những năm gần đây. Ưu điểm chính của CNN là khả năng tự động tìm hiểu các đặc tính dữ liệu từ cấp thấp đến cấp cao. Nhờ đó, mô hình có thể phát hiện các điểm cực trị trên các đoạn mạch vành, đây chính là các vị trí bất thường để giải quyết bài toán phát hiện điểm bất thường trên đoạn mạch vành. Phần trích xuất đặc trưng có nhiều lớp convolutions và pooling, các lớp này chịu trách nhiệm trích xuất tự động các đặc điểm từ mức thấp đến mức cao của dữ liệu. Lớp tích chập áp dụng thao tác tích chập để tính tích giá trị giữa các ma trận (còn gọi là bộ lọc) để thu thập các đặc trưng cần thiết. Giá trị của bộ lọc là trọng số của lớp tích chập. Bộ lọc là các ma trận trượt trên toàn bộ ảnh đoạn mạch vành, điều này làm giảm số lượng tham số trong CNN. Kết quả của phép tích chập được truyền qua hàm kích hoạt đơn vị tuyến tính được chỉnh lưu (ReLU) để làm cho mô hình trở nên phi tuyến tính. Lý do luận án sử dụng ReLU cho mô hình CNN chính là có thể tránh được vấn đề biến mất độ dốc. Sau đó, đầu ra của lớp chập (còn gọi là bản đồ đặc trưng) được chuyển qua lớp gộp. Mô hình CNN trong luận án nhiều lớp chập liên tiếp mà không sử dụng lớp gộp. Lớp gộp được tính bằng cách lấy giá trị trung bình của các giá trị trong cửa sổ có kích thước cố định được trượt trên toàn bộ bản đồ.

4.3.2.1 Mô hình tổng quát

Mô hình tổng quát được xây dựng như hình 4.6, để phân loại nhị phân gồm 02 lớp đầu ra: đoạn mạch bình thường hay đoạn mạch bất thường. Luận án sử dụng hàm lỗi MSE để đánh giá hoạt động của mô hình mà không sử dụng các hàm lỗi nhị phân khác vì quá trình đánh giá một vị trí có bất thường hay không sẽ phải dựa vào thông tin xung quanh của vị trí đó mà không có ngay được thông tin cần thiết, và những thông tin này còn bị nhiễu. Trong quá trình lan truyền ngược, luận án sử dụng thuật toán Adam [29] để cập nhật các trọng số, Adam là thuật toán kết hợp giữa RMSprop và AdaGrad cho tối ưu quá trình học.



Hình 4.6 Mô hình tổng quát với phương pháp học sâu của luận án.

4.3.2.2 Huấn luyện mô hình

Để tránh tình trạng dữ liệu tập trung về màu đen hay màu trắng, cũng như sau miền dữ liệu bị thu hẹp, luận án chuẩn hóa miền giá trị của tập dữ liệu ảnh. Sau khi dữ liệu được chuẩn hóa miền giá trị, luận án huấn luyện mô hình theo thuật toán 4.4.

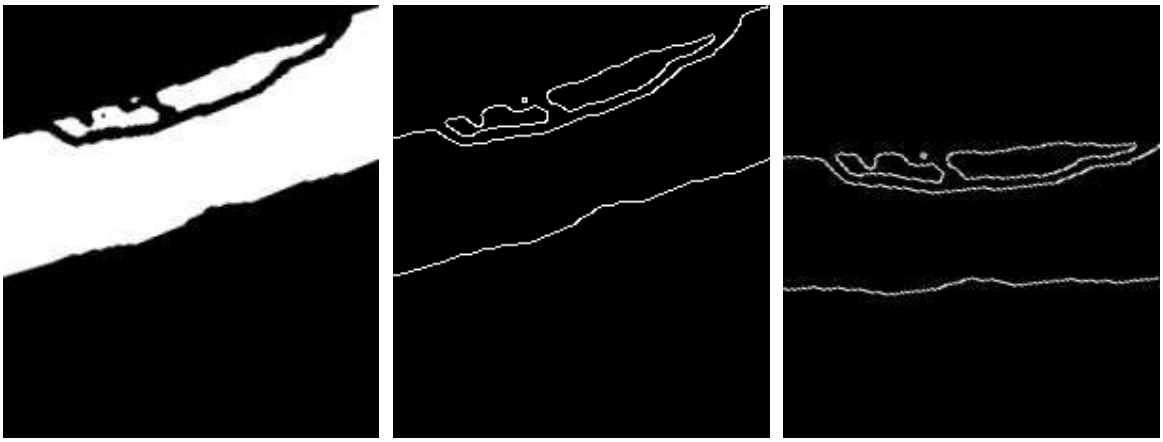
Thuật toán 4.4 Thuật toán huấn luyện
Input: Tập ảnh mạch vành bình thường B1 và tập ảnh mạch vành bất thường B2 *Ouput:* Mô hình CNN

Thiết lập ngẫu nhiên tham số cho mô hình
data = B1 ∪ B2
count = 1;
for i = 1 to |data| do
    while (error >= epsilon && count <max_ iteration)
        res = NET.train($data_i$);
        error = $|res - ground_i|$;
    count++;
    endwhile
endfor
end

4.4 Hướng tiếp cận tiền xử lý trích cạnh

4.4.1 Tiền xử lý trích cạnh

Kết quả sau khi phân đoạn động mạch vành là ảnh nhị phân các đoạn mạch vành, biên có thể bị đứt đoạn hay nhiễu; vì bị ảnh hưởng bởi nhiều yếu tố. Nhiều trường hợp có nhiễu bên trong, bên ngoài hoặc ở rìa của biên. Vì vậy, luận án trích xuất các cạnh trên và dưới của biên động mạch vành làm đầu vào để xử lý, hình 4.7, và chuẩn hóa vị trí (hình 4.7 (c)) sẽ là dữ liệu đầu vào để áp dụng phương pháp phát hiện bất thường theo hướng thuật toán dựa trên kiến thức xử lý ảnh và hướng học sâu.



(a) (b) (c)

Hình 4.7 Tiền xử lý: (a) ảnh ban đầu; (b) trích cạnh; (c) kết quả.

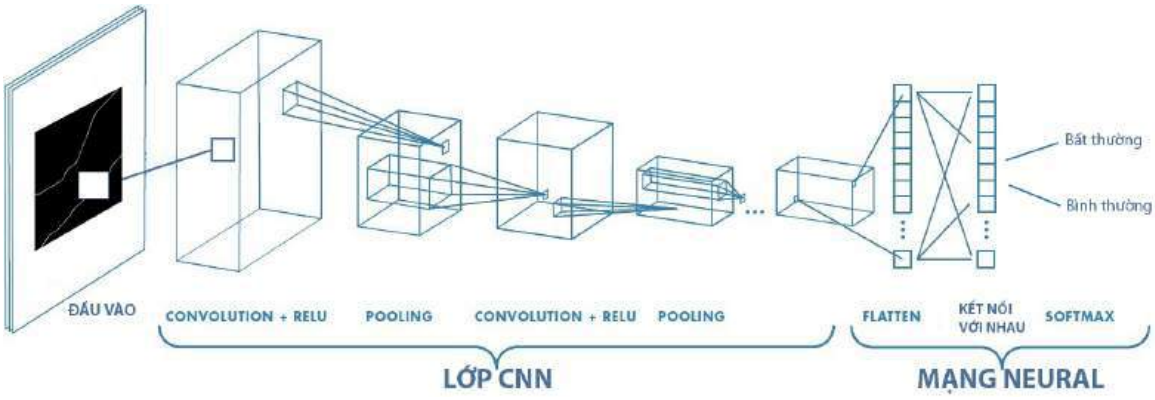
Luận án sử dụng hai phương pháp trích cạnh: phương pháp cổ điển và học sâu để trích cạnh tương ứng nhằm đánh giá thêm phương pháp trích cạnh nào sẽ tốt hơn khi dùng dữ liệu sau khi trích cạnh để xác định bất thường. Phương pháp Canny là phương pháp cổ điển cho kết quả dựa trên xem xét mức độ thay đổi độ sáng của vùng biên [85]. Phương pháp thứ hai được dùng để trích cạnh là mạng Dense Extreme Inception (Dense Extreme Inception Network - DexiNed), DexiNed là một trong những mạng học sâu được huấn luyện trên tập dữ liệu phong phú cho phép trích cạnh của bất kỳ đối tượng kể cả các ảnh dữ liệu y khoa [86]. Dữ liệu sau khi trích cạnh thì sẽ có nhiều vị trí trên biên sẽ bị mất dữ liệu (đứt đoạn), luận án dùng thuật toán hình thái [87] xử lý để biên liên tục.

4.4.2 Phát hiện bất thường với thuật toán duyệt cạnh

Luận án dùng phương pháp duyệt thành mạch máu, thuật toán 4.3, để xác định vị trí bất thường trên đoạn mạch vành với dữ liệu là đoạn mạch vành được phân đoạn và trích cạnh. Quá trình xử lý cũng tương tự như dữ liệu chưa trích cạnh.

4.4.3 Mô hình học sâu

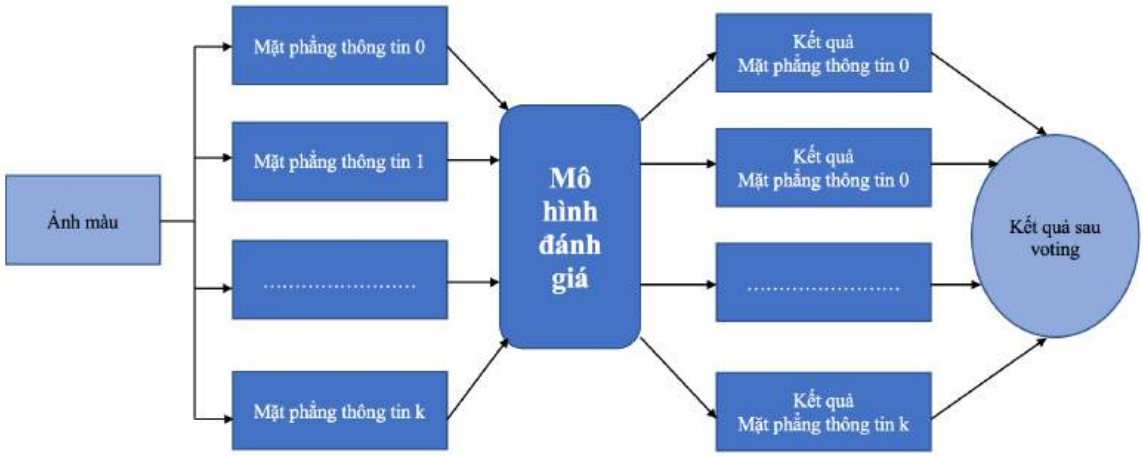
Luận án đã xây dựng mô hình CNN, hình 4.8, để huấn luyện và phân loại ảnh là bình thường hay bất thường. Đây là 2D-CNN, mô hình có 03 lớp dựa trên kích thước của hình ảnh, đã được thiết kế lại cho phù hợp kích thước và tính chất của đoạn mạch vành, hình 4.8. Mô hình sử dụng hàm lỗi MSE và tối ưu với thuật toán Adam.



Hình 4.8 Mô hình học sâu với dữ liệu đầu vào là ảnh đoạn mạch vành được trích cạnh.

4.5 Hướng tiếp cận mặt phẳng thông tin

Ảnh màu được cấu tạo từ: (1) các mặt phẳng bit [87]; (2) ba lớp màu RGB [87]. Mỗi mặt phẳng sẽ mang những thông tin khác nhau, khi tổng hợp các mặt phẳng thông tin này sẽ có được toàn bộ thông tin của ảnh, đối tượng, …. Dựa trên đặc tính này, luận án đề xuất mô hình đánh giá mặt phẳng thông tin để chọn mặt phẳng phù hợp cho bài toán, hình 4.9. Từ các mặt thông tin được chọn lựa, luận án xây dựng mô hình phân loại ảnh đoạn mạch vành nào có thể có bất thường thông qua phương pháp voting mềm [88]. Phương pháp voting mềm cho giải pháp (kết quả) tốt nhất thông qua việc tính trung bình có trọng số của các thành phần. Với tập hợp các mặt phẳng thông tin, mỗi mặt phẳng thông tin sẽ có những đặc tính khác nhau nên sẽ cho các thông tin khác nhau, dẫn đến sẽ có những kết quả khác nhau khi phân loại. Luận án xem xét hai loại mặt phẳng thông tin: mặt phẳng bit và mặt phẳng màu để phân loại, với loại mặt phẳng bit thì có 08 mặt phẳng thông tin (từ bit 0 đến bit 7) và mặt phẳng màu thì có 03 mặt phẳng màu (đó là RGB: đỏ, xanh lá, xanh dương).



Hình 4.9 Sơ đồ tổng quát mô hình đánh giá các mặt phẳng thông tin.

Luận án tiến hành huấn luyện từng mặt phẳng thông tin của từng loại mặt phẳng để xem xét loại mặt phẳng thông tin nào đóng góp vào hiệu suất phân loại để chọn lựa. Giả sử ảnh đầu vào có thể được phân tách thành n mặt phẳng thông tin. Sau đó, với mỗi loại mặt phẳng thông tin sẽ có một mô hình học sâu để huấn luyện trên tập huấn

luyện; mỗi mô hình sẽ cho một kết quả khác nhau. Luận án sẽ đánh giá và chọn lựa loại mặt phẳng thông tin nào cho đóng góp về mặt phân loại đảm bảo. Các kết quả của từng loại mặt phẳng thông tin sẽ được tổng hợp dựa vào voting mềm để có kết quả sau cùng.

Giả sử chúng ta có m mặt phẳng thông tin, mỗi mặt phẳng thông tin thứ i sẽ có n trọng số khác nhau w_t^i, trong đó $t = 1..n$, cho biết khả năng đóng góp mức độ chính xác của mặt phẳng thông tin này. Có thể viết lại n trọng số này tạo thành một vectơ trọng số W^i, với $W^i[t] = w_t^i$. Mô hình CNN được huấn luyện trên mặt phẳng thông tin thứ i được sử dụng để dự đoán vị trí bất thường (có hay không) trên đoạn mạch vành, trong đó đầu ra của mô hình thứ i là vectơ xác suất B^i với m phần tử, và $\mathrm{B}^i[t] = \beta_t^i$ là xác suất cho phân loại thứ t của đầu ra của mô hình. Kết quả phân loại với voting mềm được thực hiện bằng cách tính theo công thức (4.1)

$$S_t = \sum_i (W^i[t] \cdot \mathrm{B}^i[t]) \tag{4.1}$$

Nhãn của dự đoán cuối cùng là $\arg\max_t(S_t)$. Trọng số $W^i[t]$ được xác định bằng hiệu suất của mô hình thứ i trên loại loại đầu ra thứ t, và được ký hiệu là α_t^i. Khi đó, $W^i[t]$, được tính từ công thức (4.2) và công thức (4.3) qua 2 bước sau:

Bước 1: Tóm tắt hiệu suất mô hình của tất cả n mặt phẳng thông tin đối với loại đầu ra thứ t, công thức (4.2).

$$M_t = \sum_i \alpha_t^i \tag{4.2}$$

Bước 2: Tính tỷ lệ của loại cá thể với M_t, công thức (4.3).

$$W^i[t] = \frac{\alpha_t^i}{M_t} \tag{4.3}$$

Cụ thể với bài toán xác định bất thường nếu có trên ảnh đoạn mạch vành, có đầu ra *t* = 2 (nếu chỉ xét bình thường hay bất thường) hoặc 3 (nếu xét phình, hẹp, bình thường)

- Mặt phẳng bit thì ban đầu $m = 8$. Sau khi đánh giá thì $m \leq 8$.
- Mặt phẳng màu thì ban đầu $m = 3$. Sau khi đánh giá thì $m \leq 3$.

4.6 Thực nghiệm

4.6.1 Môi trường thực nghiệm

Do giới hạn cần dùng GPU và tài nguyên không có sẵn nên luận án đã chọn Google Colab để thực nghiệm và áp dụng phương thức lưu kết quả trước khi hết phiên làm việc và khôi phục kết quả để tiếp tục với phiên làm việc mới được tạo ra. Luận án thực hiện cài đặt bằng ngôn ngữ lập trình Python với phiên bản 3 trên nền tảng của công cụ hỗ trợ lập trình Google Colab trên Google Drive của Google. Các thông số để cài đặt trên Google Colab như hình 4.10.

```
+-----------------------------------------------------------------------------+
| NVIDIA-SMI 465.19.01    Driver Version: 460.32.03    CUDA Version: 11.2     |
|-------------------------------+----------------------+----------------------+
| GPU  Name        Persistence-M| Bus-Id        Disp.A | Volatile Uncorr. ECC |
| Fan  Temp  Perf  Pwr:Usage/Cap|         Memory-Usage | GPU-Util  Compute M. |
|                               |                      |               MIG M. |
|===============================+======================+======================|
|   0  Tesla T4            Off  | 00000000:00:04.0 Off |                    0 |
| N/A   53C    P8    10W /  70W |      0MiB / 15109MiB |      0%      Default |
|                               |                      |                  N/A |
+-------------------------------+----------------------+----------------------+

+-----------------------------------------------------------------------------+
| Processes:                                                                  |
|  GPU   GI   CI        PID   Type   Process name                  GPU Memory |
|        ID   ID                                                   Usage      |
|=============================================================================|
|  No running processes found                                                 |
+-----------------------------------------------------------------------------+
```

Hình 4.10 Thông số kỹ thuật trên Google Colab.

Luận án dùng độ đo Recall, Precision, F1-Score và Accuracy để đánh giá độ chính xác của phương pháp.

4.6.2 Chưa tiền xử lý trích cạnh

Qua thống kê, luận án đã chọn ngưỡng 15 điểm ảnh cho phương pháp duyệt thành mạch máu để xác định các ứng cử viên vùng bất thường. Trong thuật toán phát hiện

bất thường, luận án chọn lần lượt là 1,2 và 0,7 cho $T_{aneurysm}$ (ngưỡng phình) và $T_{stenosis}$ (ngưỡng hẹp) [89].

Luận án đã xây dựng kiến trúc CNN sẽ bao gồm hai lớp tích chập, mỗi lớp sử dụng kích thước nhân 3×3 với 32 bộ lọc và chức năng kích hoạt ReLU. Sau mỗi lớp chập, tất cả các bản đồ đặc trưng được chuẩn hóa về giá trị trung bình bằng 0 và độ lệch chuẩn đơn vị. Sau lần chuẩn hóa thứ hai, các bản đồ đặc trưng được chuyển đến lớp gộp bằng cách sử dụng gộp tối đa với bộ lọc có kích thước 2 × 2. Đầu ra của lớp gộp được chuyển thành vectơ làm đầu vào cho lớp được kết nối đầy đủ. Luận án cũng đã sử dụng hàm kích hoạt sigmoid và droupout 0,2 trong mô hình để tránh tình trạng quá khớp.

4.6.3 Tiền xử lý trích cạnh

Khi huấn luyện cho mô hình để phân loại bất thường hay không với dữ liệu được trích cạnh luận án thay đổi hàm lỗi thành "SparseCategoricalCrossentropy" vì những tính chất của ảnh sau khi trích cạnh. Ảnh đoạn mạch vành chỉ còn thông tin cạnh, những thông tin khác hầu như không còn.

4.6.4 Mặt phẳng thông tin

Bảng 4.1(a) là cấu trúc mạng CNN với mặt phẳng thông tin đầu vào của kênh một màu và bảng 4.1(b) là cấu trúc có mặt phẳng thông tin đầu vào của mặt phẳng bit. Với đầu vào thang độ xám (chẳng hạn như một trong ba kênh màu RGB), mô hình này chứa nhiều thông tin, bao gồm nhiễu và yêu cầu nhiều lớp để nắm bắt các tính năng. Nếu đầu vào là mặt phẳng bit thì mô hình sẽ ít lớp hơn vì chỉ cần đủ để nắm bắt được các tính chất.

Bảng 4.1 Cấu trúc mạng CNN.

(a)				(b)		
Tên lớp	**Kích thước**	**Số lượng**		**Tên lớp**	**Kích thước**	**Số lượng**
Input	$100 \times 100 \times 1$			Đầu vào	$85 \times 85 \times 1$	
Conv1, ReLU	$3 \times 3 \times 1$	32		Conv1, ReLU	$3 \times 3 \times 1$	32
Batchnorm1				Batchnorm1		
Conv2, ReLU	$3 \times 3 \times 32$	64		Conv2, ReLU	$3 \times 3 \times 32$	32
Batchnorm2				Batchnorm2		
Maxpool1	2×2			Maxpool1	2×2	
				Conv3, ReLU	$3 \times 3 \times 32$	64
				Batchnorm3		
				Conv4, ReLU	$3 \times 3 \times 64$	64
				Batchnorm4		
				Maxpool2	2×2	
FC-128, ReLU						
Dropout-0.5						
FC-2, Softmax						

4.7 Kết quả

4.7.1 Kết quả phương pháp duyệt cạnh với dữ liệu chưa trích cạnh

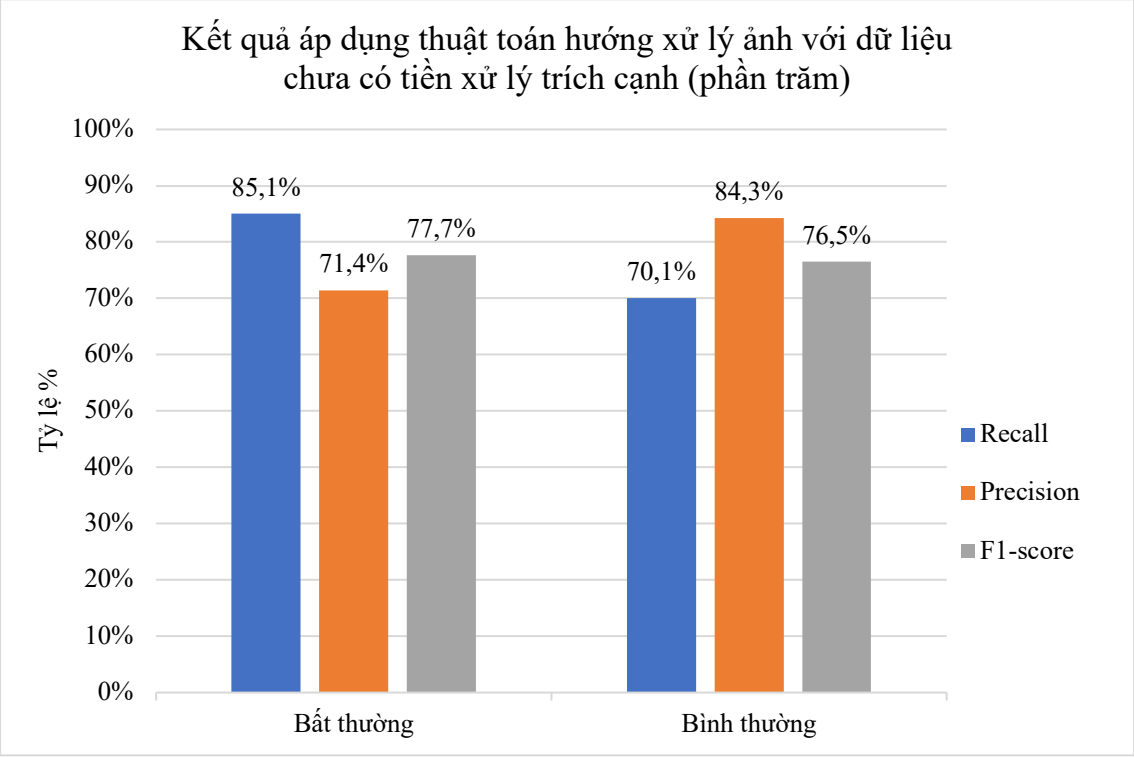
Luận án thực hiện phương pháp duyệt cạnh với dữ liệu chưa trích cạnh thì có kết quả với các giá trị như bảng 4.2 và độ chính xác, bảng 4.3, đồ thị như hình 4.11.

Bảng 4.2 Kết quả các giá trị TP, TN, FP và FN.

	Bất thường	**Bình thường**	**Tổng cộng**
Bất thường	1003 (TP)	401 (FP)	1404
Bình thường	175 (FN)	940 (TN)	1115

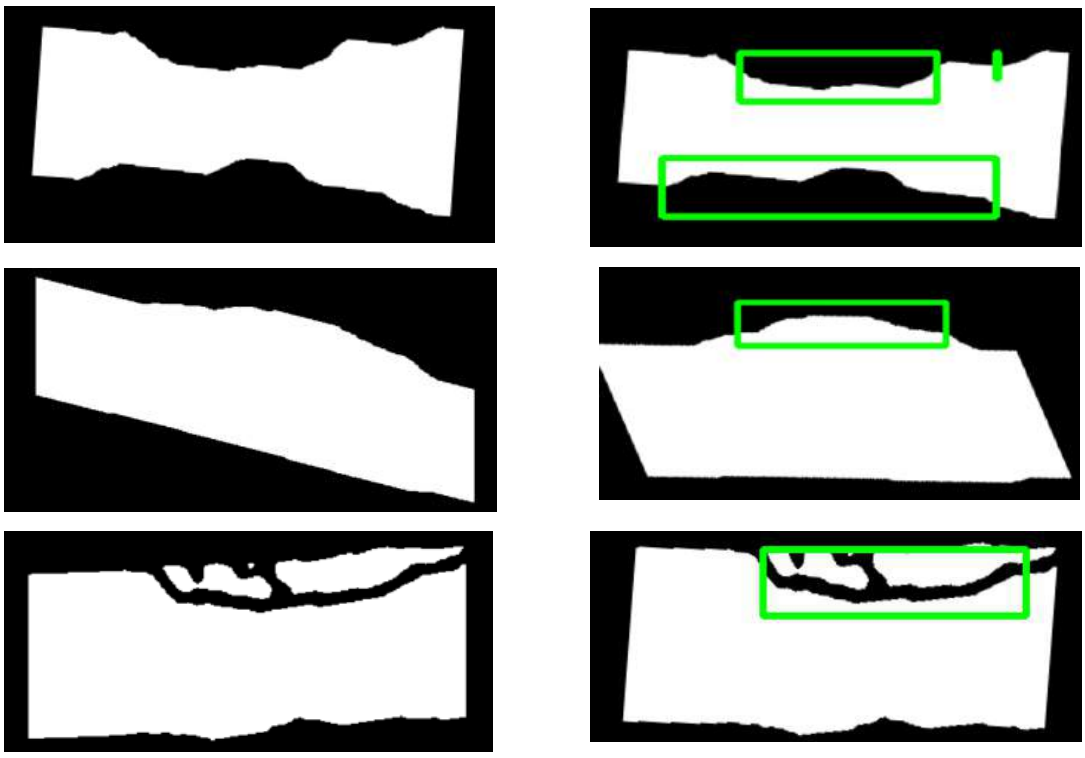
Bảng 4.3 Kết quả các độ đo.

	Recall	**Precision**	**F1-score**
Bất thường	0,851	0,714	0,777
Bình thường	0,701	0,843	0,765



Hình 4.11 Đồ thị kết quả các độ đo.

Ví dụ kết quả phát hiện bằng thuật toán duyệt cạnh, hình 4.12 (phát hiện đúng bất thường), hình 4.13 (a) và (b) (phát hiện thiếu vùng bất thường hoặc không phát hiện được bất thường), hình 4.14 (mạch bình thường phát hiện sai là bất thường).



(a) (b)

Hình 4.12 (a) ảnh bất thường; (b) phát hiện đúng bất thường.



(a) (b)

Hình 4.13 (a) không phát hiện được bất thường; (b) phát hiện thiếu vị trí bất thường.



Hình 4.14 Ảnh bình thường phát hiện sai là bất thường.

4.7.2 Kết quả phương pháp duyệt cạnh với dữ liệu đã trích cạnh

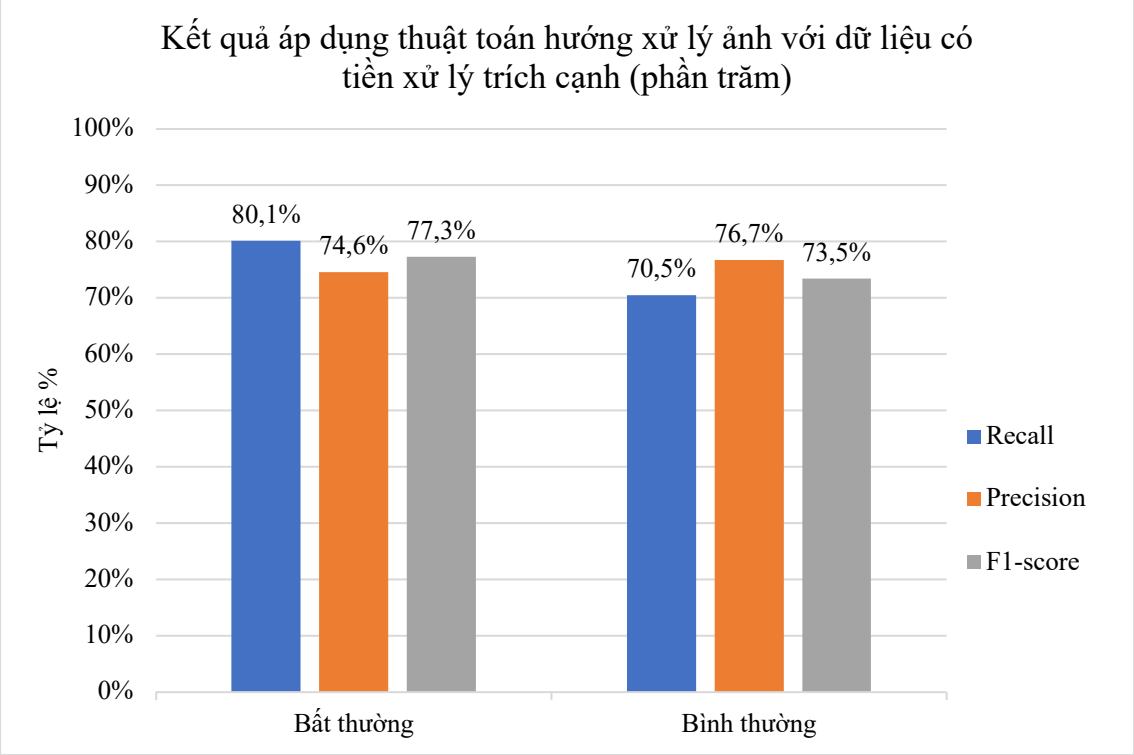
Luận án thực hiện thuật toán duyệt cạnh với dữ liệu đã trích cạnh thì có kết quả bảng 4.4, hình 4.15. Từ 1404 ảnh bất thường, thuật toán duyệt thành mạch phát hiện ra 1047 ảnh đúng và 357 ảnh sai. Trong 1115 ảnh bình thường, thuật toán phân loại đúng 855 ảnh và không đúng 260 ảnh. Thời gian xử lý trung bình là khoảng 0,34 giây cho dữ liệu bất thường và 0,45 giây cho dữ liệu bình thường. Ảnh bất thường được phân loại đúng nhưng thiếu vị trí (hình 4.16) cho thấy thuật toán phát hiện không đủ vị trí bất thường, hoặc ảnh bình thường phân loại bình thường hay sai bất thường (hình 4.17).

Bảng 4.4 Kết quả các giá trị TP, TN, FP và FN.

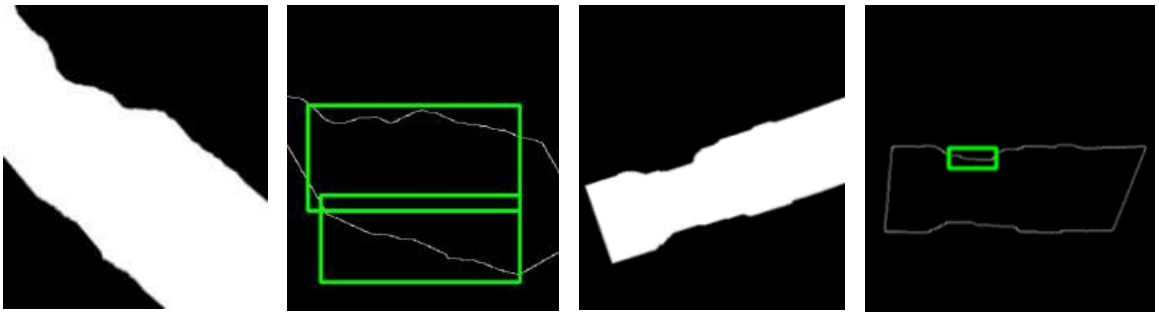
	Ảnh bất thường	**Ảnh bình thường**	**Tổng cộng**
Ảnh bất thường	1047	357	1404
Ảnh bình thường	260	855	1115

Bảng 4.5 Kết quả các độ đo.

	Recall	**Precision**	**F1-score**
Ảnh bất thường	0,801	0,746	0,773
Ảnh bình thường	0,705	0,767	0,735

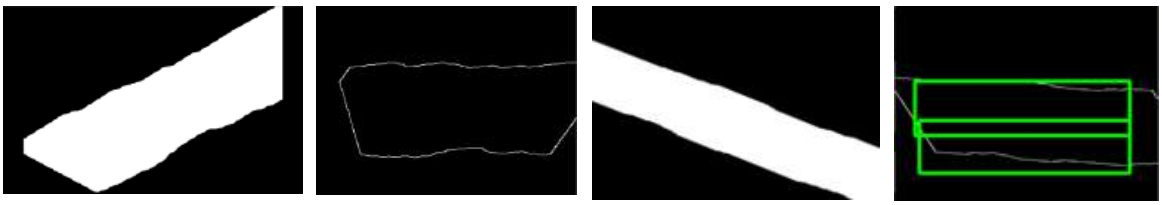


Hình 4.15 Đồ thị kết quả các độ đo.



(a) (b) (c) (d)

Hình 4.16 Ảnh bất thường: (a) đầu vào; (b) kết quả là bất thường; (c) đầu vào; (d) kết quả là bất thường nhưng thiếu vị trí.



(a) (b) (c) (d)

Hình 4.17 Ảnh bình thường: (a) đầu vào; (b) kết quả bình thường; (c) đầu vào (d) kết quả bất thường.

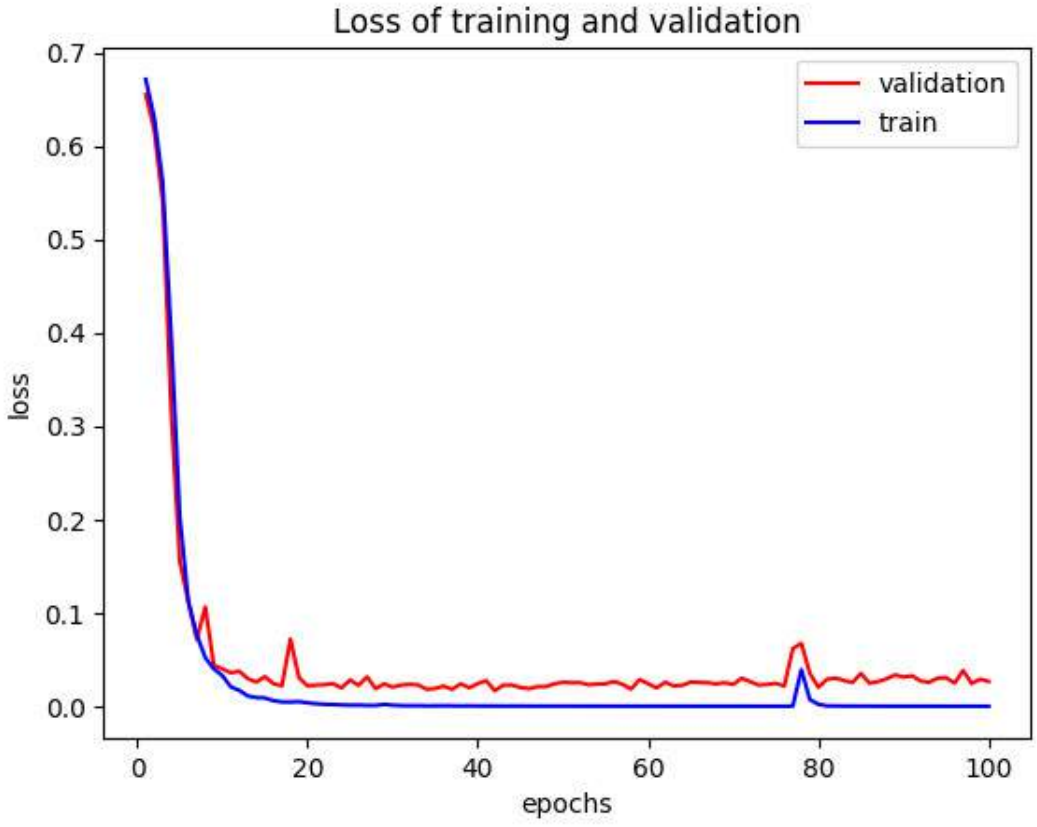
4.7.3 Kết quả phương pháp học sâu với dữ liệu chưa trích cạnh

Luận án chia dữ liệu làm hai phần để huấn luyện và kiểm tra theo tỷ lệ 65% (huấn luyện), 15% (đánh giá), và 20% (kiểm thử) như bảng 4.6.

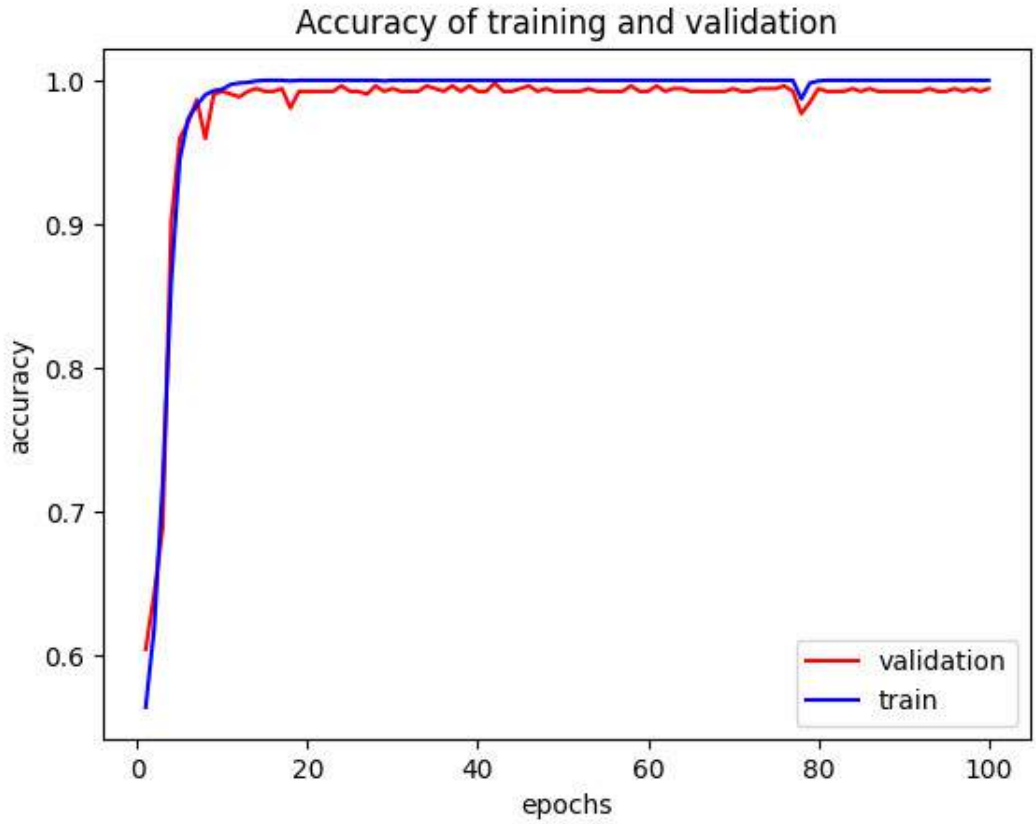
Bảng 4.6 Số lượng dữ liệu dùng cho mô hình.

	Huấn luyện	**Đánh giá**	**Kiểm thử**	**Tổng**
Bất thường	912	211	281	1404
Bình thường	725	167	223	1115

Kết quả huấn luyện như hình 4.18, hình 4.19, và bảng kết quả đánh giá mức độ chính xác, bảng 4.7, bảng 4.8, hình 4.20.



Hình 4.18 Kết quả lỗi của mô hình khi huấn luyện.



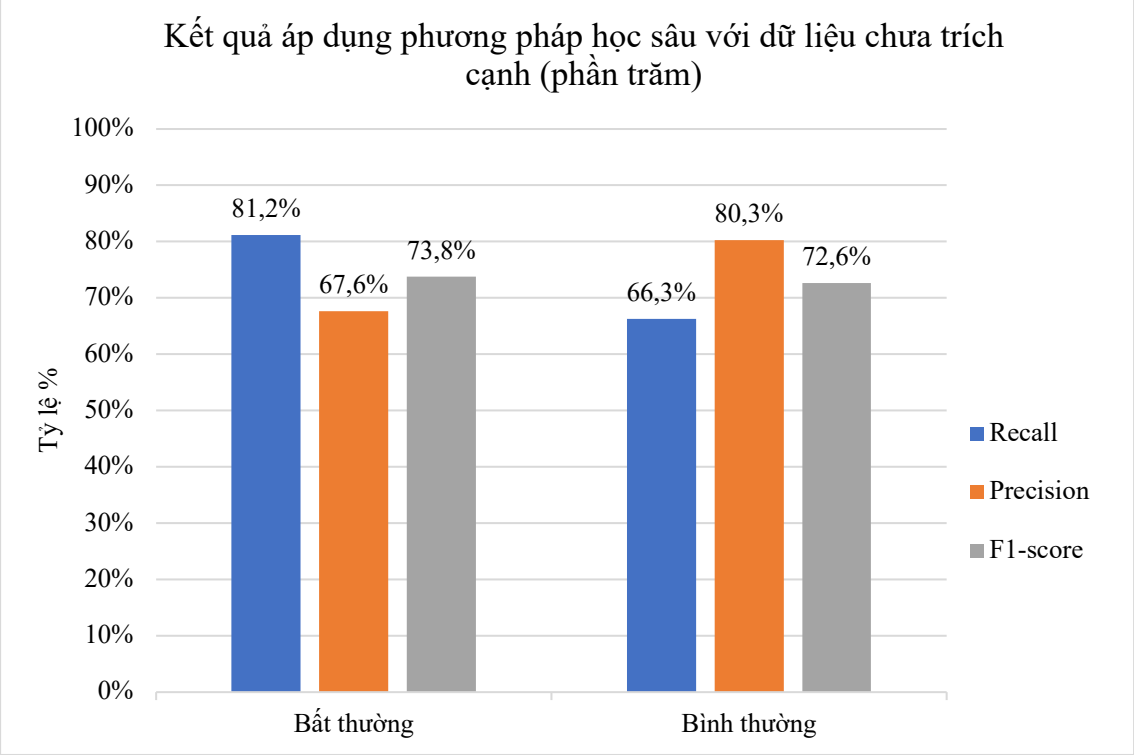
Hình 4.19 Kết quả độ chính xác mô hình khi huấn luyện.

Bảng 4.7 Kết quả các giá trị TP, TN, FP và FN.

	Ảnh bất thường	**Ảnh bình thường**	**Tổng cộng**
Ảnh bất thường	190	91	281
Ảnh bình thường	44	179	223

Bảng 4.8 Kết quả các độ đo.

	Recall	**Precision**	**F1-score**
Ảnh bất thường	0,812	0,676	0,738
Ảnh bình thường	0,663	0,803	0,726



Hình 4.20 Đồ thị kết quả các độ đo

4.7.4 Kết quả phương pháp học sâu với dữ liệu đã trích cạnh với phương pháp Canny

Luận án chia dữ liệu làm hai phần để huấn luyện và kiểm tra theo tỷ lệ 65%, 15%, và 20% như bảng 4.9.

Bảng 4.9 Số lượng dữ liệu dùng cho mô hình.

	Huấn luyện	**Đánh giá**	**Kiểm thử**	**Tổng**
Bất thường	912	211	281	1404
Bình thường	725	167	223	1115

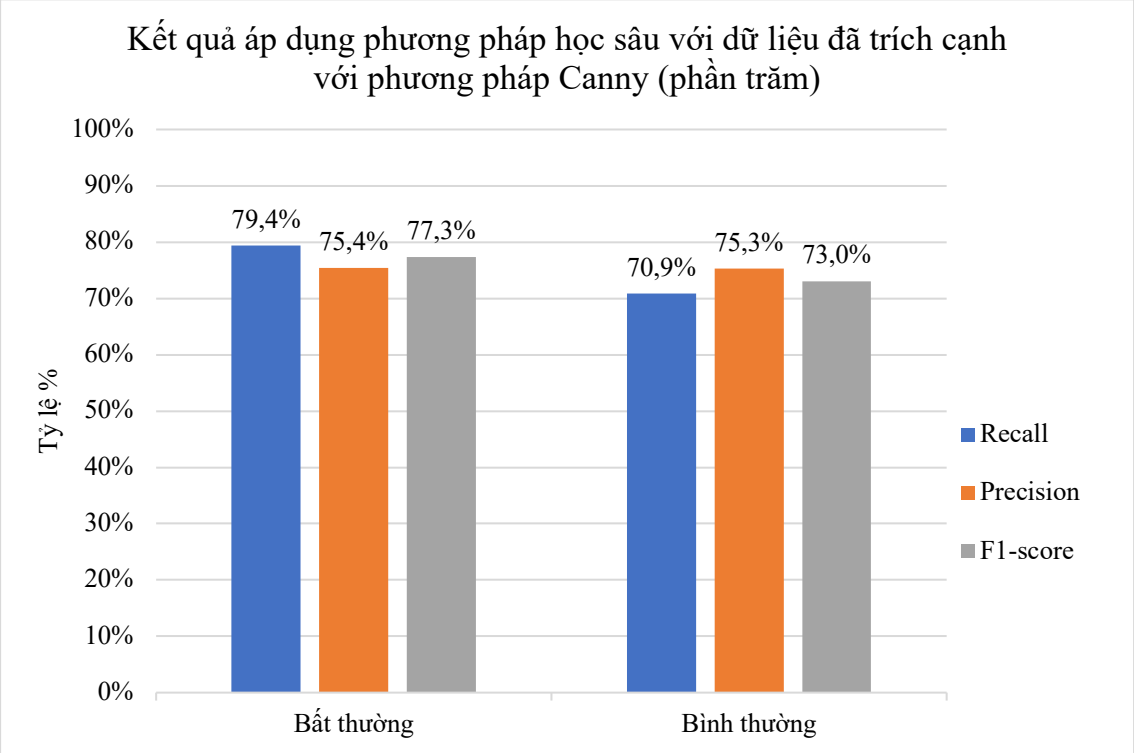
Kết quả thực nghiệm với CNN khi dữ liệu được tiền xử lý trích cạnh như bảng 4.10, bảng 4.11, hình 4.21, hình 4.22, hình 4.23, cho thấy mức độ sai lệch và mức độ chính xác của dữ liệu.

Bảng 4.10 Kết quả các giá trị TP, TN, FP và FN.

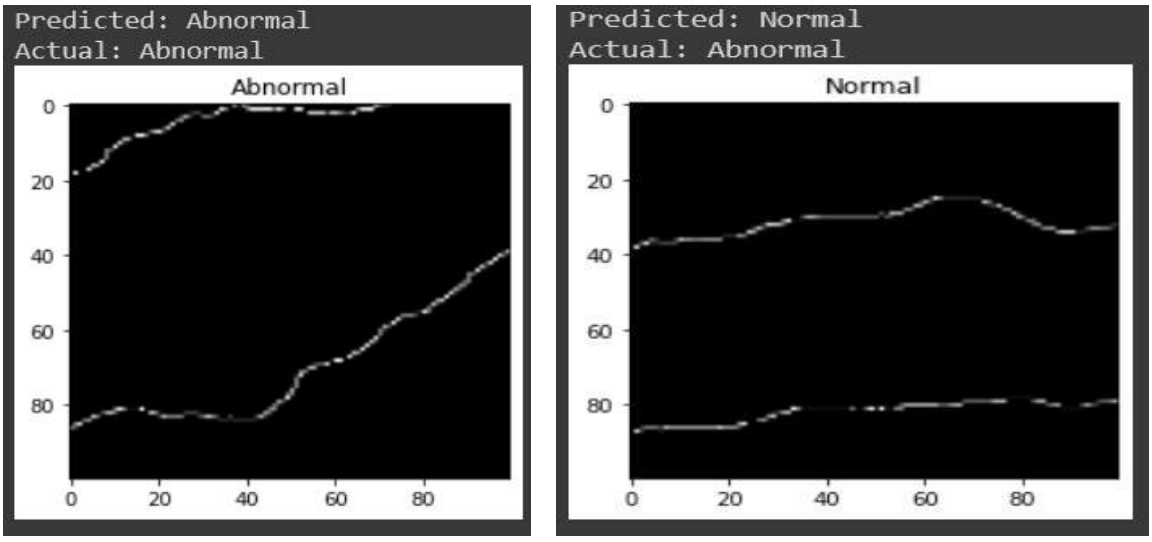
	Ảnh bất thường	**Ảnh bình thường**	**Tổng cộng**
Ảnh bất thường	212	69	281
Ảnh bình thường	55	168	223

Bảng 4.11 Kết quả các độ đo.

	Recall	**Precision**	**F1-score**
Ảnh bất thường	0,794	0,754	0,773
Ảnh bình thường	0,709	0,753	0,730

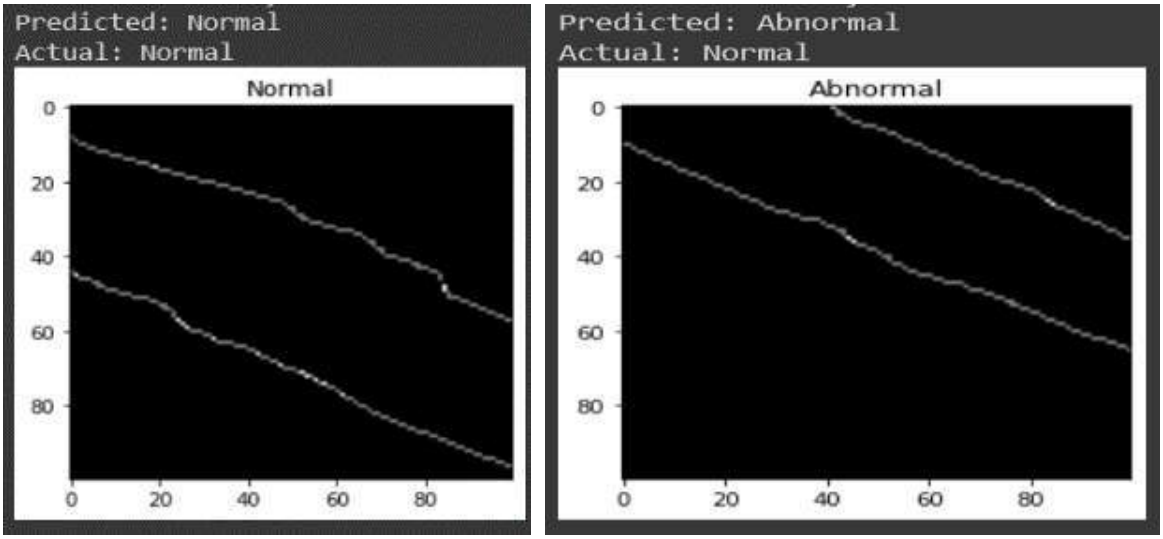


Hình 4.21 Đồ thị kết quả các độ đo



(a) (b)

Hình 4.22 Ảnh bất thường: (a) kết quả đúng; (b) kết quả sai.



(a) (b)

Hình 4.23 Ảnh bình thường: (a) kết quả đúng; (b) kết quả sai.

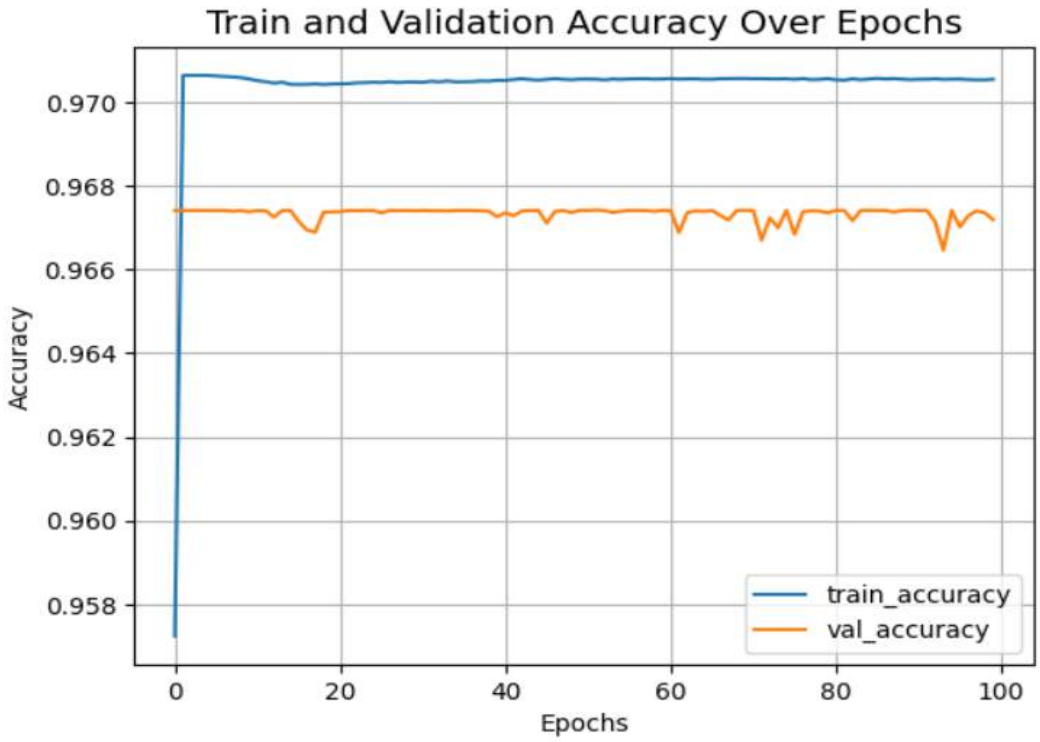
4.7.5 Kết quả phương pháp học sâu với dữ liệu đã trích cạnh với phương pháp DexiNed

Luận án chia dữ liệu làm hai phần để huấn luyện và kiểm tra theo tỷ lệ 65%, 15%, và 20% như bảng 4.12.

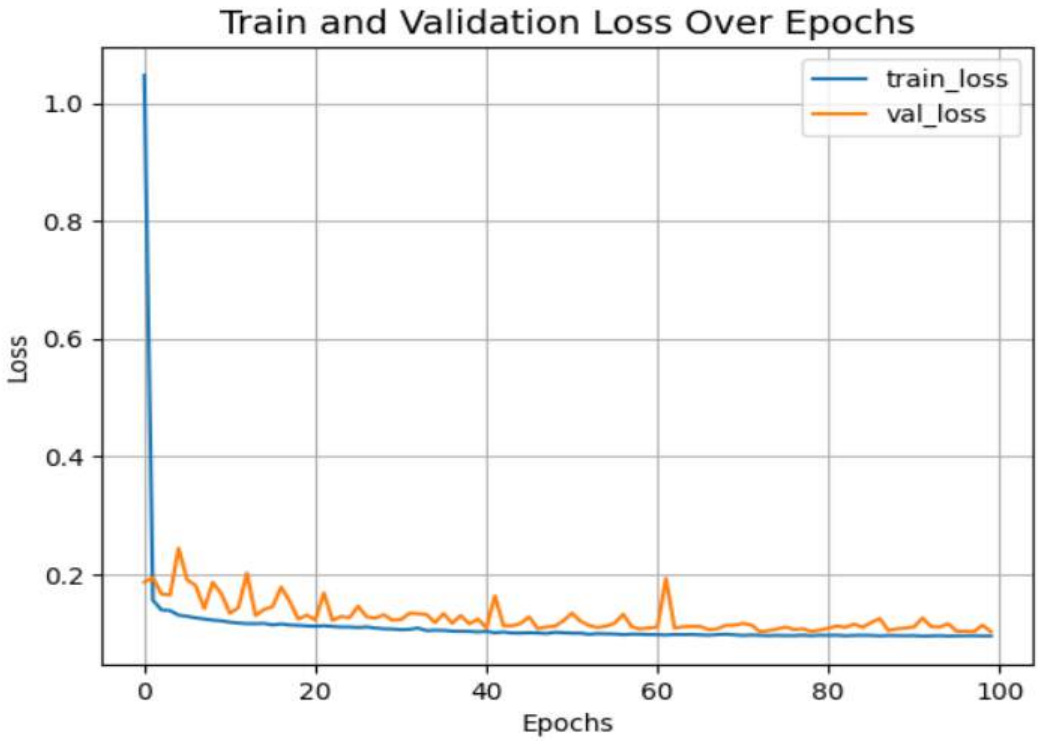
Bảng 4.12 Số lượng dữ liệu dùng cho mô hình.

	Huấn luyện	**Đánh giá**	**Kiểm thử**	**Tổng**
Bất thường	1889	436	581	2906
Bình thường	1965	453	604	3022

Luận án huấn luyện mô hình DexiNed để trích cạnh các đoạn mạch vành, hình 4.24, hình 4.25. Kết quả sau khi trích đoạn, hình 4.26, hình 4.27. Sau khi trích cạnh luận án dùng thuật toán hình thái học để tăng thông tin cạnh, kết quả như hình 4.28, hình 4.29.



Hình 4.24 Độ chính xác của tập huấn luyện và tập đánh giá khi trích cạnh.



Hình 4.25 Độ sai lệch của tập huấn luyện và tập đánh giá khi trích cạnh.



Hình 4.26 Ảnh mạch vành bình thường sau khi được trích cạnh.



Hình 4.27 Ảnh mạch vành bất thường sau khi được trích cạnh.

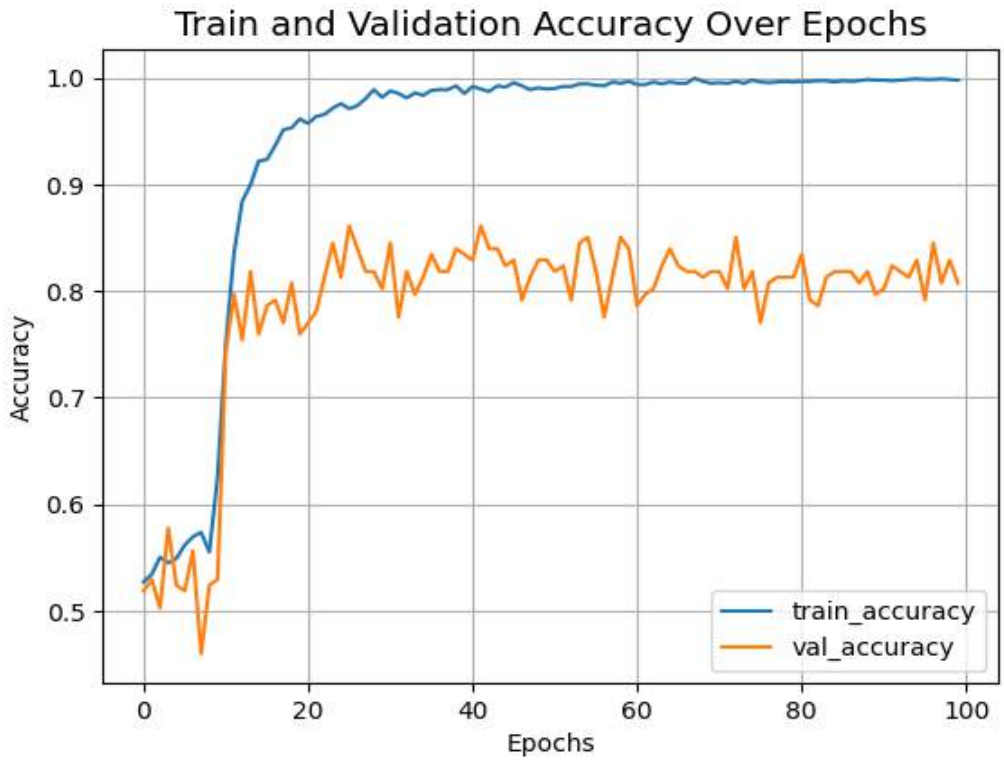


Hình 4.28 Ảnh mạch vành bình thường sau khi được làm giàu thông tin cạnh.

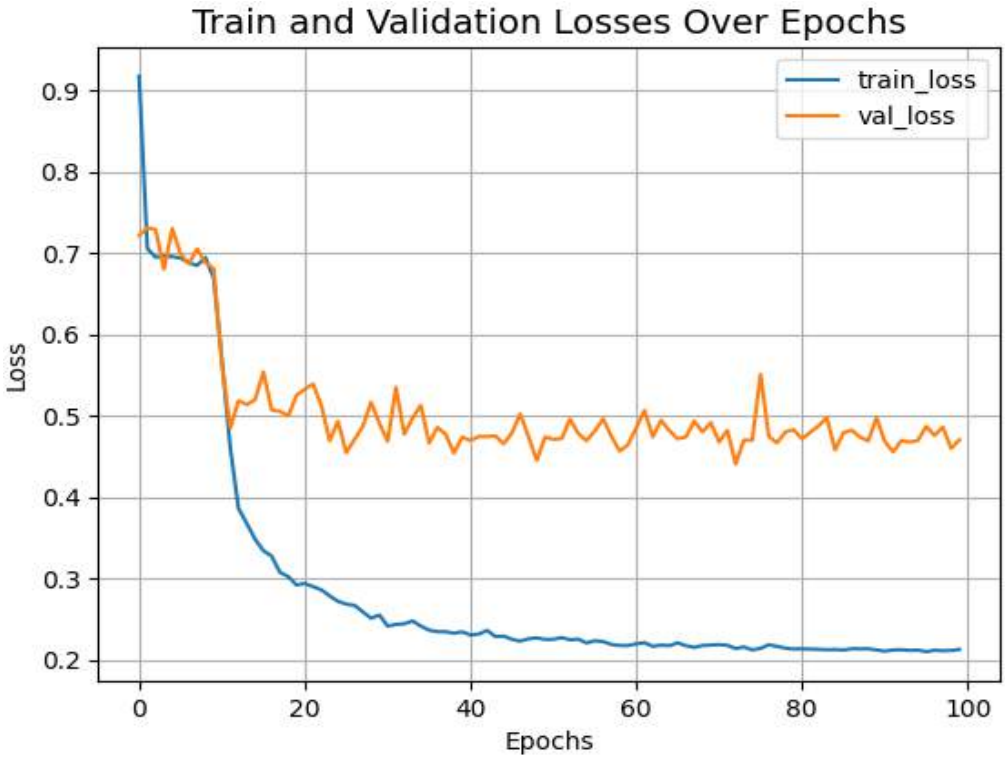


Hình 4.29 Ảnh mạch vành bất thường sau khi được làm giàu thông tin cạnh.

Luận án huấn luyện mô hình phân loại đoạn mạch vành có bất thường hay không với dữ liệu đầu vào là đoạn mạch vành đã được trích cạnh từ mô hình DexiNed, hình 4.30, hình 4.31, kết quả bảng 4.13, bảng 4.14, hình 4.32.



Hình 4.30 Độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện.



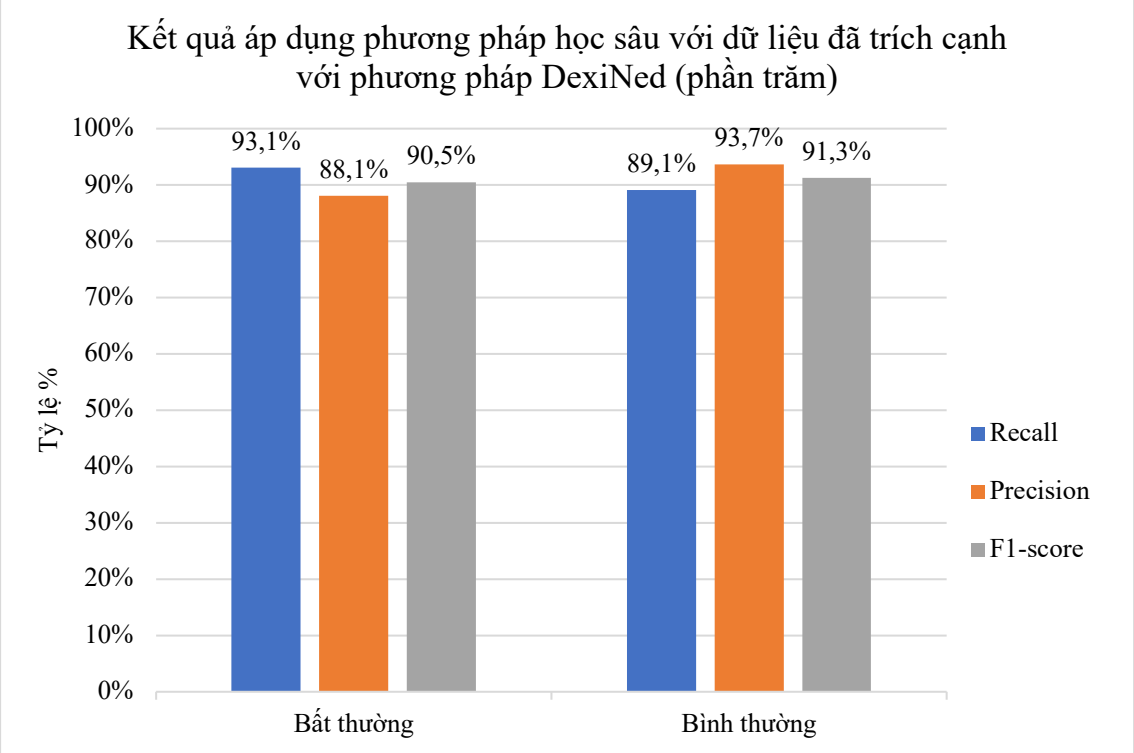
Hình 4.31 Độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện.

Bảng 4.13 Kết quả các giá trị TP, TN, FP và FN.

	Ảnh bất thường	**Ảnh bình thường**	**Tổng cộng**
Ảnh bất thường	512	69	581
Ảnh bình thường	38	566	604

Bảng 4.14 Kết quả các độ đo.

	Recall	**Precision**	**F1-score**
Ảnh bất thường	0,931	0,881	0,905
Ảnh bình thường	0,891	0,937	0,913



Hình 4.32 Đồ thị kết quả các độ đo.

4.7.6 Kết quả phương pháp học sâu với dữ liệu mặt phẳng bit

4.7.6.1 Thực nghiệm với bộ dữ liệu D

Luận án chia dữ liệu làm hai phần để huấn luyện và kiểm tra theo tỷ lệ 65%, 15%, và 20% như bảng 4.15.

Bảng 4.15 Số lượng dữ liệu dùng cho mô hình.

	Huấn luyện	**Đánh giá**	**Kiểm thử**	**Tổng**
Bất thường	1889	436	581	2906
Bình thường	1965	453	604	3022

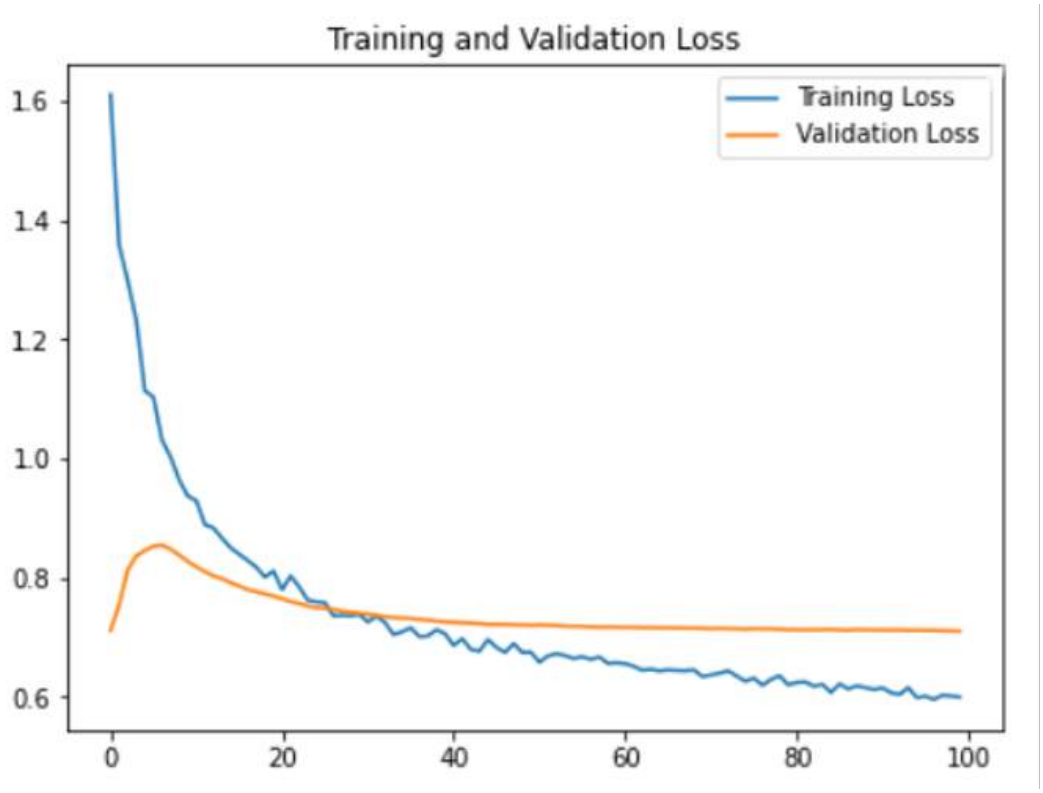
Luận án thực nghiệm trên từng mặt phẳng bit được tập kết quả về độ chính xác của mô hình dự đoán theo từng mặt phẳng bit, bảng 4.16.

Bảng 4.16 Kết quả độ chính xác của mô hình dự đoán sử dụng từng mặt phẳng bit.

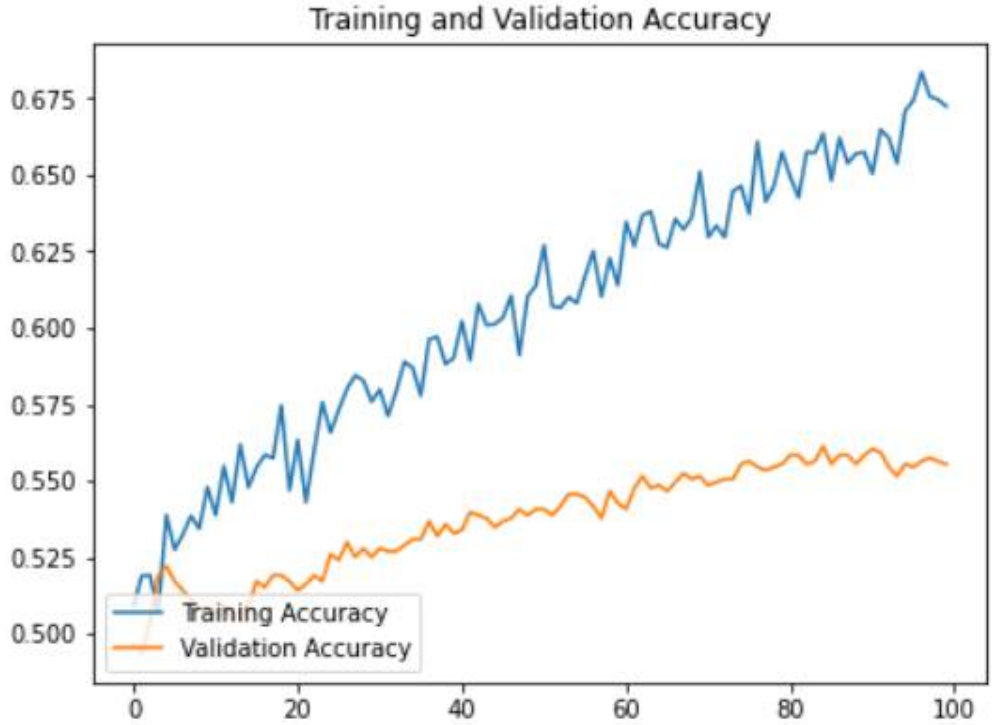
Mặt phẳng bit	**Tập huấn luyện**	**Tập đánh giá**	**Tập kiểm thử**
7	0,771	0,570	0,604
6	0,688	0,535	0,546
5	0,487	0,540	0,596
4	0,451	0,443	0,420
3	0,419	0,506	0,471
2	0,402	0,379	0,371
1	0,352	0,440	0,335
0	0,301	0,255	0,295

Luận án nhận thấy các mặt phẳng bit có vị trí càng thấp càng đóng góp ít cho độ chính xác của quá trình dự đoán. Vì vậy luận án đã loại bỏ 5 mặt phẳng bit cuối cùng và giữ lại 3 mặt phẳng bit đầu tiên để dùng cho quá trình tính toán của phương pháp voting.

Luận án xem xét mức độ chính xác của quá trình huấn luyện và đánh giá, với mặt phẳng bit 7 có các hình 4.33, 4.34 tương ứng; và kết quả mức độ chính xác từ tập kiểm thử, bảng 4.17. Còn dữ liệu là mặt phẳng bit 6 và 5, luận án có kết quả tương ứng là hình 4.35, hình 4.36, bảng 4.18 và hình 4.37, hình 4.38, bảng 4.19.



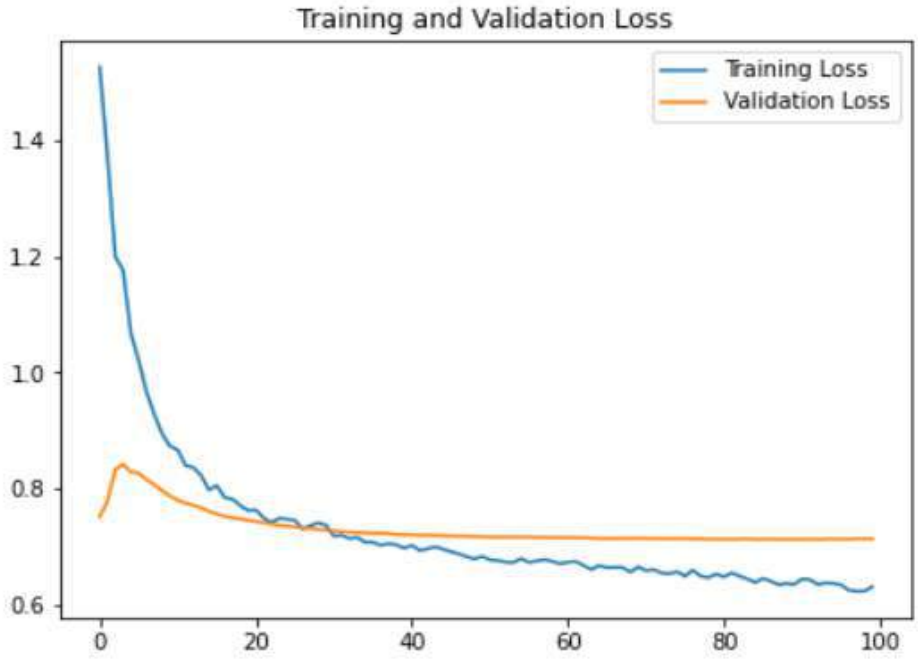
Hình 4.33 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 7.



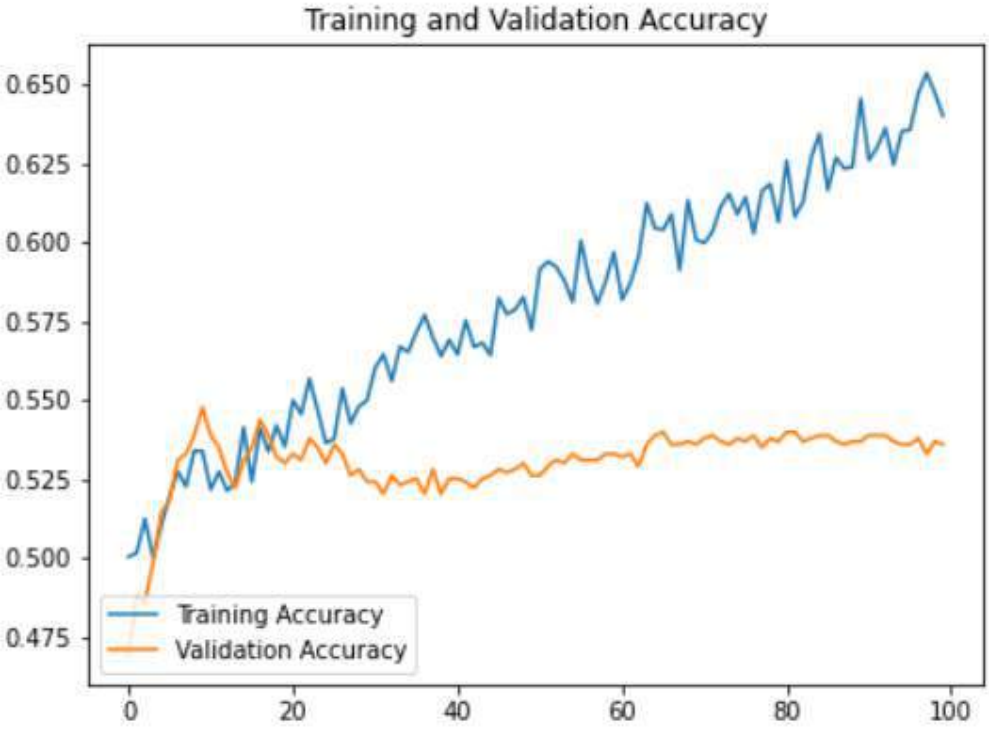
Hình 4.34 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 7.

Bảng 4.17 Kết quả các độ đo với mặt phẳng bit 7.

	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,626	0,604	0,615
Ảnh bình thường	0,631	0,652	0,641



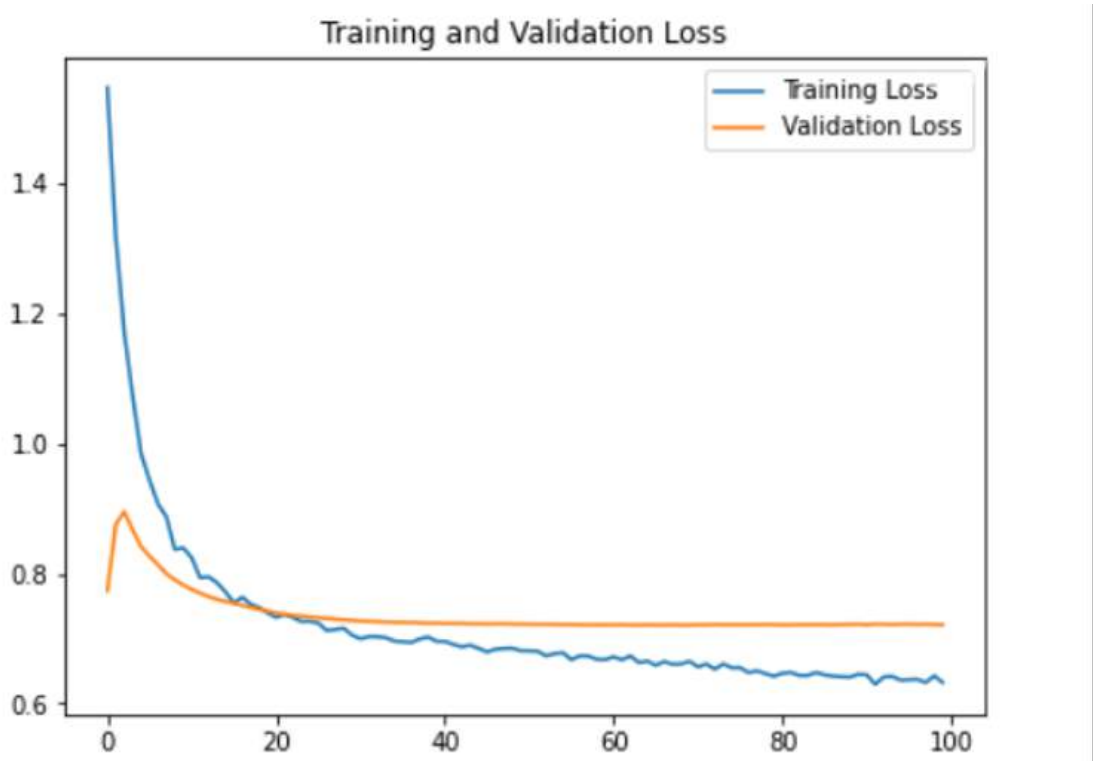
Hình 4.35 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 6.



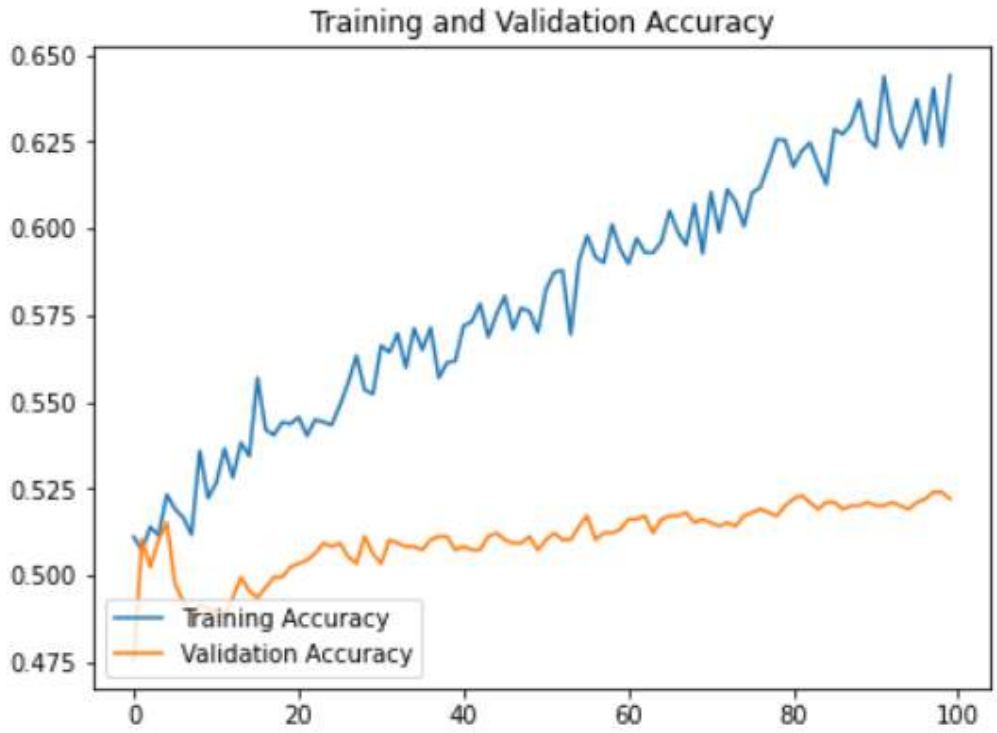
Hình 4.36 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 6.

Bảng 4.18 Kết quả các độ đo với mặt phẳng bit 6.

	Recall	Precision	F1-Score
Ảnh bất thường	0,588	0,546	0,566
Ảnh bình thường	0,591	0,632	0,611



Hình 4.37 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 5.



Hình 4.38 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng bit 5.

Bảng 4.19 Kết quả các độ đo với mặt phẳng bit 5.

	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,626	0,596	0,611
Ảnh bình thường	0,628	0,657	0,642

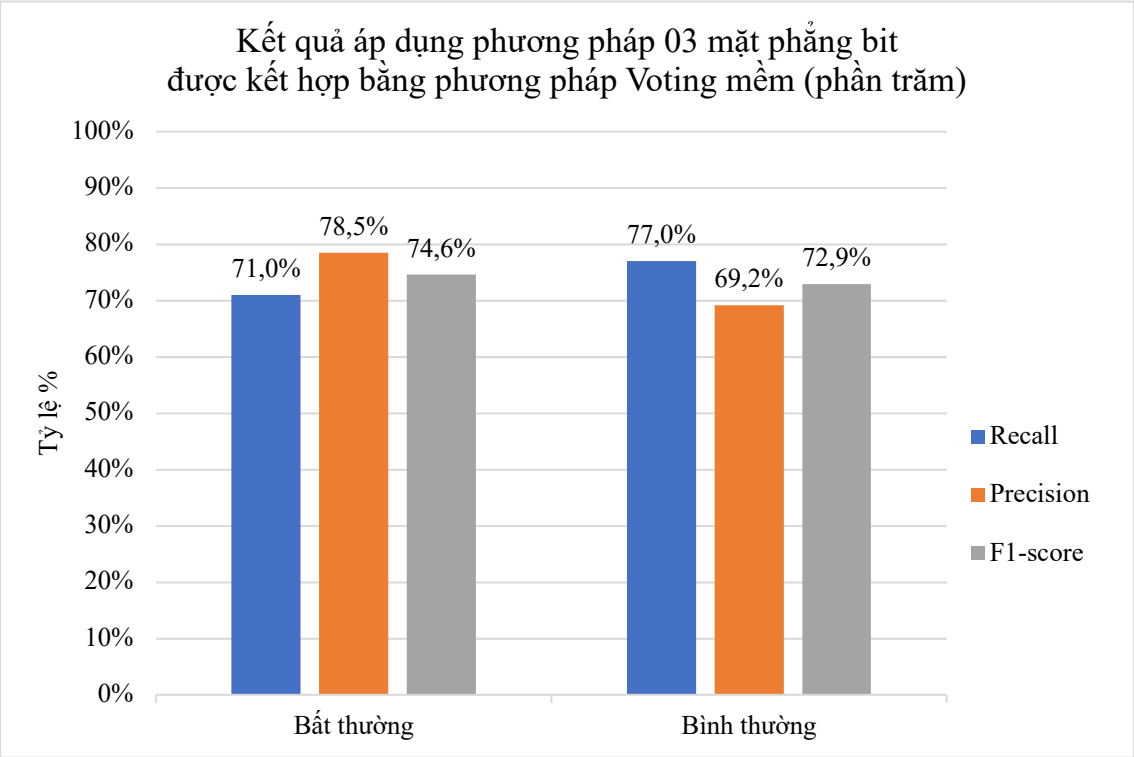
Sau khi dùng phương pháp voting mềm, luận án có được kết quả như bảng 4.20, bảng 4.21, hình 4.39, ví dụ kết quả phân loại với phương pháp kết hợp mặt phẳng bit bằng voting mềm, hình 4.40.

Bảng 4.20 Kết quả các giá trị TP, TN, FP và FN.

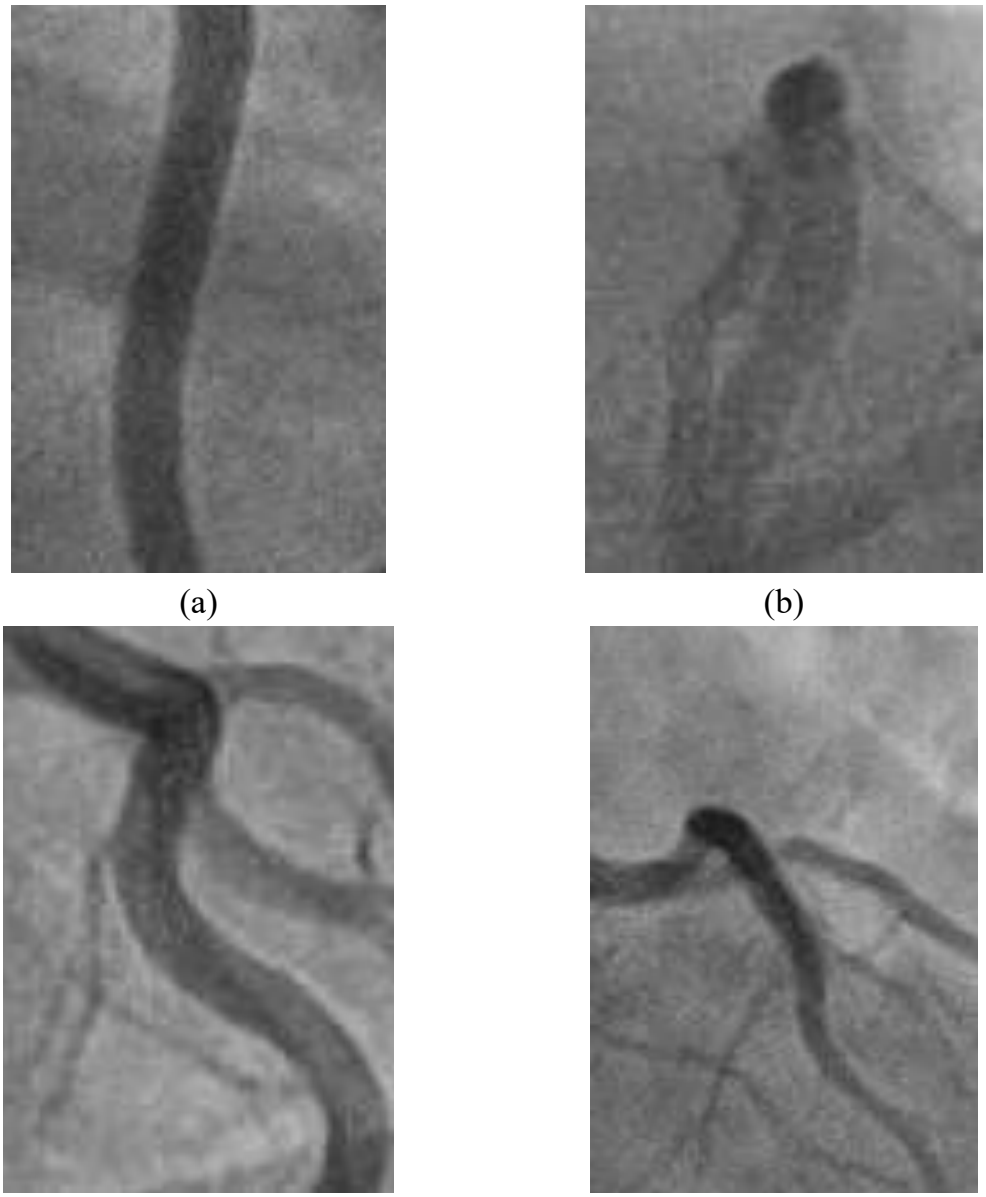
	Ảnh bất thường	**Ảnh bình thường**	**Tổng cộng**
Ảnh bất thường	456	125	581
Ảnh bình thường	156	418	604

Bảng 4.21 Kết quả các độ đo với 03 mặt phẳng bit được kết hợp bằng phương pháp voting mềm.

	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,71	0,785	0,746
Ảnh bình thường	0,77	0,692	0,729



Hình 4.39 Đồ thị kết quả các độ đo.



Hình 4.40 Dự đoán ảnh theo phương pháp mặt phẳng bit:
(a) ảnh bình thường ra bình thường; (b) ảnh bình thường ra bất thường.
(c) ảnh bất thường ra bình thường; (d) ảnh bất thường ra bất thường.

4.7.6.2 Thực nghiệm với bộ dữ liệu ARCADE

Luận án thực hiện thực nghiệm tương tự như thực hiện với bộ dữ liệu D để có kết quả như bảng độ 4.22. Kết quả với ba mặt phẳng bit là 7, 6, 5 được trình bày ở các bảng 4.23, 4.24, 4.25; và kết quả kết hợp ba mặt phẳng màu bằng phương pháp voting mềm với bảng 4.26, 4.27.

Bảng 4.22 Kết quả độ chính xác của mô hình dự đoán sử dụng từng mặt phẳng bit.

Mặt phẳng bit	Tập huấn luyện	Tập đánh giá	Tập kiểm thử
7	0,723	0,580	0,619
6	0,710	0,528	0,556
5	0,489	0,550	0,587
4	0,453	0,454	0,432
3	0,417	0,511	0,474
2	0,401	0,381	0,370
1	0,353	0,441	0,336
0	0,301	0,257	0,297

Bảng 4.23 Kết quả các độ đo với mặt phẳng bit 7.

	Recall	Precision	F1-Score
Ảnh bất thường	0,569	0,619	0,593
Ảnh bình thường	0,704	0,659	0,681

Bảng 4.24 Kết quả các độ đo với mặt phẳng bit 6.

	Recall	Precision	F1-Score
Ảnh bất thường	0,526	0,556	0,541
Ảnh bình thường	0,665	0,638	0,651

Bảng 4.25 Kết quả các độ đo với mặt phẳng bit 5.

	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,556	0,587	0,571
Ảnh bình thường	0,689	0,661	0,675

Bảng 4.26 Kết quả các giá trị TP, TN, FP và FN.

	Ảnh bất thường	**Ảnh bình thường**	**Tổng cộng**
Ảnh bất thường	99	27	126
Ảnh bình thường	52	122	174

Bảng 4.27 Kết quả các độ đo với 03 mặt phẳng bit được kết hợp bằng phương pháp voting mềm.

	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,656	0,786	0,715
Ảnh bình thường	0,819	0,701	0,755

4.7.7 Kết quả phương pháp học sâu với dữ liệu mặt phẳng màu

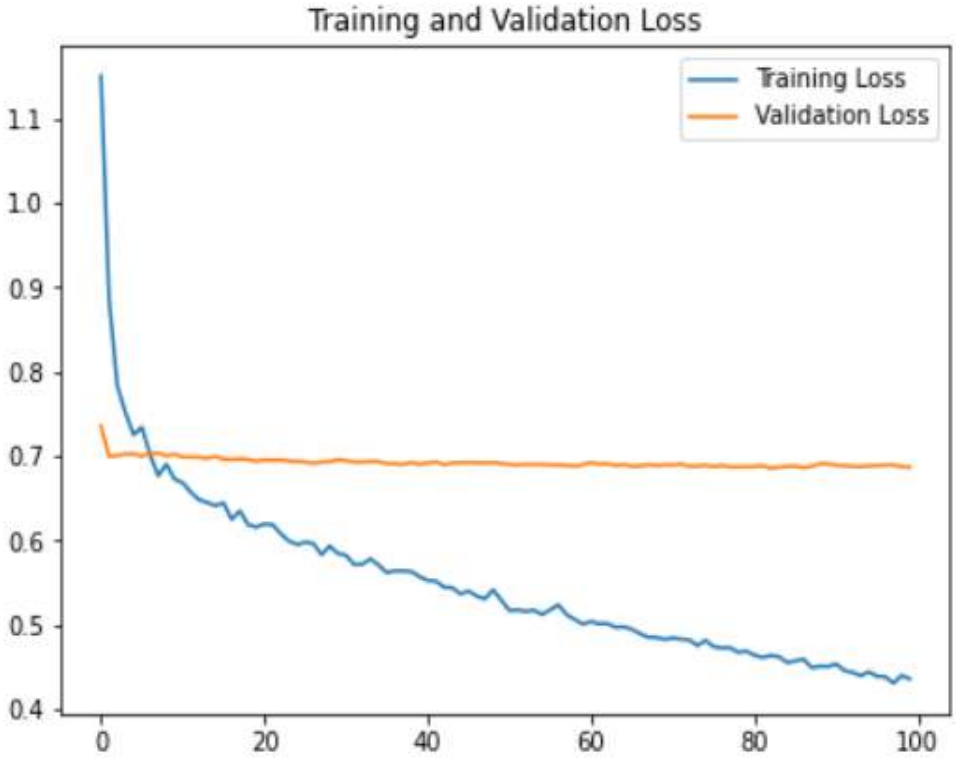
1.7.7.1 Thực nghiệm với bộ dữ liệu D

Với ảnh màu ban đầu luận án thực nghiệm trên dữ liệu như bảng 4.15 cho từng mặt phẳng màu thì có kết quả về độ chính xác của mô hình theo từng mặt phẳng màu, bảng 4.28.

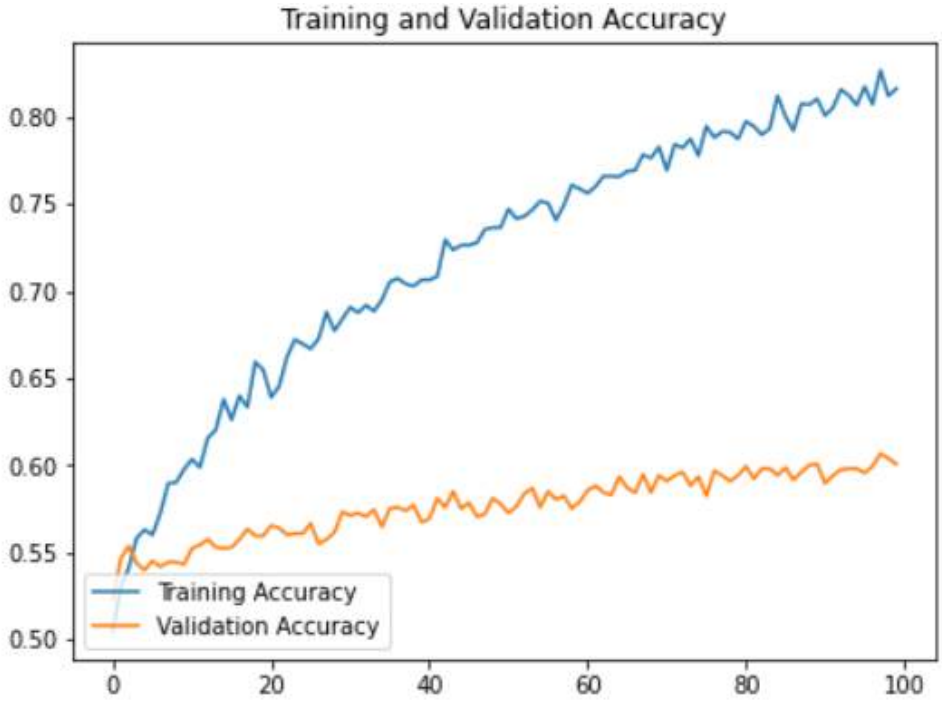
Luận án huấn luyện và kiểm thử cho từng mặt phẳng màu: mặt phẳng màu đỏ cho kết quả như hình 4.41, hình 4.42, bảng 4.29; mặt phẳng màu màu lục cho kết quả như hình 4.43, hình 4.44, bảng 4.30; mặt phẳng màu màu lam cho kết quả như hình 4.45, hình 4.46, bảng 4.31.

Bảng 4.28 Kết quả độ chính xác của mô hình dự đoán sử dụng mặt phẳng màu.

Mặt phẳng màu	Tập huấn luyện	Tập đánh giá	Tập kiểm thử
Đỏ	0,945	0,617	0,723
Lục	0,932	0,619	0,706
Lam	0,932	0,610	0,739



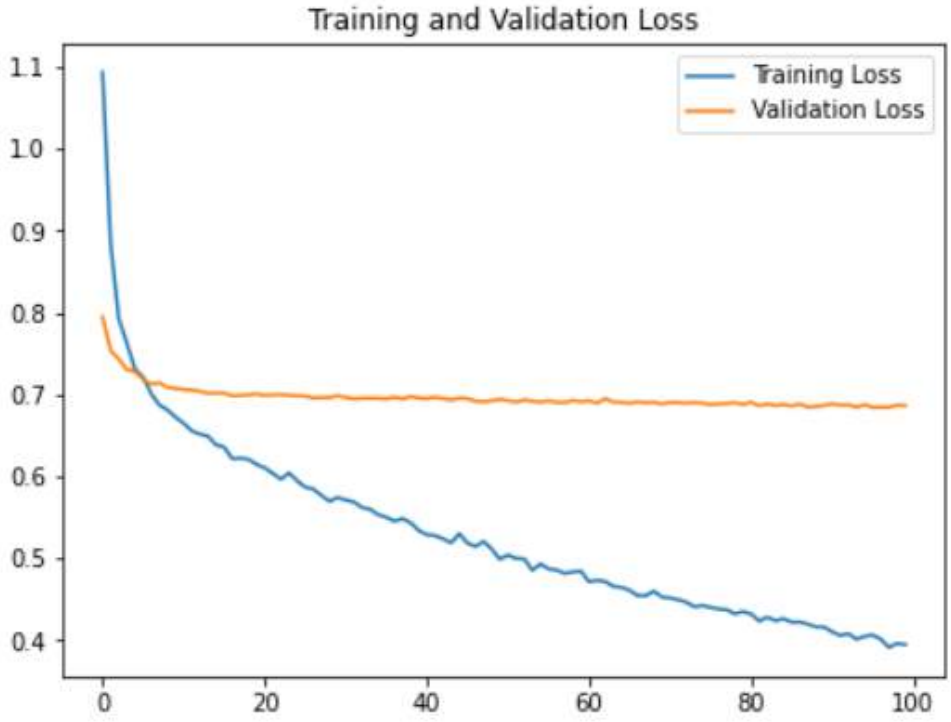
Hình 4.41 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu đỏ.



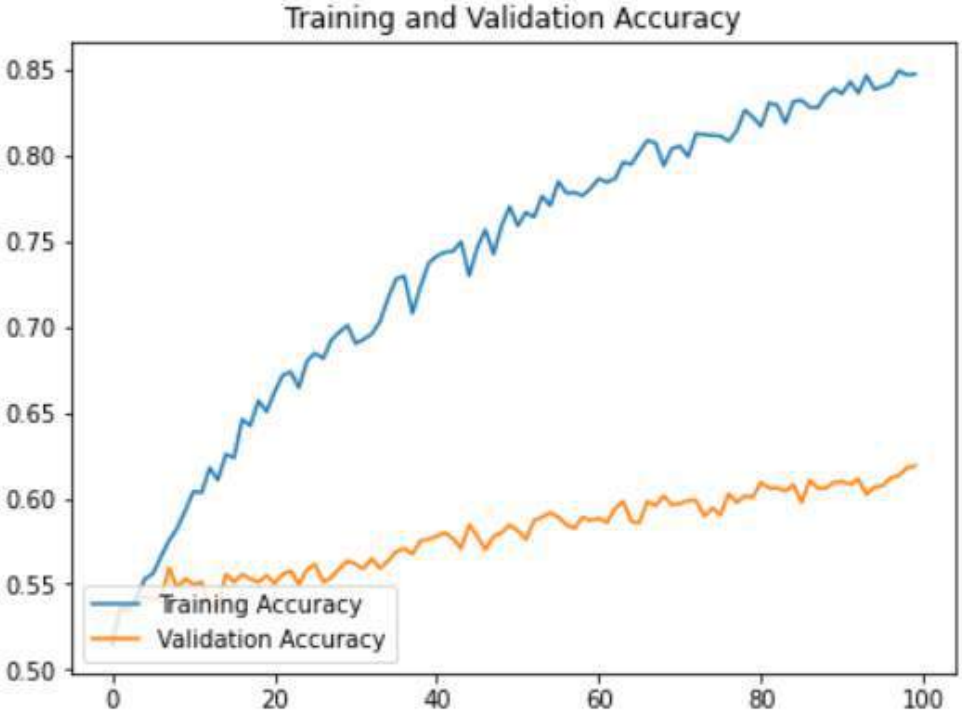
Hình 4.42 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu đỏ.

Bảng 4.29 Kết quả với mặt phẳng màu đỏ.

	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,676	0,723	0,699
Ảnh bình thường	0,715	0,667	0,690



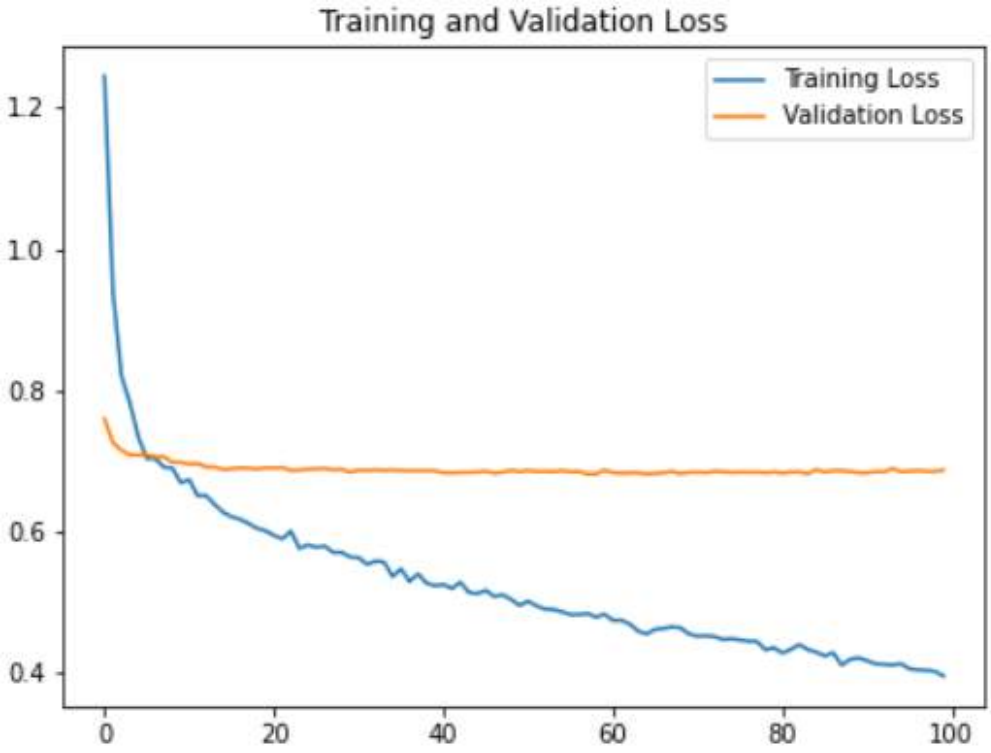
Hình 4.43 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu lục.



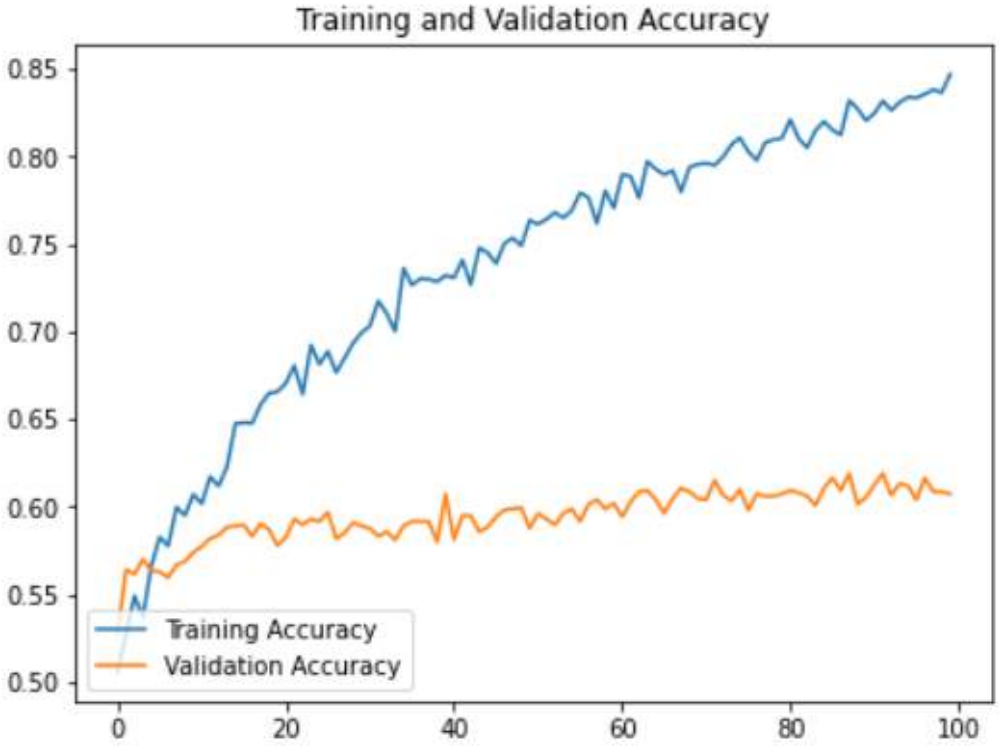
Hình 4.44 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu lục.

Bảng 4.30 Kết quả với mặt phẳng màu lục.

	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,660	0,706	0,682
Ảnh bình thường	0,697	0,651	0,673



Hình 4.45 Kết quả độ sai lệch của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu lam.



Hình 4.46 Kết quả độ chính xác của tập huấn luyện và tập đánh giá khi huấn luyện với mặt phẳng màu lam.

Bảng 4.31 Kết quả với mặt phẳng màu lam.

	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,697	0,740	0,718
Ảnh bình thường	0,734	0,690	0,711

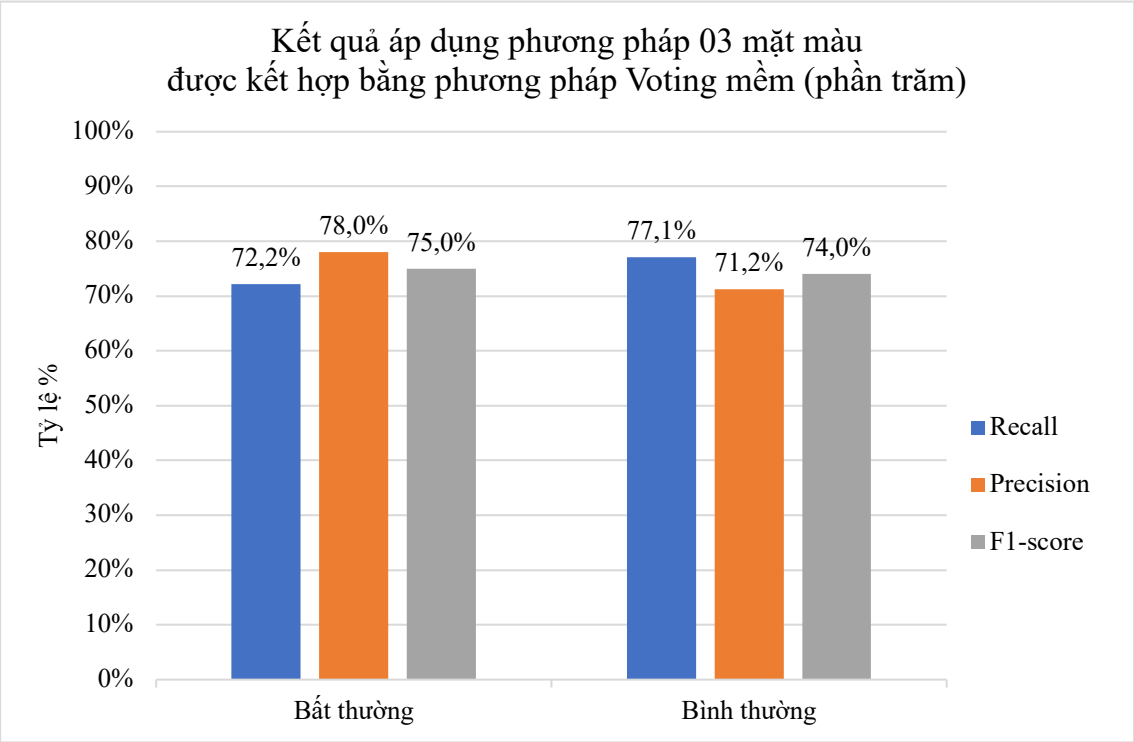
Luận án áp dụng phương pháp voting mềm kết hợp dữ liệu cho ba mặt phẳng màu thì được kết qủa như bảng 4.32, và bảng 4.33, hình 4.47. Ví dụ kết quả phân loại với phương pháp kết hợp mặt phẳng bit bằng voting mềm, hình 4.48.

Bảng 4.32 Kết quả các giá trị TP, TN, FP và FN.

	Ảnh bất thường	**Ảnh bình thường**	**Tổng cộng**
Ảnh bất thường	453	128	581
Ảnh bình thường	174	430	604

Bảng 4.33 Kết quả kiểm tra với 03 mặt phẳng màu được kết hợp bằng phương pháp voting mềm.

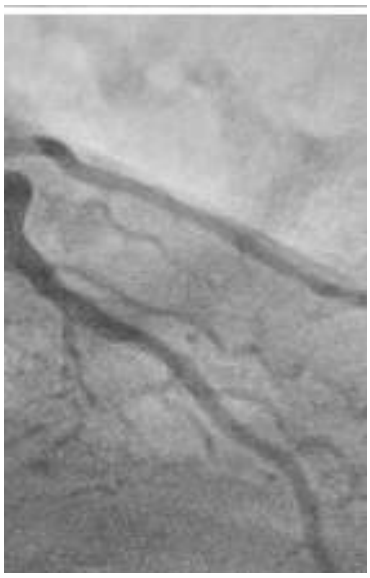
	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,722	0,780	0,750
Ảnh bình thường	0,771	0,712	0,740



Hình 4.47 Đồ thị kết quả các độ đo.



(a)



(b)



(c)



(d)

Hình 4.48 Dự đoán ảnh theo phương pháp mặt phẳng màu:
(a) ảnh bình thường ra bình thường; (b) ảnh bình thường ra bất thường.
(c) ảnh bất thường ra bình thường; (d) ảnh bất thường ra bất thường.

4.7.7.2 Thực nghiệm với bộ dữ liệu ARCADE

Luận án thực nghiệm tương tự mục 4.7.7.1 cho bộ dữ liệu ARCADE được kết quả cho từng mặt phẳng màu như bảng 4.34, 4.35 và 4.36. Sau khi kết hợp ba mặt phẳng màu bằng phương pháp voting mềm thì được kết quả như bảng 4.37 và 4.38.

Bảng 4.34 Kết quả độ chính xác của mô hình dự đoán sử dụng mặt phẳng màu.

Mặt phẳng màu	Tập huấn luyện	Tập đánh giá	Tập kiểm thử
Đỏ	0,950	0,621	0,730
Lục	0,941	0,625	0,714
Lam	0,937	0,611	0,746

Bảng 4.35 Kết quả với mặt phẳng màu đỏ.

	Recall	Precision	F1-Score
Ảnh bất thường	0,613	0,73	0,666
Ảnh bình thường	0,773	0,667	0,716

Bảng 4.36 Kết quả với mặt phẳng màu lục.

	Recall	Precision	F1-Score
Ảnh bất thường	0,600	0,714	0,652
Ảnh bình thường	0,760	0,655	0,704

Bảng 4.37 Kết quả với mặt phẳng màu lam.

	Recall	Precision	F1-Score
Ảnh bất thường	0,644	0,746	0,691
Ảnh bình thường	0,792	0,701	0,744

Bảng 4.38 Kết quả các giá trị TP, TN, FP và FN.

	Ảnh bất thường	**Ảnh bình thường**	**Tổng cộng**
Ảnh bất thường	98	28	126
Ảnh bình thường	50	124	174

Bảng 4.39 Kết quả kiểm tra với ba mặt phẳng màu được kết hợp bằng phương pháp voting mềm.

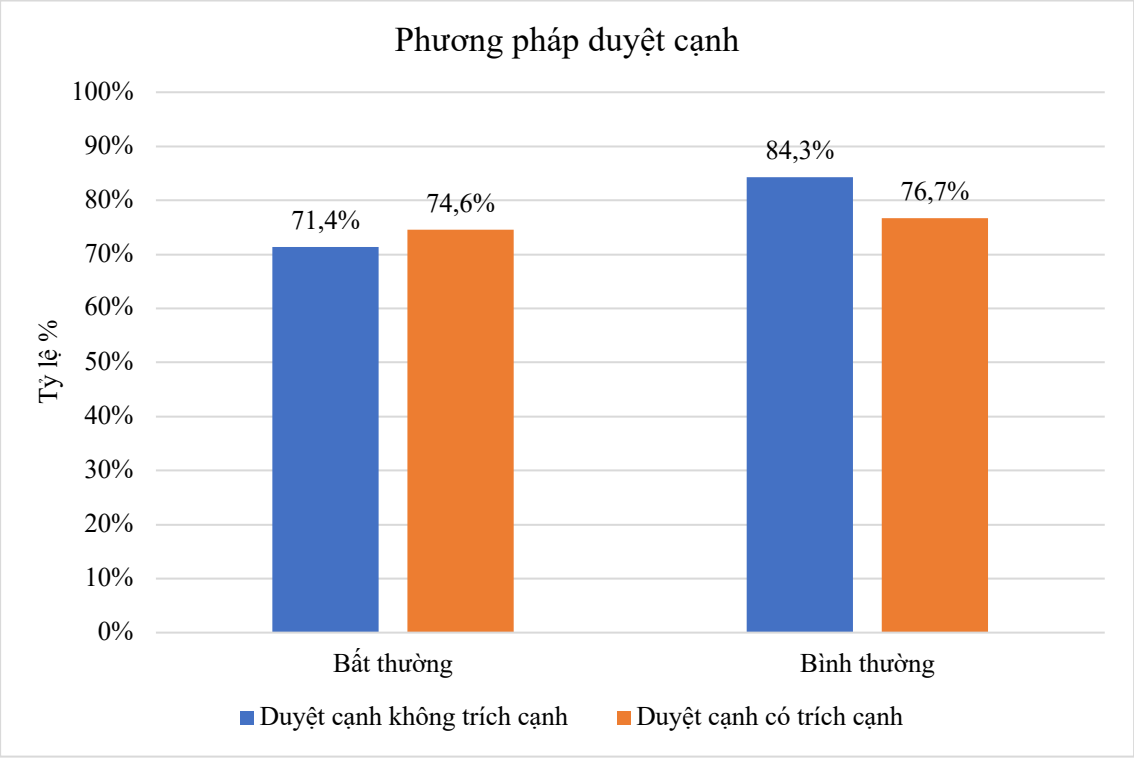
	Recall	**Precision**	**F1-Score**
Ảnh bất thường	0,664	0,778	0,720
Ảnh bình thường	0,821	0,713	0,763

4.8 Đánh giá

Với hai bộ dữ liệu khác nhau là D và *ARCADE,* phương pháp với hướng tiếp cận dữ liệu đầu vào là các mặt phẳng thông tin (loại mặt phẳng bit và mặt phẳng màu) với mô hình học sâu cho kết quả gần tương tự như nhau. Điều này cho thấy dù bất kỳ dữ liệu đoạn mạch vành nào, nếu dùng mặt phẳng thông tin thì kết quả không sai khác và ở khoảng 78% với ảnh bất thường và 72%.

Phương pháp duyệt theo cạnh mạch vành để phát hiện bất thường phụ thuộc rất nhiều vào ngưỡng chuyển trạng thái của cạnh nên việc chọn ngưỡng sẽ rất khó để có độ chính xác cao, dù việc trích cạnh giúp giảm chi phí duyệt và có làm tăng khoảng 3% mức độ chính xác trong trường hợp cạnh bất thường, nhưng lại làm giảm gần 8% mức độ chính xác trong trường hợp cạnh bình thường sẽ nhầm lẫn sang cạnh bất thường khi kết quả phân đoạn không hoàn toàn chính xác hay đoạn mạch cắt đoạn hơi chuyển đổi hướng chuyển động, hình 4.49. Độ lệch chuẩn của bất thường là 0,016 và bình thường là 0,038; giá trị này cho thấy độ lệch khi xác định bất thường sẽ ít bị biến động hơn so với bình thường do tác động của giá trị ngưỡng được chọn cao để xác định đoạn mạch bất thường tốt hơn, nhưng điều này lại làm những đoạn mạch

nghi ngờ hoặc hơi bất thường sẽ được xem là đoạn mạch bình thường. Điều đấy cho thấy giá trị recall cao hơn so với precision và F1-score.

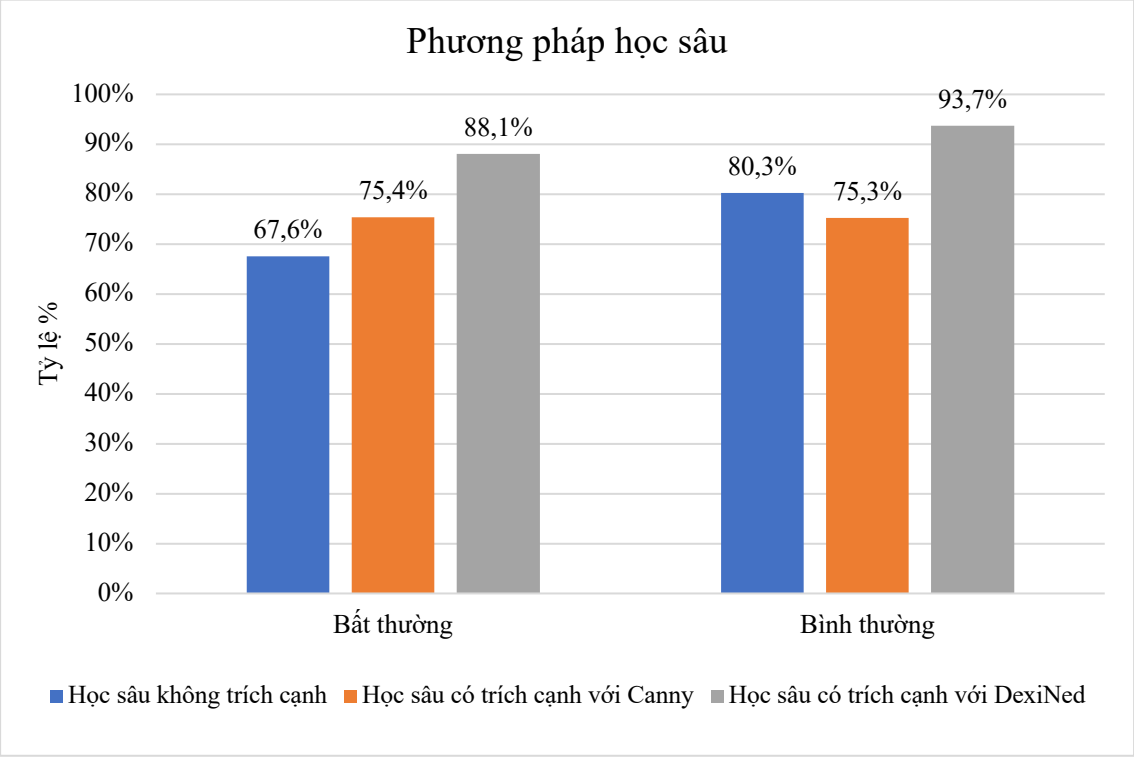


Hình 4.49 So sánh mức độ chính xác phương pháp duyệt cạnh với dữ liệu đầu vào là đoạn mạch không trích cạnh và có trích cạnh.

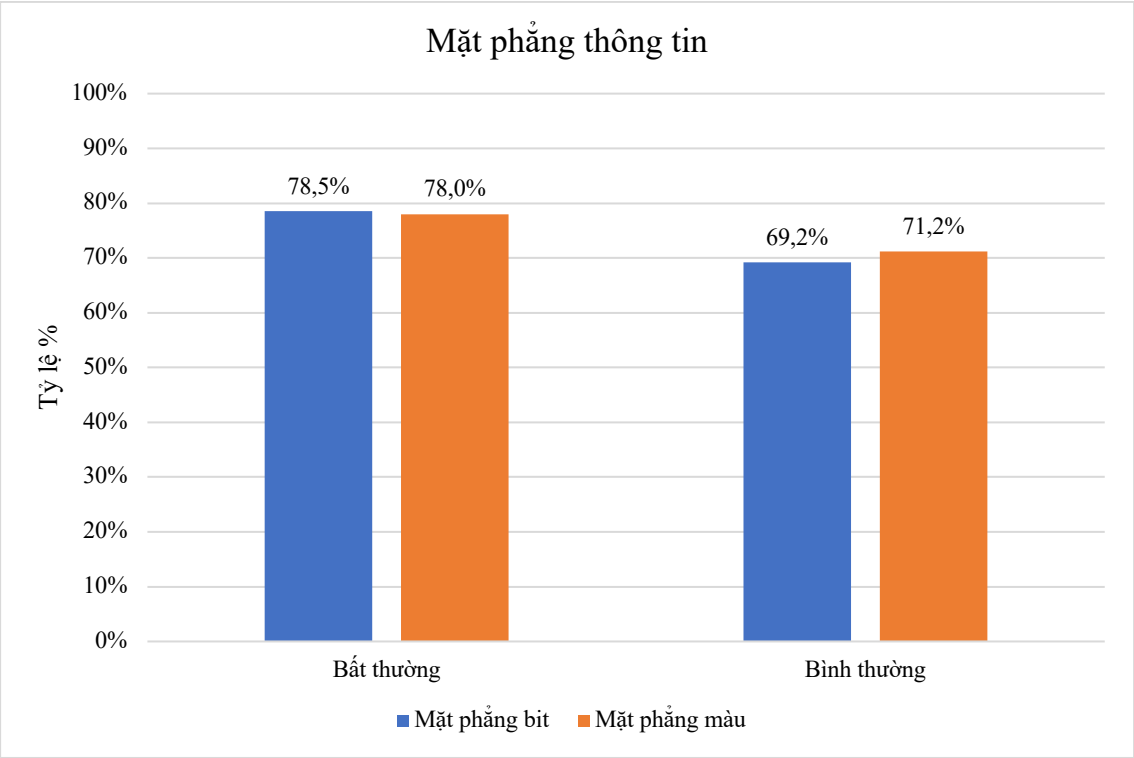
Đối với hướng sử dụng phương pháp học sâu thì kết quả cho thấy rõ sự phức tạp của đoạn ảnh mạch vành khi không trích cạnh thì kết quả xác định bất thường khá thấp (thấp hơn cả với phương pháp duyệt cạnh), hình 4.50. Tuy nhiên mức độ chính xác khi xác định cạnh bình thường tốt hơn so với dữ liệu đã được trích cạnh bằng phương pháp cổ điển (Canny) khoảng 4% nhưng không bằng học sâu (DexiNed), với học sâu có dữ liệu được trích cạnh bằng Dexined thì hơn 9%. Với phương pháp học sâu phát hiện bất thường với dữ liệu được trích cạnh bằng học sâu sẽ cho kết quả tốt nhất, hơn 13% so với phương pháp tốt thứ hai, điều này cho thấy việc trích cạnh bằng học sâu cho cạnh giàu thông tin hơn so với trích cạnh bằng phương pháp cổ điển (vì Canny cũng dùng ngưỡng để trích cạnh) và học sâu không trích cạnh, hình 4.50. Không những tốt nhất cho phân loại bất thường mà cho kết quả phân loại ảnh bình thường cũng đảm bảo. Độ lệch chuẩn của bất thường là 0,063 và bình thường là 0,092 trong

trường hợp tiền xử lý trích cạnh. Độ lệch chuẩn của bất thường có giá trị lớn hơn nhiều vì giá trị này cũng dùng kết quả của phân đoạn không trích cạnh. Và độ lệch chuẩn của bất thường là 0,084 và bình thường là 0,077. Đối với dữ liệu mạch vành chưa phân đoạn được dùng cho mô hình voting mềm với các kết quả của mặt phẳng thông tin: mặt phẳng bit và mặt phẳng màu, hình 4.51. Độ lệch chuẩn của bất thường là 0,0025 và bình thường là 0,01. Do mức độ phức tạp của đoạn ảnh mạch vành, dù có tách các mặt phẳng thông tin nhưng các thông tin này vẫn không thể tách được riêng lẻ cho từng mặt phẳng thông tin mà vẫn tồn tại mối tương quan lẫn nhau.

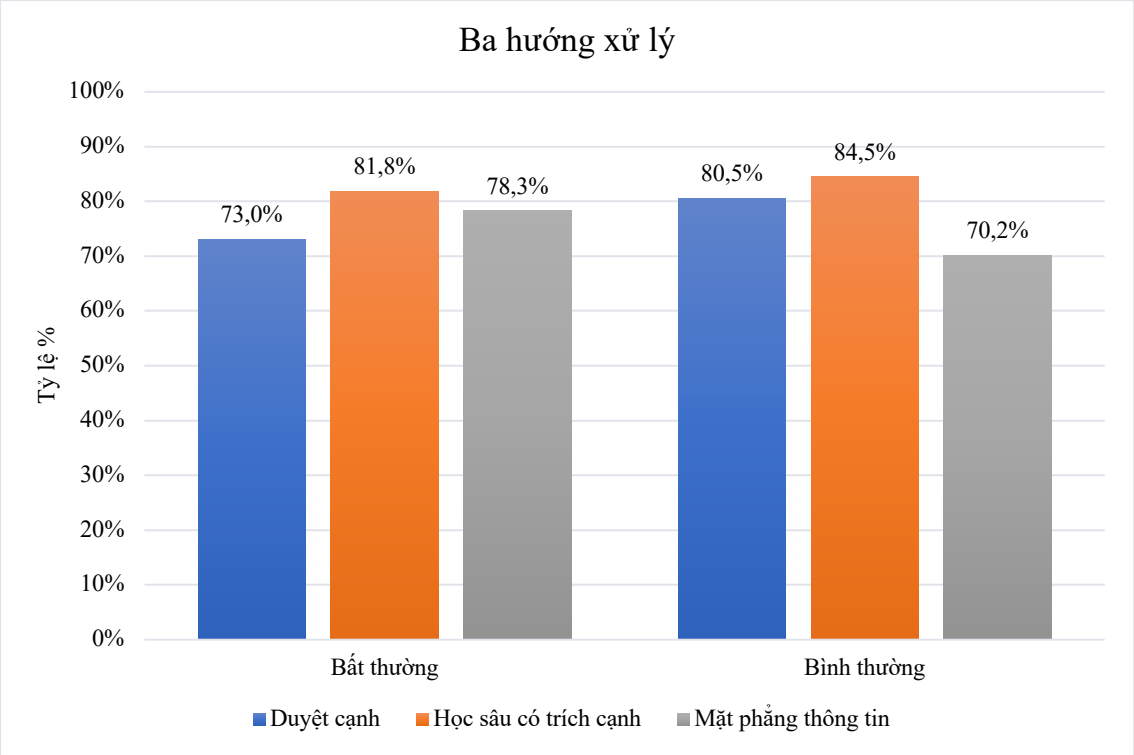
Cuối cùng nếu xem xét giá trị trung bình mức độ chính xác cho từng tiếp cận thì hướng tiếp cận học sâu có trích cạnh vẫn có ưu thế nhất, hình 4.52.



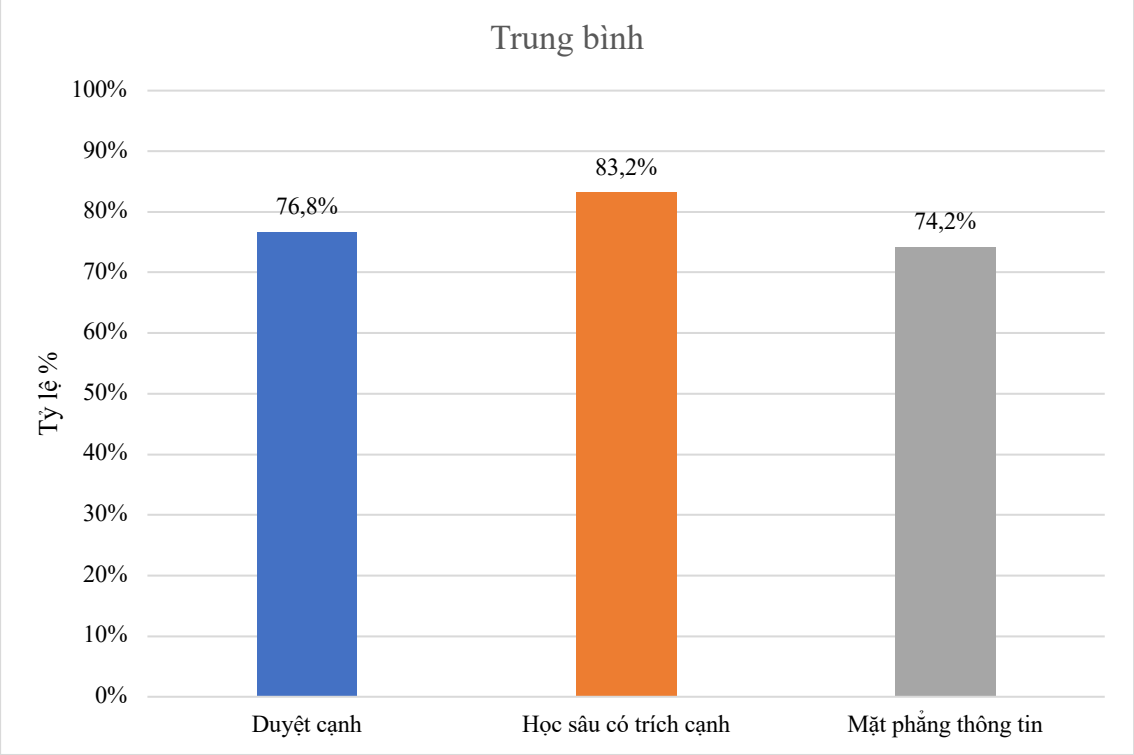
Hình 4.50 So sánh mức độ chính xác phương pháp học sâu với dữ liệu đầu vào là đoạn mạch không trích cạnh và có trích cạnh.



Hình 4.51 So sánh mức độ chính xác phương pháp học sâu trên mặt phẳng thông tin kết hợp phương pháp voting.



(a)



(b)

Hình 4.52 So sánh trung bình của ba hướng xử lý:
(a) xem xét bình thường và bất thường; (b) chỉ xem xét mức độ chính xác.

4.9 Kết chương

Hai hướng tiếp cận để giải quyết bài toán xác định đoạn mạch vành có bất thường hay không. Hướng tiếp cận thứ nhất là xây dựng các thuật toán kết hợp quan hệ biên của điểm ảnh trên đoạn mạch vành để xem xét mức độ biến thiên về hướng chuyển động của các điểm ảnh trên biên có vượt qua ngưỡng hay không để quyết định đoạn mạch vành có bất thường hay không? Trong hướng tiếp cận này luận án xem xét dữ liệu đầu vào là đoạn mạch vành đã được phân đoạn: không có trích cạnh và có trích cạnh. Hướng tiếp cận thứ hai là dùng mô hình học sâu, cụ thể là CNN, để phát hiện đoạn mạch có bất thường hay không? Dữ liệu đầu vào cũng có hai loại: không có trích cạnh và có trích cạnh. Tuy nhiên, với dữ liệu trích cạnh thì luận án xem xét dùng hai phương pháp trích cạnh: Canny và DexiNed. Trong hướng tiếp cận này, luận án xem xét kết quả phân loại của các mặt phẳng thông tin và kết hợp các kết quả dựa vào phương pháp voting mềm để có quyết định cuối cùng.

Với kết quả các nghiên cứu, luận án chỉ ra phương pháp phát hiện bất thường bằng phương pháp học sâu, phương pháp học sâu dùng dữ liệu là ảnh các đoạn mạch vành sau phân đoạn và được trích cạnh bằng phương pháp học sâu sẽ cho kết quả tốt nhất. Điều này hứa hẹn những nghiên cứu sau có thể cho kết quả được ứng dụng vào tực tế. Các kết quả nghiên cứu của luận án đã được công bố 02 bài báo khoa học trên tạp chí Scopus [CT3] và SCIE [CT1] và một bài hội nghị quốc tế thuộc IEEE [CT5].

CHƯƠNG 5 KẾT LUẬN VÀ HƯỚNG PHÁT TRIỂN

5.1 Kết luận

Luận án đã hoàn thành được mục tiêu đặt ra giải quyết hai bài toán với các đề xuất phương pháp giải quyết mới:

- Phân đoạn mạch vành để làm cơ sở để giải quyết bài toán;
- Phát hiện bất thường trên mạch vạch (nếu có).

Bài toán đầu tiên, luận án đã đề xuất hướng tiếp cận từ thô đến mịn trên cơ sở các mô hình học sâu khác nhau để giải quyết cho bài toán phân đoạn đối tượng với loại dữ liệu phức tạp có kích thước đối tượng biến động, các đối tượng có chồng chéo lên nhau, độ tương phản các đối tượng khác nhau, tính chất nền phức tạp, nhiều nhiễu, và các yếu tố khác …; từ ý tưởng này luận án đã phân đoạn thành công mạch vành với dữ liệu rất phức tạp và kích thước mạch vành biến động (cùng là một đối tượng nhưng ở vị trí khác nhau sẽ có kích thước khác nhau và tính chất khác nhau), cũng như vị trí phức tạp và nền rất phức tạp so với các loại dữ liệu khác. Ý tưởng từ thô đến mịn với hai mô hình Unet đã cho kết quả khá tốt, với Unet là một mô hình học sâu hiệu quả cho ảnh y khoa.

Từ kết quả phân đoạn này, luận án đã đề xuất hai hướng tiếp cận để giải quyết bài toán phát hiện bất thường trên đoạn mạch vành (nếu có):

- Hướng tiếp cận xây dựng thuật toán duyệt cạnh dựa trên sự biến đổi hướng, cũng như độ dốc của hướng để quyết định đoạn mạch có bất thường hay không, vùng bất thường có thể là bị hẹp hay bị phình? Hướng tiếp cận này đã xem xét dữ liệu đầu vào là đoạn mạch đã được phân đoạn: chưa trích cạnh và được trích cạnh.
- Hướng tiếp cận học sâu, trong hướng tiếp cận này luận án xây dựng mô hình CNN với dữ liệu đầu vào là đoạn mạch đã được phân đoạn: chưa trích cạnh và được trích cạnh. Để trích cạnh luận án sử dụng hai phương pháp: truyền thống

– Canny và học sâu – DexiNed. Ngoài ra, luận án cũng xem xét dùng các mặt phẳng thông tin để phát hiện bất thường trên đoạn mạch vành thông qua phương pháp voting mềm để kết hợp kết quả của các mặt phẳng thông tin với dữ liệu đầu vào là các đoạn mạch chưa phân đoạn.

Luận án đạt được một số ý nghĩa khoa học cụ thể như sau:

- Đề xuất phương pháp cho bài toán phân đoạn mạch vành với hướng tiếp cận từ thô đến mịn cho các mô hình học sâu, cụ thể hai mô hình học sâu ở đây là Unet main và Unet branch [CT2]. Mỗi mô hình sẽ học được những đặc tính của mạch chính và mạch nhánh thứ cấp.
- Đề xuất và xây dựng thuật toán duyệt cạnh (mới) để phát hiện vùng bất thường (nếu có) trên thành đoạn mạch vành đã phân đoạn [CT3] dựa trên sự biến đổi của độ dốc của cạnh.
- Đề xuất cải tiến hướng tiếp cận thuật toán với dữ liệu đầu vào là đoạn mạch vành được trích cạnh. Cạnh đoạn mạch vành được trích bằng hai phương pháp: truyền thống và học sâu [CT5] nhằm tăng thông tin trên cạnh bằng giảm nhiễu.
- Đề xuất phương pháp phát hiện vùng bất thường trên thành đoạn mạch vành đã được phân đoạn với mô hình học sâu [CT3].
- Đề xuất cải tiến hướng tiếp cận học sâu cho phát hiện vùng bất thường trên thành đoạn mạch vành với dữ liệu đầu vào là đoạn mạch đã được phân đoạn rồi sẽ trích cạnh. Cạnh đoạn mạch vành được trích bằng hai phương pháp: truyền thống và học sâu [CT5].
- Đề xuất phương pháp phát hiện vùng bất thường trên thành đoạn mạch vành với mô hình học sâu kết hợp phương pháp voting mềm cho dữ liệu là các mặt phẳng thông tin của ảnh đoạn mạch vành chưa phân đoạn [CT1].

Về ý nghĩa thực tiễn thì kết quả của luận án có thể làm tiền đề với hướng tiếp cận hợp lý cho các nhóm nghiên cứu có trang thiết bị tốt để có thể tăng mức độ chính xác cao hơn nữa. Bước đầu bác sĩ có thể dùng để tham khảo nhanh cho các chẩn đoán.

Các kết quả của luận án đã được các chuyên gia hỗ trợ đánh giá, kiểm tra tính hợp lệ, đúng đắn.

5.2 Hướng phát triển của luận án

Bài toán phân đoạn mạch vành và phát hiện bất thường trên mạch vành còn rất nhiều thách thức, vì đây là bài toán khác phức tạp đồng thời dữ liệu không nhiều. Luận án cũng chỉ là những bước đầu nghiên cứu. Trong các nghiên cứu tiếp theo, tác giả sẽ tập trung và các nội dung sau:

- Phối hợp với các trung tâm y khoa có uy tín thu thập thêm dữ liệu để có thể tiến hành triển khai thực tế.
- Phối hợp với các chuyên gia nhằm tích hợp tri thức chuyên ngành vào mô hình phân đoạn sao cho có kết quả tốt hơn nữa để làm tiền đề cho việc phân loại nhanh mạch vành có bất thường hay không; ví dụ như xem xét bản đồ đặc trưng của ảnh đoạn mạch vành làm dữ liệu đầu vào.
- Xem xét phương án tiền xử lý với đa phương pháp thích nghi cho nhiều tình huống dữ liệu khác nhau.

DANH MỤC CÔNG TRÌNH CỦA TÁC GIẢ

Bài báo đăng trong tạp chí SCIE

[CT1] Le Nhi Lam Thuy, Vo Hoang Trong, Huynh Trung Hieu, Pham The Bao, "Detection of Abnormality in Coronary Artery Magnetic Resonance Imaging using Bit Plane Slicing and Deep Learning," *Current Medical Imaging*, vol. 20, pp. 1-12, 2024. http://dx.doi.org/10.2174/0115734056252243231025113221, Q3, IF = 1.315.

[CT2] Le Nhi Lam Thuy, Tan Dat Trinh, Le Hoang Anh, Jin Young Kim, Huynh Trung Hieu, and Pham The Bao, "Coronary Vessel Segmentation by Coarse-to-Fine Strategy using U-Nets," *BioMed Research International*, vol. 2021, 2021. https://doi.org/10.1155/2021/5548517, Q2, IF = 3.246 (2023).

Bài báo đăng tạp chí Scopus

[CT3] Le Nhi Lam Thuy, Tran Vi Van, Quang Ngoc Trieu, Le Huu Uyn, Nguyen Ngoc Tuan, Tang Thi Phuong Linh, Pham The Bao, "The Comparing of Two Approaches for Detecting and Locating Abnormalities on Coronary Artery Images," *International Journal of Intelligent Information and Database Systems*, vol. 15, no. 3, pp. 341 – 352, 2022. https://doi.org/10.1504/IJIIDS.2022.124092, Q3.

Bài báo đăng tạp chí trong nước

[CT4] Le Nhi Lam Thuy, Vu Ngoc Thanh Sang, Huynh Trung Hieu, Pham The Bao, "A Survey on Medical Image and Its Segmentation," *Journal on Information Technologies & Communications*, vol. 2022, no. 1, pp. 1-17, 2022. https://doi.org/10.32913/mic-ict-research.v2022.n1.1002.

Bài báo đăng hội nghị quốc tế:

[CT5] Le Nhi Lam Thuy, Ngoc Trieu Quang, Dat Nhan Truong, Pham The Bao, "Detecting Abnormality On Coronary Artery Image By Extracted Edges to Deep Learning*," 2022 IEEE 10th Conference on Systems, Process & Control (ICSPC),* pp. 151-154, 2022. https://doi.org/10.1109/ICSPC55597.2022.10001819.

TÀI LIỆU THAM KHẢO

[1] S. Webb, "The Physis of Medical Imaging (Medical Science Series)," 1988.

[2] Cho Z, Jones JP, Singh M, "Foundtions of medical imaging," 1993.

[3] Ophir J, Céspedes I, Ponnekanti H, Yazdi Y, Li X, "Elastography: a quantitative method for imaging the elasticity of biological tissues," *Ultrasonic Imaging,* vol. 13 (2), pp. 111-134, 1991.

[4] Ganguly, D., Chakraborty, S., Balitanas, M., Kim, Th., "Medical Imaging: A Review," *In: Kim, Th., Stoica, A., Chang, RS. (eds) Security-Enriched Urban Computing and Smart Grid. SUComS 2010. Communications in Computer and Information Science,* vol. 78, Springer, 2010.

[5] A. Medl, "Time Frequency and Wavelets in Biomedical Signal Processing," *IEEE Engineering in Medicine and Biology Magazine,* vol. 17, no. 6, pp. 15-97, 1998.

[6] Ifeanyichukwu Ogobuiro, Chase J. Wehrle, Faiz Tuma., in *Anatomy, Thorax, Heart Coronary Arteries*, StatPearls Publishing, 2023.

[7] Zuluaga, Maria, "Methods for automation of vascular lesions detection in computed tomography images," *PhD. Diseertation, Human health and pathology. Universit´e Claude Bernard - Lyon I; Universit´e des Ande,* 2011.

[8] John B. West, "The beginnings of cardiac catheterization and the resulting impact on pulmonary medicine," *American Journal of Physiology Lung Cellular and Molecular Physiology,* vol. 313(4), pp. L651-L658, 2017.

[9] Adriana DM Villa, Eva Sammut, Arjun Nair, Ronak Rajani, Rodolfo Bonamini, and Amedeo Chiribiri, "Coronary artery anomalies overview: The normal and the abnormal," *World Journal Radiol,* vol. 8(6), pp. 537-555, 2016.

[10] Popov, M., Amanturdieva, A., Zhaksylyk, N. et al., "Dataset for Automatic Region-based Coronary Artery Disease Diagnostics Using X-Ray Angiography Images.," *Sci Data 11,* 20 (2024). https://doi.org/10.1038/s41597-023-02871-z.

[11] Mukesh M. Goswami, Bhavika B. Panara, Suman K. Mitra and Archana N. Vyas, "A contour-based thinning algorithm with post-processing using auto-encoder," *International Journal of Applied Pattern Recognition,* vol. 7, no. 2, 2023.

[12] L. Lam, S. . -W. Lee and C. Y. Suen, "Thinning methodologies-a comprehensive survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence,* vol. 14, no. 9, pp. 869-885, 1992.

[13] T. Y. Zhang and C. Y. Sue, "A Fast Parallel Algorithm for Thinning Digital Patterns," *Communications of ACM,* vol. 27, no. 3, pp. 236-239, 1984.

[14] P. Bambharolia, "Overview of Convolutional Neural Networks," *International Conference on Academic Research in Engineering and Management,* pp. 25-31, 2017.

[15] Le Lu, Xiaosong Wang, Gustavo Carneiro, Lin Yang, "Deep Learning and Convolutional Neural Networks for Medical Imaging and Clinical Informatics (Advances in Computer Vision and Pattern Recognition)," *1st Edition, Springer,* 2019.

[16] Edward Raff, in *Inside Deep Learning: Math, Algorithms, Models*, Manning Publications, 2022.

[17] Mustapha, A., Mohamed, L., Ali, K, "An Overview of Gradient Descent Algorithm Optimization in Machine Learning: Application in the Ophthalmology Field," *In: Hamlich, M., Bellatreche, L., Mondal, A., Ordonez, C. (eds) Smart Applications and Data Analysis. SADASC 2020. Communications in Computer and Information Science,* vol. 1207. Springer, 2020.

[18] C. Lemaréchal, "Cauchy and the Gradient Method," *Doc Math Extra,* pp. 251-254, 2012.

[19] Courant, R., "Variational methods for the solution of problems of equilibrium and vibrations," *Bulletin of the American Mathematical Society,* vol. 49 (1), pp. 1-23, 1943.

[20] Haskell B. Curry, "The Method of Steepest Descent for Non-linear Minimization Problems," *Quarterly of Applied Mathematics,* vol. 2, no. 3, pp. 258-261, 1944.

[21] B. Polyak, "Introduction to Optimization," *Optimization Software Inc. ,* Publication Division, New York, 2010.

[22] G. P. Akilov and L. V. Kantorovich, *Functional Analysis (2nd ed.),* Pergamon Press (ISBN 0-08-023036-9), 2014.

[23] R. Venkatesan and B. Li, *Convolutional Neural Networks in Visual Computing: A Concise Guide,* CRC Press, 2017.

[24] Josh Patterson and Adam Gibson, *Deep Learning,* O'Reilly Media Inc., 2017.

[25] Ian Goodfellow, Yoshua Bengio, Aaron Courville, "Deep Learning (Adaptive Computation and Machine Learning series)," *The MIT Press,* Illustrated edition, 2016.

[26] A. B. J. W. Wei Di, *Deep Learning Essentials,* O'Reilly, 2018.

[27] C. R. a. T. Nayak, "Cross entropy, dissimilarity measures, and characterizations of quadratic entropy," *IEEE Transactions on Information Theory,* vol. 31, no. 5, pp. 589-593, 1985.

[28] B. S. E. M. Oliver Dürr, "Probabilistic Deep Learning: With Python, Keras and TensorFlow Probability," *The Manning,* 2020.

[29] Diederik P. Kingma and Jimmy Ba, "Adam: A Method for Stochastic Optimization," *The 3rd International Conference for Learning Representations,* 2015.

[30] Ronneberger O., Fischer P., Brox T., "U-Net: Convolutional Networks for Biomedical Image Segmentation," *International Conference on Medical Image Computing and Computer-Assisted Intervention – MICCAI,* vol. 9351, pp. 234-241, Springer, 2015.

[31] Quek, C. Kirbas and F., "A Review of Vessel Extraction Techniques and Algorithms," *ACM Computing Surveys,* vol. 36, no. 2, pp. 81-112, 2004.

[32] Dhawan, A. Sarwal and A., "3-D Reconstruction of Coronary Arteries," *Annual International Conference of the IEEE Engineering in Medicine and Biology Society,* vol. 16, pp. 504-505, 1994.

[33] Tan Dat Trinh, Thieu Bao Tran, Le Nhi Lam Thuy, Ikuko Shimizu, Jin Young Kim, Pham The Bao, "Coronary Vessel Segmentation by Coarse-to-Fine Strategy using Otsu Algorithm and Decimation-Free Directional," *Journal of IKEEE,* vol. 23, no. 2, pp. 557-570, 2019.

[34] Sui Chenxin, Fu Zhuang, Fu Zeyu, Wang Yao, Zhuang Yu, Xie Rongli, Zhao Yanna, Zhang Jun, Fei Jian, "A Novel Method for Vessel Segmentation and Automatic Diagnosis of Vascular Stenosis," *2019 IEEE International Conference on Robotics and Biomimetics (ROBIO),* pp. 918-923, 2019.

[35] K. Y, N. Niki and T. Kumazaki, "An Approach for Detecting Blood Vessel Diseases from Cone-beam CT Image," *International Conference on Image Processing,* vol. 2, pp. 500-503, 1995.

[36] R. Jain, R. Kasturi and B. Schunck, *Machine Vision,* McGraw-Hill, 1995.

[37] Ezquerra, J. O'Brien and N., "Automated Segmentation of Coronary Vessels in Angiographic Image Sequences Utilizing Temporal, Spatial and Structural Constraints," *Proceeding SPIE 2359, Visualization in Biomedical Computing,* 1994.

[38] Song S, Yang J, Ai D, Du C, Huang Y, Song H, Zhang L, Han Y, Wang Y, Frangi AF, "Patch-Based Adaptive Background Subtraction for Vascular Enhancement in X-Ray Cineangiograms," *IEEE Journal of Biomedical and Health Informatics,* vol. 23, no. 6, pp. 2563-2575, 2019.

[39] Ma, Guangkun, Yang, Jinzhu, and Zhao, Hong, "A Coronary Artery Segmentation Method Based on Region Growing with Variable Sector Search Area," *Technology and Health Care,* vol. 28, pp. 463-472, 2020.

[40] Terzopoulos, T. McInerney and D., "Deformable Models in Medical Image Analysis: A Survey," *Medical Image Analysis,* vol. 1, no. 2, pp. 91-108, 1996.

[41] D. Rueckert, P. Burger, S. Forbat, R. Mohiaddin and G. Yang, "Automatic Tracking of the Aorta in Cardiovascular MR Images Using Deformable

Models," *IEEE Transactions on Medical Imaging,* vol. 16, no. 5, pp. 581-590, 1997.

[42] R. Chan, W. Kari and R. Lees, "A New Model-Based Technique for Enhanced Small-Vessel Measurements in X-Ray Ciné-Angiograms," *IEEE Transactions on Medical Imaging,* no. 3, pp. 243-255, 2000.

[43] C. Pellot, A. Herment, M. Sigelle, P. Horain, H. Maitre and P. Peronneau, "A 3D Reconstruction of Vascular Structures from Two X-Ray Angiograms Using an Adapted Simulated Annealing Algorithm," *IEEE Transactions on Medical Imaging,* vol. 13, no. 1, pp. 46-80, 1994.

[44] Shuang Song, Chenbing Du, Ying Chen, Danni Ai, Hong Song, Yong Huang, Yongtian Wang and Jian Yang, "Inter/intra-frame constrained vascular segmentation in X-ray angiographic image sequence," *BMC Medical Informatics and Decision Making,* vol. 19, 2019.

[45] Stansfield, S., "ANGY: A Rule-Based Expert System for Automatic Segmentation of Coronary Vessels From Digital Subtracted Angiograms," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-8, no. 2, pp. 188-199, 1996.

[46] Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, Thomas Unterthiner, Mostafa Dehghani, Matthias Minderer, Georg Heigold, Sylvain Gelly, Jakob Uszkoreit, Neil Houlsby, "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," *9th International Conference on Learning,* 2021.

[47] Le Nhi Lam Thuy, Tan Dat Trinh, Le Hoang Anh, Jin Young Kim, Huynh Trung Hieu, and Pham The Bao, "Coronary Vessel Segmentation by Coarse-to-Fine Strategy using U-Nets," *BioMed Research International,* vol. 2021, 2021.

[48] Zhanchao Xian, Xiaoqing Wang, Shaodi Yan, Dahao Yang, Junyu Chen, and Changnong Peng, "Main Coronary Vessel Segmentation Using Deep Learning in Smart Medical," *Mathematical Problems in Engineering,* vol. 2020, 2020.

[49] Su Yang, Jihoon Kweon, Jae-Hyung Roh, Jae-Hwan Lee, Heejun Kang, Lae-Jeong Park, Dong Jun Kim, Hyeonkyeong Yang, Jaehee Hur, Do-Yoon Kang, Pil Hyung Lee, Jung-Min Ahn, Soo-Jin Kang, Duk-Woo Park, Seung-Whan

Lee, Young-Hak Kim, Cheol Whan Lee, Seong-Wo, "Deep learning segmentation of major vessels in X-ray coronary angiography," *Scientific Reports, Nauture,* 2019.

[50] Seung Yeon Shin, Soochahn Lee, Il Dong Yun, Kyoung Mu Lee, "Deep vessel segmentation by learning graphical connectivity," *Image Image Analysis,* vol. 58, 2019.

[51] Bin Kong, Xin Wang, Junjie Bai, Yi Lu, Feng Gao, Kunlin Cao, Jun Xia, Qi Song,Youbing Yin, "Learning tree-structured representation for 3D coronary arterysegmentation," *Computerized Medical Imaging and Graphics,* vol. 80, 2020.

[52] Jingfan Fan, Jian Yang, Yachen Wang, Siyuan Yang, Danni Ai, Yong Huang, Hong Song, Aimin Hao, And Yongtian Wang, "Multichannel Fully Convolutional Network for Coronary Artery Segmentation in X-Ray Angiograms," *IEEE Access,* vol. 6, pp. 44635-44643, 2018.

[53] Jingyang Zhang, Guotai Wang, Hongzhi Xie, Shuyang Zhang, Ning Huang, Shaoting Zhang, Lixu Gu, "Weakly Supervised Vessel Segmentation in X-ray Angiograms by Self-Paced Learning from Noisy Labels with Suggestive Annotation," *Neurocomputing,* vol. 417, pp. 114-127, 2020.

[54] Shaoyan Xia, Haogang Zhu, Xiaoli Liu, Ming Gong, Xiaoyong Huang, Lei Xu, Hongjia Zhang and Jialong Guo, "Vessel Segmentation of X-Ray Coronary Angiographic Image Sequence," *IEEE Transactions on Biomedical Engineering,* vol. 67, no. 5, pp. 1338-1348, 2020.

[55] Kritika Iyer, Cyrus P. Najarian, Aya A. Fattah, Christopher J. Arthurs, S. M. Reza Soroushmehr, Vijayakumar Subban, Mullasari A. Sankardas, Raj R. Nadakuditi, Brahmajee K. Nallamothu & C. Alberto Figueroa, "AngioNet: a convolutional neural network for vessel segmentation in X-ray angiography," *Scientific Reports,* vol. 11, 2021.

[56] Y. Shen, Z. Fang, Y. Gao, N. Xiong, C. Zhong and X. Tang, "Coronary Arteries Segmentation Based on 3D FCN With Attention Gate and Level Set Function," *IEEE Access,* vol. 7, pp. 42826-42835, 2019.

[57] Tao Wan, Jianhui Chen, Zhonghua Zhang, Deyu Li, Zengchang Qin, "Automatic vessel segmentation in X-ray angiogram using spatio-temporal fully-convolutional neural network," *Biomedical Signal Processing and Control,* vol. 68, 2021.

[58] S. Mulay, K. Ram, B. Murugesan and M. Sivaprakasam, "Style Transfer based Coronary Artery Segmentation in X-ray Angiogram," *2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW),* pp. 3386-3394, 2021.

[59] Zijun Gao, Lu Wang, Reza Soroushmehr, Alexander Wood, Jonathan Gryak, Brahmajee Nallamothu & Kayvan Najarian, "Vessel segmentation for X-ray coronary angiography using ensemble methods with deep learning and filter-based features," *BMC Med Imaging,* vol. 22, 2022.

[60] Zhao, C., Bober, R., Tang, H., Tang, J., Dong, M., Zhang, C., He, Z., Esposito, M. L., Xu, Z., Zhou, W., "Semantic Segmentation to Extract Coronary Arteries in Invasive Coronary Angiograms," *Journal of Advances in Applied & Computational Mathematics,* vol. 9, pp. 76-85, 2022.

[61] Caixia Dong, Songhua Xu, Duwei Dai, Yizhi Zhang, Chunyan Zhang, Zongfang Li, "A novel multi-attention, multi-scale 3D deep network for coronary artery segmentation"," *Medical Image Analysis,* vol. 85, 2023.

[62] Nannini G, Saitta S, Baggiano A, Maragna R, Mushtaq S, Pontone G, Redaelli A, "A fully automated deep learning approach for coronary artery segmentation and comprehensive characterization," *APL Bioengineering,* vol. 8, 2024.

[63] Internet, "Sketup Software", [Online]. Available: https://www.sketchup.com.

[64] M.A.K.Y.L.S a K.T.T.T.Phan, "Vessel enhancement filter using directional filter bank," *Computer Vision and Image Understanding,,* vol. 113, no. 1, pp. 101-112, 2009.

[65] F. Cervantes-Sanchez, I. Cruz-Aceves and A. Hernandez-Aguirre, "Automatic detection of coronary artery stenosis in X-ray angiograms using Gaussian filters and genetic algorithms," *AIP conference proceedings,* vol. 1747, no. 020005, 2016.

[66] I. Cruz-Aceves, F. Cervantes-Sanchez and A. Hernandez-Aguirre, "Automatic detection of coronary artery stenosis using Bayesian classification and Gaussian filters based on differential evolution," *Hybrid Intelligence for Image Analysis and Understanding,* pp. 369-390, 2017.

[67] Sankaran, S., Schaap, M., Hunley, S.C., Min, J.K., Taylor, C.A., Grady, L., "HALE: Healthy Area of Lumen Estimation for Vessel Stenosis Quantification," *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2016. Lecture Notes in Computer Science,* vol. 9902. Springer, 2016.

[68] Tao Wan, Hongxiang Feng, Chao Tong, Deyu Li, Zengchang Qin, "Automated identification and grading of coronary artery stenoses with X-ray angiography," *Computer Methods and Programs in Biomedicine,* vol. 167, pp. 13-22, 2018.

[69] Sui Chenxin, Fu Zhuang, Fu Zeyu, Wang Yao, Zhuang Yu, Xie Rongli, Zhao Yanna, Zhang Jun, Fei Jian, "A Novel Method for Vessel Segmentation and Automatic Diagnosis of Vascular Stenosis," *2019 IEEE International Conference on Robotics and Biomimetics (ROBIO),* pp. 918-923, 2019.

[70] M. A. Gil-Rios, I. Guryev, J. M. Lopez-Hernandez and I. Cruz-Aceves, "Automatic Classification of Coronary Stenosis using Feature Selection and Boltzmann-Univariate Marginal Distribution Algorithm," *2021 International Conference on Computational Science and Computational Intelligence (CSCI),* pp. 1600-1605, 2021.

[71] Karol Antczak and Łukasz Liberadzki, "Stenosis Detection with Deep Convolutional Neural Networks," *22nd International Conference on Circuits, Systems, Communications and Computers (C)SCC 2018,* vol. 210, 2018.

[72] Chao Cong, Yoko Kato, Henrique Doria Vasconcellos, Joao Lima, Bharath Venkatesh, "Automated Stenosis Detection and Classification in X-ray Angiography Using Deep Neural Network," *2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM),* pp. 1301-1308, 2019.

[73] Ovalle-Magallanes, Emmanuel, Juan Gabriel Avina-Cervantes, Ivan Cruz-Aceves, and Jose Ruiz-Pinales., "Transfer Learning for Stenosis Detection in X-ray Coronary Angiography," *Mathematics,* vol. 8, no. 9, 2020.

[74] Wei Wu, Jingyang Zhang, Hongzhi Xie, Yu Zhao, Shuyang Zhang, Lixu Gu, "Automatic detection of coronary artery stenosis by convolutional neural network with temporal constraint," *Computers in Biology and Medicine,* vol. 118, 2020.

[75] Chen Zhao, Aviral Vij, Saurabh Malhotra, Jinshan Tang, Haipeng Tang, Drew Pienta, Zhihui Xu, Weihua Zhou, "Automatic extraction and stenosis evaluation of coronary arteries in invasive coronary angiograms," *Computers in Biology and Medicine,* vol. 136, 2021.

[76] Jong Hak Moon, Da Young Lee, Won Chul Cha, Myung Jin Chung, Kyu-Sung Lee, Baek Hwan Cho, Jin Ho Choi, "Automatic stenosis recognition from coronary angiography using convolutional neural networks," *Computer Methods and Programs in Biomedicine,* vol. 198, 2021.

[77] Ovalle-Magallanes E., Alvarado-Carrillo D. E., Avina-Cervantes J. G., Cruz-Aceves I., Ruiz-Pinales J., & Contreras-Hernandez J. L., "Attention Mechanisms Evaluated on Stenosis Detection using X-ray Angiography Images," *Journal of Advances in Applied & Computational Mathematics,* vol. 9, pp. 62-75, 2022.

[78] Emmanuel Ovalle-Magallanes, Juan Gabriel Avina-Cervantes, Ivan Cruz-Aceves, Jose Ruiz-Pinales, "Improving convolutional neural network learning based on a hierarchical bezier generative model for stenosis detection in X-ray images," *Computer Methods and Programs in Biomedicine,* vol. 219, 2022.

[79] A.H. Nandhu Kishore and VE. Jayanthi, "Automatic stenosis grading system for diagnosing coronary artery disease using coronary angiogram," *Int. J. Biomedical Engineering and Technolog,* vol. 31, no. 3, 2019.

[80] Kun Pang, Danni Ai, Huihui Fang, Jingfan Fan, Hong Song, Jian Yang, "Stenosis-DetNet: Sequence consistency-based stenosis detection for X-ray coronary angiography," *Computerized Medical Imaging and Graphics,* vol. 89, 2021.

[81] Algarni M, Al-Rezqi A, Saeed F, Alsaeedi A, Ghabban F., "Multi-constraints based deep learning model for automated segmentation and diagnosis of

coronary artery disease in X-ray angiographic images," *PeerJ Computer Science,* 2022.

[82] K. Kavipriya and Manjunatha Hiremath, "Identification of coronary artery stenosis based on hybrid segmentation and feature fusion," *Journal for Control, Measurement, Electronics, Computing and Communications,* vol. 64, no. 3, pp. 622-633, Taylor & Francis. 2023.

[83] Wahab Sait, Abdul Rahaman, and Ashit Kumar Dutta, "Developing a Deep-Learning-Based Coronary Artery Disease Detection Technique Using Computer Tomography Images," *Diagnostics,* vol. 3, no. 7, 2023.

[84] Michał Jungiewicz, Piotr Jastrzębski, Piotr Wawryka, Karol Przystalski, Karol Sabatowski, Stanisław Bartuś, "Vision Transformer in stenosis detection of coronary arteries," *Expert Systems with Applications,* vol. 228, 2023.

[85] Canny, J., "A Computational Approach to Edge Detection," *IEEE Transactions on Pattern Analysis and Machine Intelligence,* Vols. PAMI-8, no. 6, pp. 679-698, 1986.

[86] X. Soria, E. Riba and A. Sappa, "Dense Extreme Inception Network: Towards a Robust CNN Model for Edge Detection," *2020 IEEE Winter Conference on Applications of Computer Vision (WACV),* vol. Snowmass, pp. 1912-1921, 2020.

[87] Rafael C. Gonzalez and Richard E. Woods, in *Digital Image Processing*, Fourth Edition, Pearson Education Limited, 2018.

[88] G. V. Vlăsceanu, R. -M. Paraschiv, C. Artene and C. -A. Boiangiu, "Voting-based edge detection," *2019 18th RoEduNet Conference: Networking in Education and Research (RoEduNet), Galati, Romania,* pp. 1-5, 2019.

[89] Armin Arbab-Zadeh and John Hoe, "Quantification of Coronary Arterial Stenoses by Multidetector CT Angiography in Comparison with Conventional Angiography: Methods, Caveats, and Implications," *JACC: Cardiovascular Imaging,* vol. 4, no. 2, pp. 191-202, 2011.