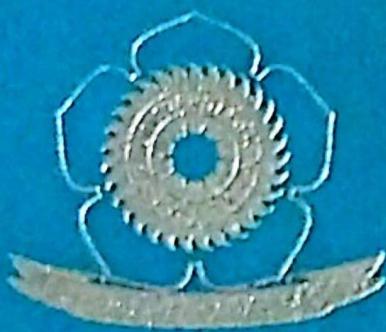


DISERTASI
(TEK 010317)

*PREPROCESSING STENOSIS ARTERI KORONER
DAN PENGEMBANGAN MODEL CONVOLUTIONAL
NEURAL NETWORK UNTUK IDENTIFIKASI
PENYAKIT JANTUNG KORONER*



Thema : Ahyac Supandi
NIM : 03613622025002
BKO : Teknik Informatika
Promotor : Prof. Dr. Ir. Siti Nurroshim, MT.
Ko-Promotor 1 : Prof. Dr. dr. Radiyati Umi Partan, SpPD-KR, M.Kes
Ko-Promotor 2 : Dr. Ir. Bhakti Yudho Suprapto, S.T., M.T., IPM.

PROGRAM STUDI DOKTOR ILMU TEKNIK
FAKULTAS TEKNIK
UNIVERSITAS SRIWIJAYA
2025

HALAMAN PENGESAHAN
DISERTASI
(TEK 010317)

***PREPROCESSING STENOSIS ARTERI KORONER
DAN PENGEMBANGAN MODEL CONVOLUTIONAL
NEURAL NETWORK UNTUK IDENTIFIKASI
PENYAKIT JANTUNG KORONER***

Oleh:
AHYAR SUPANI
NIM. 03013622025002

Telah disetujui
Pada Tanggal, Agustus 2025

Promotor

Prof. Dr. Ir. Siti Nurmaini, MT
NIP. 196908021994012001

Ko-Promotor 1

Prof. Dr. dr. Radiyati Umi
Partan, SpPD-KR, M.Kes
NIP. 197207172008012007

Ko-Promotor 2

Dr. Ir. Bhakti Yudho
Suprapto, S.T., M.T., IPM.
NIP. 197502112003121002



Dr. Ir. Bhakti Yudho Suprapto, S.T., M.T., IPM.
NIP. 197502112003121002

Mengetahui,



Koordinator Program Studi
Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

HALAMAN PERSETUJUAN

Disertasi berjudul "*Preprocessing Stenosis Arteri Koroner dan Pengembangan Model Convolutional Neural Network untuk Identifikasi Penyakit Jantung Koroner*" telah dipresentasikan di hadapan Tim Pengaji Disertasi pada Program Studi Doktor Ilmu Teknik Fakultas Teknik Universitas Sriwijaya pada hari Senin, tanggal 25 Agustus, tahun 2025.

Palembang, 25 Agustus 2025

Tim Pengaji Disertasi berupa Disertasi:

Ketua Tim Pengaji:

Nama: Ir. Irsyadi Yani, ST. M.Eng., Ph.D. IPM.

NIP : 197112251997021001

Anggota Tim Pengaji:

1. Nama : Prof. Dr. Ir. Bambang Tutuko, M.T.

NIP : 196001121989031002

2. Nama : Dr. Firdaus, ST., M. Kom.

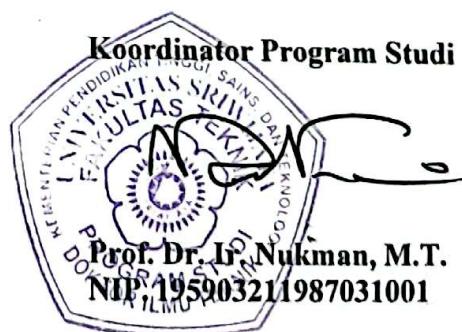
NIP : 197801212008121003

3. Nama : Dr. Nyayu Latifah Husni, ST., MT.

NIP : 197605032001122000

()
( 19/9/2025)
()
()

Mengetahui,



SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Ahyar Supani
NIM : 03013622025002
Program Studi : Doktor Ilmu Teknik
BKU : Teknik Informatika

Dengan ini menyatakan bahwa disertasi saya dengan judul "Preprocessing Stenosis Arteri Koroner dan Pengembangan Model Convolutional Neural Network untuk Identifikasi Penyakit Jantung Koroner", bebas dari fabrikasi, falsifikasi, plagiat, kepengarangan yang tidak sah dan konflik kepentingan dan pengajuan jamak, seperti yang tercantum dalam Peraturan Menteri Pendidikan, Kebudayaan, Riset, dan Teknologi Republik Indonesia Nomor 39 Tahun 2021.

Bilamana ditemukan ketidak sesuaian dengan hal-hal di atas, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai dengan aturan yang berlaku.

Demikian pernyataan ini dibuat dengan sesungguhnya dan dengan sebenarnya.

Palembang, Agustus 2025

Yang menyatakan



Ahyar Supani

NIM. 03013622025002

ABSTRAK

Penerapan kecerdasan buatan di bidang kesehatan menunjukkan perkembangan pesat, terutama dalam mendukung diagnosis penyakit jantung koroner (CAD). Dalam praktik klinis, penilaian tingkat keparahan penyempitan (stenosis) arteri koroner melalui *X-ray Coronary Angiography* (XCA) dari prosedur kateterisasi umumnya menggunakan *Physician Visual Assessment* (PVA). Metode ini menentukan rasio stenosis signifikan (abnormal) atau tidak signifikan (normal), tetapi dinilai kurang akurat, memakan waktu, serta menuntut keahlian tinggi karena ukuran arteri yang sangat kecil, sehingga berpotensi menimbulkan kesalahan. Kajian otomatis berbasis deep learning telah dikembangkan, namun performanya belum memenuhi standar klinis. Untuk mengatasi keterbatasan tersebut, penelitian disertasi ini mengusulkan peningkatan performa segmentasi otomatis melalui preprocessing area stenosis dengan metode *cropping-scaling*, yang diuji pada empat arsitektur segmentasi, yaitu SegNet, ResNet34, UNet, dan Residual UNet. Selain itu, dilakukan pengembangan model klasifikasi dengan memodifikasi lapisan rekayasa fitur CNN (CNN-Plus). Dataset berasal dari dua rumah sakit di Palembang, Indonesia. Data segmentasi mencakup 1.400 citra stenosis (700 abnormal, 700 normal), sedangkan data klasifikasi terdiri atas 472 kasus stenosis (247 abnormal, 225 normal). Evaluasi dilakukan menggunakan metrik akurasi, intersection over union (IoU), presisi, recall, dan F1-score. Eksperimen segmentasi menunjukkan Residual UNet sebagai model terbaik dengan peningkatan akurasi 0,22%, IoU 38,75%, presisi 87,82%, recall 85,89%, dan F1-score 86,78%. Sementara itu, pada klasifikasi, CNN-Plus memberikan peningkatan akurasi 2,85%, IoU 5,24%, recall 6,76%, dan F1-score 2,95%, meskipun terjadi sedikit penurunan presisi 0,86%. Temuan ini menegaskan bahwa pendekatan berbasis CNN berpotensi meningkatkan akurasi diagnosis dan mendukung evaluasi stenosis koroner secara otomatis, sehingga berkontribusi positif terhadap perawatan pasien dengan penyakit jantung koroner.

Kata kunci: *Convolutional Neural Network*, Penyakit Jantung Koroner, *x-ray coronary angiography*, stenosis arteri koroner.

ABSTRACT

The application of artificial intelligence in healthcare has shown rapid progress, particularly in supporting the diagnosis of coronary artery disease (CAD). In clinical practice, the assessment of coronary artery stenosis severity using X-ray Coronary Angiography (XCA) from catheterization procedures is commonly performed through Physician Visual Assessment (PVA). This method determines the stenosis ratio as either significant (abnormal) or non-significant (normal). However, it is considered less accurate, time-consuming, and highly dependent on expertise due to the very small size of the arteries, thereby increasing the risk of misinterpretation. Although deep learning-based automated approaches have been developed, their performance has not yet met clinical standards. To address these limitations, this dissertation proposes enhancing the performance of automatic segmentation through stenosis area preprocessing using a cropping-scaling method, evaluated on four segmentation architectures: SegNet, ResNet34, UNet, and Residual UNet. In addition, an automatic classification model was developed by modifying the feature engineering layers of CNN (CNN-Plus). The dataset was obtained from two hospitals in Palembang, Indonesia. The segmentation dataset consisted of 1,400 stenosis images (700 abnormal and 700 normal), while the classification dataset included 472 stenosis cases (247 abnormal and 225 normal). Model performance was evaluated using accuracy, intersection over union (IoU), precision, recall, and F1-score metrics. Segmentation experiments demonstrated that Residual UNet achieved the best performance, with improvements of 0.22% in accuracy, 38.75% in IoU, 87.82% in precision, 85.89% in recall, and 86.78% in F1-score. For classification, CNN-Plus yielded performance gains on the test data with an increase of 2.85% in accuracy, 5.24% in IoU, 6.76% in recall, and 2.95% in F1-score, despite a slight decrease of 0.86% in precision. These findings highlight the potential of CNN-based approaches to improve diagnostic accuracy and support automated evaluation of coronary stenosis, thereby contributing positively to patient care in coronary artery disease.

Keywords: Convolutional Neural Network, Coronary Artery Disease, X-ray Coronary Angiography, Coronary Artery Stenosis.

KATA PENGANTAR

Segala puji dan syukur penulis panjatkan ke hadirat Allah SWT atas limpahan rahmat, taufik, dan hidayah-Nya sehingga penulis dapat menyelesaikan disertasi yang berjudul "*Preprocessing Stenosis Arteri Koroner dan Pengembangan Model Convolutional Neural Network untuk Identifikasi Penyakit Jantung Koroner*", sebagai salah satu syarat untuk meraih gelar Doktor Ilmu Teknik. Karya ini merupakan hasil dari proses panjang, mulai dari penentuan topik, perumusan masalah, hingga penyempurnaan metodologi penelitian. Pencapaian ini tidak terlepas dari bimbingan, arahan, serta dukungan berbagai pihak yang telah memberikan kontribusi selama pelaksanaan penelitian hingga penyusunan disertasi ini.

Dengan penuh hormat, penulis menyampaikan terima kasih yang sebesar-besarnya kepada Ibu Prof. Dr. Ir. Siti Nurmaini, M.T. selaku Promotor, serta Ibu Prof. Dr. dr. Radiyati Umi Partan, SpPD-KR, M.Kes. dan Dr. Ir. Bhakti Yudho Suprapto, S.T., M.T., IPM selaku Ko-Promotor, atas segala bimbingan, arahan, koreksi, dan semangat yang senantiasa diberikan sepanjang proses studi. Ucapan terima kasih juga penulis sampaikan kepada para anggota dewan pengaji, yaitu Prof. Dr. Ir. Bambang Tutuko, M.T., Dr. Firdaus, S.T., M.Kom., dan Dr. Nyayu Latifah Husni, S.T., M.T., atas masukan serta penilaian yang sangat berarti bagi penyempurnaan karya ini.

Penghargaan yang tulus penulis berikan kepada Bapak Prof. Dr. Ir. Nukman, M.T. selaku Ketua Program Studi Doktor Ilmu Teknik, beserta seluruh tim pengelola, dosen pengajar, tim pengaji, dan staf akademik Program Studi Doktor Ilmu Teknik yang telah memberikan dukungan, baik secara akademik maupun administratif, selama penulis menempuh pendidikan doktoral. Ucapan terima kasih setinggi-tingginya penulis sampaikan kepada dr. Alpian, Sp.PD. KKV., atas bantuan, izin, dan validasi terhadap data stenosis arteri koroner dari pasiennya yang sangat berkontribusi pada penyelesaian penelitian disertasi ini.

Apresiasi mendalam juga penulis sampaikan kepada Direktur, para Wakil Direktur, Ketua Jurusan Teknik Komputer Politeknik Negeri Sriwijaya, serta Tim *Intelligent System Research Group*, Universitas Sriwijaya, atas dukungan institusional dan kolaborasi yang sangat berarti dalam pengembangan penelitian ini. Ucapan terima kasih khusus juga ditujukan kepada para sahabat yang menjadi sumber semangat dan diskusi yang membangun, antara lain Bapak Dr. Hadi Saputra, S.Kom., M.Kom., serta rekan seperjuangan Bapak Arius Satoni Kurniawansyah, S.Kom., M.Kom. Selain itu, penulis juga berterima kasih kepada seluruh dosen dan tenaga kependidikan Jurusan Teknik Komputer Politeknik Negeri Sriwijaya atas dukungannya selama penyelesaian studi.

Dengan penuh cinta dan penghargaan, penulis menyampaikan terima kasih yang tak terhingga kepada ibu dan almarhum ayah, istri tercinta Yuli Andriani, anak-anak tercinta Muhammad Rizqulloh Akbar, Muhammad Ihsan Robbani, dan Nabila Nuraisyah Sholihah, serta seluruh keluarga besar yang senantiasa memberikan doa, kesabaran, dan pengertian yang luar biasa selama proses studi dan penyusunan

disertasi ini.

Semoga disertasi ini dapat memberikan kontribusi ilmiah yang bermanfaat dalam pengembangan ilmu pengetahuan dan teknologi, khususnya di bidang kecerdasan buatan untuk identifikasi penyakit jantung koroner berdasarkan citra medis. Penulis menyadari bahwa karya ini masih jauh dari sempurna, namun besar harapan penulis agar dapat menjadi pijakan bagi penelitian lanjutan yang lebih mendalam di masa mendatang.

Palembang, Agustus 2025
Penulis

Ahyar Supani

DAFTAR ISI

	Halaman
Halaman Judul	i
Halaman Pengesahan	ii
Halaman Persetujuan	iii
Surat Pernyataan Bebas Plagiat	iv
Abstrak	v
Abstract	vi
Kata Pengantar	vii
Daftar Isi	ix
Daftar Tabel	xiii
Daftar Gambar	xiv
Daftar Lampiran	xvi
Nomenklatur	xvii
 BAB I PENDAHULUAN	 1
1.1 Latar Belakang Penelitian	1
1.2 Perumusan Masalah	9
1.3 Tujuan Penelitian	9
1.4 Ruang Lingkup	10
1.5 Keterbaruan dan kontribusi	11
1.6 Sistematika Penulisan	13
 BAB II STUDI LITERATUR	 15
2.1 <i>State of the art</i> Penelitian	15
2.2 Penelitian Sejenis	17
2.3 <i>Convolutional Neural Network</i>	22
2.4 <i>Convolutional Layer</i> , Kernel dan Operasinya	23
2.5 <i>Pooling Layer</i>	25
2.6 Fungsi aktivasi	26
2.6.1 <i>Rectified Linear Unit (ReLU)</i>	26
2.6.2 <i>Softmax</i>	27
2.6.3 <i>Sigmoid</i>	28
2.7 <i>Batch Normalization (BN)</i> dan <i>Dropout</i>	29
2.7.1 <i>Batch Normalization</i>	29

2.7.2 <i>Dropout</i>	30
2.8 Fungsi Optimasi AdamW	31
2.9 Fungsi <i>Loss</i>	32
2.10 <i>Fully Connected Layer</i>	33
2.11 Arteri Koroner Jantung	34
2.12 Penyakit Jantung Koroner dan Stenosis	35
2.13 <i>Preprocessing</i> Stenosis	37
2.13.1 <i>Cropping</i>	37
2.13.2 <i>Scaling</i>	38
2.14 Evaluasi Performa Klasifikasi	39
2.15 Pengertian Segmentasi dan Klasifikasi secara umum	41
 BAB III METODOLOGI	44
3.1 Sumber Data Penelitian	44
3.2 Kerangka Kerja Penelitian	45
3.3 Konversi Video ke Citra	48
3.4 Validasi Citra Stenosis	48
3.5 Peningkatan Kualitas Citra	48
3.6 Melakukan <i>Preprocessing</i> Stenosis	48
3.7 Anotasi Stenosis	49
3.7.1 Anotasi Kontur	49
3.7.2 Anotasi Rasio	50
3.8 Pemisahan (<i>split</i>) dataset	50
3.9 Rancangan Arsitektur CNN untuk Identifikasi CAD	51
3.9.1 Rancangan Arsitektur untuk Segmentasi	51
3.9.2 Rancangan Arsitektur untuk Klasifikasi	52
3.10 Eksperimen Model Segmentasi dan Klasifikasi	52
3.10.1 Eksperimen Model Segmentasi	52
3.10.1.1 Eksperimen segmentasi dengan stenosis sebelum <i>cropping-scaling</i>	52
3.10.1.2 Eksperimen segmentasi dengan stenosis setelah <i>cropping-scaling</i>	53
3.10.2 Eksperimen Model Klasifikasi	54
3.10.2.1 Eksperimen Klasifikasi dengan Model CNN Dasar	54

3.10.2.2 Eksperimen Klasifikasi dengan Model CNN-Plus	54
3.11 Evaluasi Hasil	55
BAB IV HASIL DAN PEMBAHASAN	56
4.1 Deskripsi Data	56
4.1.1 Hasil konversi video ke frame citra stenosis	56
4.1.2 Hasil Peningkatan Kualitas Citra XCA	57
4.2 Hasil Preprocessing Stenosis Arteri Koroner	57
4.3 Hasil Anotasi Stenosis	58
4.3.1 Hasil Anotasi Kontur	58
4.3.2 Hasil Anotasi Rasio	59
4.4 Hasil Rancangan Arsitektur	60
4.5 Hasil Eksperimen Model Segmentasi dan Klasifikasi	66
4.5.1 Eksperimen 1: Training Model Segmentasi	66
4.5.1.1 Hasil Pengujian Model Segmentasi Dengan Dataset Kontur Sebelum <i>Cropping-Scaling</i>	67
4.5.1.2 Hasil Pengujian Model Segmentasi Dengan Dataset Kontur Setelah <i>Cropping-Scaling</i>	68
4.5.2 Eksperimen 2: Training Model Klasifikasi	77
4.5.2.1 Hasil Pengujian Model CNN dasar	77
4.5.2.2 Hasil Pengujian Model CNN Plus	78
4.6 Pembahasan	86
4.6.1 Pembahasan Model Segmentasi terhadap <i>cropping-scaling</i> stenosis	86
4.6.2 Pembahasan Model Klasifikasi CNN terhadap Modifikasi Lapisan Rekayasa Fitur	91
BAB V KESIMPULAN	96
5.1 Kesimpulan	96
5.2 Penelitian Selanjutnya	96
DAFTAR PUSTAKA	98
Lampiran A	106
Lampiran B	107

Lampiran C	108
Lampiran D	109
Lampiran E	110
Lampiran F	113
Lampiran G	114
Publikasi artikel di Jurnal ISI Q3		
Surat Keterangan Perbaikan Disertasi		

DAFTAR TABEL

Tabel 2.1. Penelitian sejenis	18
Tabel 2.2. Derajat stenosis dengan diameter luminal	37
Tabel 2.3. Tabel kategori evaluasi kinerja	41
Tabel 3.1. Dataset kontur stenosis untuk <i>training</i> , <i>testing</i> , dan <i>unseen data</i>	51
Tabel 3.2. Dataset rasio stenosis untuk <i>training</i> , <i>testing</i> , dan <i>unseen data</i>	51
Tabel 4.1. Metrik performa 4 model segmentasi sebelum <i>cropping</i> dan <i>scaling</i> stenosis	67
Tabel 4.2. Pengesetan <i>hyperparameter</i> saat <i>training</i> segmentasi untuk 4 arsitektur	69
Tabel 4.3. Metrik performa 4 model segmentasi setelah <i>cropping</i> dan <i>scaling</i> stenosis	69
Tabel 4.4. Metrik performa 4 model segmentasi dengan <i>unseen data</i>	70
Tabel 4.5. Metrik performa 2 model klasifikasi untuk dataset <i>training</i>	79
Tabel 4.6. Metrik performa 2 model untuk dataset <i>testing</i>	79
Tabel 4.7. Metrik performa 2 model untuk <i>unseen data</i>	80
Tabel 4.8. Perbandingan metrik performa model segmentasi pada <i>dataset</i> sebelum dan setelah <i>cropping-scaling</i> , dan kenaikan performa	87
Tabel 4.9. Perbandingan kajian stenosis oleh peneliti lain	94

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Konsep dasar CNN	22
Gambar 2.2. Filter 2D ukuran 2x2	23
Gambar 2.3 Operasi konvolusi 4 langkah	24
Gambar 2.4. Fitur map akhir setelah selesai lengkap konvolusi	25
Gambar 2.5. Grafik fungsi aktivasi ReLU	27
Gambar 2.6. Grafik fungsi <i>softmax</i>	28
Gambar 2.7. Grafik fungsi <i>sigmoid</i>	29
Gambar 2.8. Arsitektur <i>fully connected layer</i>	33
Gambar 2.9. Arteri koroner	35
Gambar 2.10. Arteri koroner dengan stenosis.....	36
Gambar 2.11. Kontur stenosis arteri coroner	36
Gambar 2.12. <i>Confusion matrix</i>	40
Gambar 2.13. Contoh segmentasi stenosis arteri coroner	42
Gambar 3.1. Tahapan-tahapan penelitian	46
Gambar 3.2. Pipeline task segmentasi, klasifikasi stenosisarteri koroner	47
Gambar 3.3. Tahapan persiapan <i>dataset</i>	48
Gambar 4.1. Frame citra stenosis XCA	57
Gambar 4.2. Frame citra stenosis XCA yang difilter	58
Gambar 4.3. <i>Cropping</i> stenosis pada frame 512x512 px ke 100x100 px	58
Gambar 4.4. <i>Upscaling</i> stenosis pada frame 100x100 px ke 512x512 px	58
Gambar 4.5 Penandaan kontur stenosis: a. abnormal, b. normal	59
Gambar 4.6. Hasil anotasi kontur stenosis: a. dan c. tanda kontur, b. dan d. thresholding	59
Gambar 4.7. Anotasi rasio stenosis dalam format csv: (a) abnormal (b) normal ...	60
Gambar 4.8. Arsitektur SegNet	61
Gambar 4.9. Arsitektur Resnet34	62
Gambar 4.10. Arsitektur UNet	63
Gambar 4.11. Arsitektur Residual UNet	64
Gambar 4.12. Arsitektur CNN dasar	65
Gambar 4.13. Pengembangan lapisan arsitektur CNN-Plus	66

Gambar 4.14. Grafik Segnet (a) model akurasi, (b) model loss	71
Gambar 4.15. Grafik Resnet34 (a) model akurasi, (b) model loss	72
Gambar 4.16. Grafik UNet: (a) model akurasi, (b) model loss	74
Gambar 4.17. Grafik Residual UNet: (a) model akurasi, (b) model loss	75
Gambar 4.18. Grafik performa CNN dasar: (a) <i>train/test score</i> (b) <i>train/test cost</i>	81
Gambar 4.19. <i>Confusion matriks</i> untuk CNN dasar	82
Gambar 4.20. Grafik performa CNN-Plus: (a) <i>train/test score</i> (b) <i>train/test cost</i>	84
Gambar 4.21. <i>Confusion matriks</i> untuk CNN-Plus	85

DAFTAR LAMPIRAN

	Halaman
Lampiran A: Filter CLAHE	106
Lampiran B: Filter DENOISE	107
Lampiran C: Upscaling Dengan Metode: <i>Nearest Neighbor Interpolation</i>	108
Lampiran D: Tutorial Segmentasi Dan Thresholding	109
Lampiran E: Source Code Segmentasi, File Nama: labelme2voc.py	110
Lampiran F: Source Code Thresholding, File Nama: thresholding.py	113
Lampiran G: Source Code Nama Label, Filename: labels.txt	114

NOMENKLATUR

ISTILAH	URAIAN
AI	Kecerdasan buatan atau Artificial Intelligence (AI) adalah cabang ilmu komputer yang berfokus pada pengembangan sistem atau mesin yang mampu meniru, mempelajari, dan melakukan tugas-tugas yang biasanya memerlukan kecerdasan manusia, seperti berpikir, mengenali pola, mengambil keputusan, dan memecahkan masalah.
Akurasi	Akurasi adalah salah satu metrik evaluasi dalam statistik, <i>machine learning</i> , maupun deep learning yang menunjukkan tingkat ketepatan model dalam memprediksi data dengan benar dibandingkan dengan keseluruhan data yang diuji.
Anotasi	Proses memberi label, tanda, atau keterangan pada data (misalnya citra, teks, atau video) agar dapat digunakan dalam pelatihan, validasi, atau evaluasi model AI.
AUC	<i>Area Under the Curve</i> (AUC), AUC mengukur kemampuan model klasifikasi dalam membedakan antara kelas positif dan negatif, dengan rentang nilai 0 hingga 1.
CAD	<i>Coronary Artery Disease</i> merupakan penyakit jantung koroner yang terjadi penyempitan (stenosis) pada arteri koroner. CAD dapat juga disebut <i>Myocardial Infarction</i> (MI) dimana otot jantung tidak mendapatkan aliran darah atau <i>Myocardial Ischemic</i> (MI) otot jantung sedikit mendapat aliran darah atau <i>Coronary Heart Disease</i> (CHD) atau <i>Ischemic Heart Disease</i> (IHD).
CAD-RADS	<i>The Coronary Artery Disease-Reporting and Data System</i> (CAD-RADS) merupakan sistem pelaporan terstandar pada CCTA yang mengklasifikasikan tingkat stenosis arteri koroner dari CAD-RADS 0 (tanpa stenosis), CAD-RADS 1 (stenosis minimal <25%), CAD-RADS 2 (stenosis ringan 25–49%), CAD-RADS 3 (stenosis sedang 50–69%), CAD-RADS 4 (stenosis berat 70–99%), hingga CAD-RADS 5 (oklusi total 100%) untuk memandu evaluasi klinis secara konsisten.
CAE	<i>Convolutional Autoencoder</i> (CAE) adalah jenis jaringan saraf

	tiruan yang menggunakan lapisan konvolusi untuk secara otomatis mengekstraksi dan merepresentasikan fitur penting dari data, terutama digunakan untuk kompresi, denoising, dan representasi citra.
CCTA	<i>Coronary Computed Tomography Angiography</i> (CCTA) adalah teknik pencitraan non-invasif yang menggunakan CT scan dan zat kontras untuk memperoleh gambaran detail arteri koroner, sehingga dapat mendeteksi penyempitan atau sumbatan akibat plak maupun penyakit jantung koroner.
CHF	<i>Congestive Heart Failure</i> (CHF) adalah kondisi ketika jantung tidak mampu memompa darah secara efektif untuk memenuhi kebutuhan tubuh, sehingga menyebabkan penumpukan cairan (kongesti) di paru-paru, tungkai, atau bagian tubuh lainnya.
CLAHE	<i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE), digunakan untuk memperbaiki kualitas citra dengan membuat perbedaan intensitas lebih jelas tanpa menimbulkan distorsi berlebihan.
CNN	<i>Convolutional Neural Network</i> merupakan algoritma kecerdasan buatan yang meliputi fitur <i>engineering</i> dan <i>fully connected</i> . CNN sangat populer untuk mengenal citra.
Dataset	<i>Dataset</i> dalam <i>deep learning</i> adalah fondasi utama pembelajaran mesin, karena tanpa data yang cukup dan berkualitas, model <i>deep learning</i> tidak dapat dilatih secara efektif maupun digunakan dalam aplikasi nyata.
Data tabular	<i>Dataset</i> yang berisi tipe data numerik dan kategorik, dalam hal ini data rekam medis pasien yang mengalami CAD
Derajat stenosis	Kategori atau tingkat klasifikasi penyempitan berdasarkan nilai persentase stenosis. Klasifikasi klinis: <50% (ringan), 50–70% (sedang), dan > 70% (berat/signifikan)
DL	<i>Deep Learning</i> (DL) adalah cabang dari machine learning yang menggunakan jaringan saraf tiruan berlapis (deep neural networks) untuk mempelajari representasi data secara otomatis dan melakukan tugas kompleks seperti pengenalan gambar, suara, dan bahasa

DSSD	<i>Deconvolutional Single Shot Multibox Detector (DSSD)</i> merupakan varian SSD berbasis CNN yang dilengkapi lapisan dekonvolusi untuk memperkaya representasi fitur spasial, sehingga mampu mendeteksi lesi stenosis kecil pada citra XCA dengan lebih baik.
EKG	Elektrokardiogram (EKG) adalah suatu pemeriksaan medis non-invasif yang digunakan untuk merekam aktivitas listrik jantung dalam suatu periode waktu. Alat ini mendeteksi impuls listrik yang dihasilkan setiap kali jantung berkontraksi dan menampilkannya dalam bentuk gelombang pada kertas grafik atau monitor.
Ekstraksi garis pusat arteri koroner	Proses menentukan jalur utama (centerline) dari lumen arteri koroner pada citra medis (misalnya CT Coronary Angiography/CTCA atau X-ray Coronary Angiography/XCA)
ICA	<i>Invasive Coronary Angiography</i> (ICA) adalah prosedur diagnostik invasif untuk mengevaluasi kondisi arteri koroner, dengan memasukkan kateter ke dalam pembuluh darah (biasanya melalui arteri femoralis atau radial) dan menyuntikkan zat kontras. Hasilnya direkam menggunakan sinar-X untuk melihat penyempitan (<i>stenosis</i>) atau sumbatan pada arteri koroner.
IoU	<i>Intersection Over Union</i> (IoU) adalah rasio luas irisan (<i>intersection</i>) antara hasil prediksi dengan label sebenarnya dibandingkan dengan luas gabungan (<i>union</i>) keduanya.
FFR	<i>Fractional Flow Reserve</i> (FFR) adalah metode pengukuran invasif yang menilai tingkat keparahan penyempitan arteri koroner dengan membandingkan tekanan darah sebelum dan sesudah stenosis untuk menentukan dampaknya terhadap aliran darah ke jantung.
F1-score	F1-score adalah harmonic mean antara presisi dan recall. F1-score menyeimbangkan presisi dan recall. Nilai tinggi menunjukkan model memiliki keseimbangan baik antara kemampuan menemukan kasus positif dan ketepatan prediksi positifnya. Cocok digunakan pada dataset yang tidak seimbang.
Konsensus CTA	Konsensus CTA (<i>Coronary CT Angiography consensus reading</i>) adalah metode penilaian citra angiografi koroner berbasis CT yang dilakukan oleh dua atau lebih pembaca (biasanya radiolog atau ahli jantung), di mana hasil akhir ditetapkan berdasarkan kesepakatan bersama.

<i>Learning rate (Lr)</i>	Dalam pemodelan <i>deep learning</i> , <i>learning rate</i> (laju pembelajaran) adalah parameter hiper yang menentukan seberapa besar langkah yang diambil model ketika memperbarui bobot (weights) selama proses training menggunakan algoritma optimisasi, misalnya <i>stochastic gradient descent (SGD)</i> atau turunannya. Peran Lr adalah jika terlalu besar , model bisa gagal konvergen karena melompat-lompat melewati titik minimum (<i>overshooting</i>). Jika terlalu kecil, proses training menjadi sangat lambat dan bisa terjebak di <i>local minima</i> . Oleh karena itu, pemilihan <i>learning rate</i> yang tepat sangat penting untuk memastikan model belajar secara efektif dan efisien.
ML	<i>Machine Learning</i> adalah cabang kecerdasan buatan yang memungkinkan sistem belajar dari data dan pengalaman untuk membuat prediksi atau keputusan tanpa diprogram secara eksplisit.
MI	<i>Myocardial Infarction</i> (MI) atau serangan jantung adalah kondisi medis serius yang terjadi ketika aliran darah ke otot jantung terhenti akibat sumbatan pada arteri koroner, sehingga menyebabkan kerusakan atau kematian jaringan otot jantung.
Miokardium <i>left ventricular</i> (LV)	Lapisan otot pada ventrikel kiri jantung. Kondisi ini penting dalam penelitian kardiologi karena fungsi ventrikel kiri sangat berhubungan dengan suplai darah/oksigen ke jaringan tubuh. Penulisan secara ilmiah adalah miokardium LV.
MIMS	<i>Multi-Input Multi-Scale UNet</i> adalah arsitektur deep learning berbasis UNet yang memanfaatkan masukan dari berbagai skala resolusi untuk menangkap detail lokal maupun global, sehingga meningkatkan akurasi dalam segmentasi citra medis.
MPR	<i>Multi-Planar Reformatted</i> (MPR) adalah teknik rekonstruksi citra CT yang menampilkan potongan arteri koroner dari berbagai bidang (aksial, sagital, koronal, atau bidang melengkung), sehingga memudahkan penilaian tingkat stenosis secara lebih akurat.
<i>Patch of stenosis</i>	<i>Patch of stenosis</i> berarti potongan citra yang diambil hanya pada wilayah stenosis agar area target lebih jelas terlihat dibandingkan dengan keseluruhan citra angiografi.

PPV	<i>Positive Predictive Value</i> (PPV) adalah metrik evaluasi yang menunjukkan proporsi deteksi stenosis yang benar-benar positif dibandingkan dengan seluruh hasil deteksi positif oleh model, setara dengan <i>precision</i> dalam <i>machine learning</i> .
Presisi	Presisi adalah proporsi prediksi positif yang benar-benar positif, istilah presisi mempunyai pengertian yang sama dengan <i>Positive Predictive Value</i> (PPV)
PVA	<i>Physician Visual Assessment</i> (PVA) adalah metode penilaian stenosis arteri koroner yang dilakukan oleh dokter (biasanya ahli kardiologi intervensi) dengan cara mengamati langsung hasil angiografi koroner (<i>X-ray Coronary Angiography/XCA</i>) dan kemudian memperkirakan secara visual tingkat penyempitan lumen arteri.
QCA	<i>Quantitative Coronary Angiography</i> (QCA) adalah teknik analisis citra angiografi koroner secara kuantitatif untuk mengukur diameter, panjang, dan tingkat penyempitan (stenosis) arteri koroner secara objektif dan akurat.
Rasio stenosis atau persentase stenosis	Nilai kuantitatif yang menunjukkan seberapa besar penyempitan lumen arteri dibandingkan dengan ukuran normalnya
Recall	Recall adalah proporsi kasus positif yang berhasil terdeteksi dengan benar. Metrik ini mempunyai pengertian yang sama dengan metrik sensitivitas atau <i>True Positive Rate</i> (TPR).
ROF	Model Rudin–Osher–Fatemi (ROF) digunakan untuk membersihkan citra dari noise sambil menjaga ketajaman tepi, sehingga hasilnya lebih stabil untuk segmentasi atau analisis lanjutan.
Stenosis	Artinya penyempitan, stenosis arteri koroner adalah kondisi penyempitan lumen (ruang dalam) arteri koroner akibat adanya penumpukan plak aterosklerosis yang terdiri dari kolesterol, lemak, kalsium, dan sel-sel inflamasi di dinding pembuluh darah. Penyempitan ini mengurangi aliran darah dan suplai oksigen ke otot jantung (miokard), sehingga dapat menimbulkan gejala angina (nyeri dada) hingga serangan jantung (infark miokard).
Stenosis bermakna	Penyempitan pada lumen arteri koroner yang secara hemodinamik

	berpotensi mengganggu aliran darah ke otot jantung. Dalam praktik klinis, stenosis dikatakan bermakna apabila penyempitan diameter lumen arteri koroner mencapai $\geq 50\%$ pada angiografi koroner. Kondisi ini berhubungan dengan penurunan suplai oksigen ke miokardium dan berisiko menimbulkan gejala klinis seperti nyeri dada (angina), sesak napas, hingga serangan jantung.
Stenosis tidak bermakna	Penyempitan lumen arteri koroner yang relatif ringan, umumnya dengan derajat penyempitan $< 50\%$ dari diameter normal. Pada kondisi ini, aliran darah koroner masih relatif kuat dan biasanya tidak menimbulkan gejala klinis yang signifikan. Namun, stenosis tidak bermakna tetap berpotensi berkembang menjadi stenosis bermakna apabila faktor risiko (misalnya hipertensi, diabetes, hiperlipidemia, atau merokok) tidak dikendalikan.
<i>Triage tool</i>	<i>Triage tool</i> adalah alat bantu untuk memprioritaskan pasien agar diagnosis dan terapi dapat lebih efisien dan tepat sasaran.
UM	<i>Unsharp Masking</i> (UM) digunakan untuk menajamkan citra agar struktur penting seperti lumen pembuluh darah lebih jelas terlihat.
<i>Vessel map</i>	Secara umum, <i>vessel map</i> berarti peta pembuluh darah. Dalam konteks medis dan pencitraan (imaging), istilah ini merujuk pada representasi visual atau model digital dari jaringan pembuluh darah yang diperoleh melalui teknik pencitraan medis.
XCA	<i>X-ray Coronary Angiography</i> (XCA) adalah prosedur pencitraan medis menggunakan sinar-X yang dikombinasikan dengan zat kontras (dye) untuk melihat gambaran pembuluh darah arteri koroner.

BAB I

PENDAHULUAN

1.1. Latar Belakang Penelitian

AI merupakan disiplin ilmu yang mengembangkan sistem komputer untuk meniru sekaligus memperluas kemampuan intelektual manusia. Dalam bidang medis, AI berperan sebagai alat bantu tenaga kesehatan untuk meningkatkan akurasi diagnosis melalui analisis radiologi, patologi, endoskopi, ultrasonografi, dan biokimia, serta mendukung perancangan rencana perawatan yang lebih tepat dan efektif tanpa menggantikan peran klinis tenaga medis [1]. Salah satu cabang AI yang penting adalah *Computer Vision*, yang memungkinkan komputer mengenali dan memahami objek melalui pemrosesan citra secara presisi. Kombinasi AI dan *Computer Vision* melahirkan *Visual Intelligent System*, yaitu sistem yang mampu melakukan interpretasi visual secara cerdas [2].

Saat ini, perkembangan AI di bidang kedokteran semakin meluas dan mencakup berbagai disiplin, antara lain diagnosis medis [3], layanan kesehatan [4], produksi obat [5], pendidikan serta manajemen medis [6], hingga riset penyakit seperti penyakit jantung [7–11], kanker otak [12], dan kanker paru-paru [13]. Dalam sektor kesehatan, AI telah menjadi inovasi revolusioner karena kemampuannya dalam menganalisis volume besar data medis, termasuk catatan medis elektronik dan citra medis [14,15]. Kemampuan ini berkontribusi signifikan terhadap peningkatan akurasi diagnosis sekaligus penyusunan rencana perawatan yang lebih terpersonalisasi. Salah satu pendekatan utama dalam AI adalah ML, yang berfungsi mendukung pengambilan keputusan klinis oleh dokter, misalnya dengan memprediksi risiko penyakit dan menganalisis data genetik pasien [16,17]. Lebih lanjut, perkembangan DL telah merevolusi metode dalam ML. DL menggunakan arsitektur jaringan saraf berlapis banyak yang meniru struktur dan fungsi otak manusia [18–21], serta memiliki keunggulan dalam ekstraksi fitur dan pengenalan pola secara otomatis dari data kompleks. Kemajuan signifikan dalam DL telah memicu pergeseran paradigma dalam berbagai aplikasi, termasuk pengenalan citra, pemrosesan bahasa alami, dan pengenalan suara. Pergeseran ini juga memberikan dampak besar pada analisis penyakit berbasis citra digital. Salah satu algoritma DL yang paling banyak digunakan

dalam pengolahan citra medis adalah CNN, yang telah diaplikasikan secara luas dalam diagnosis penyakit jantung melalui analisis citra digital [22–24].

Penyakit jantung merupakan penyebab kematian utama di dunia. Berdasarkan laporan WHO tahun 2023–2025, sebanyak 17,9 juta orang meninggal setiap tahunnya akibat penyakit ini, yang mewakili sekitar 32% dari total kematian global [25]. Penyakit jantung dapat menimbulkan komplikasi berupa aritmia, yaitu gangguan irama jantung yang ditandai oleh ritme tidak teratur akibat fungsi abnormal pada sistem konduksi listrik jantung [26–29]. Menurut kajian Acharya (2017) [30], terdapat tiga kondisi utama pada penyakit jantung yang diidentifikasi berdasarkan sinyal EKG, yaitu CAD, MI, dan CHF. Pada Disertasi ini, fokus penelitian diarahkan pada identifikasi CAD. CAD merupakan salah satu penyakit jantung pada arteri koroner akibat penyempitan arteri koroner atau stenosis [31]. Arteri koroner yang berbentuk tabung mengalami penurunan diameter [32], sehingga suplai darah dan oksigen menuju jantung berkurang [33]. Persentase stenosis yang menyebabkan penyumbatan lebih dari 50% aliran darah dikategorikan sebagai CAD [34] dan menjadi acuan klinis bagi dokter jantung dalam menentukan diagnosis. Oleh karena itu, diagnosis dini serta analisis stenosis memiliki peranan yang sangat penting dalam upaya pencegahan maupun intervensi dini penyakit arteri koroner [35].

Dalam praktik klinis, identifikasi CAD umumnya dilakukan melalui analisis citra stenosis arteri koroner yang diperoleh dari rekaman kateterisasi pasien dalam video. Rekaman tersebut kemudian dikonversikan menjadi citra (XCA) untuk selanjutnya dianalisis dalam rangka menentukan adanya stenosis arteri. Metode standar yang digunakan dalam analisis ini adalah PVA, yaitu penilaian manual terhadap rasio stenosis secara visual. Pada metode ini, dokter mengamati diameter penyempitan arteri koroner pada titik paling sempit, kemudian membandingkannya dengan diameter normal maksimum sebelum titik penyempitan. Rasio antara selisih diameter penyempitan dan diameter normal tersebut dikenal sebagai rasio stenosis, yang menjadi acuan dokter jantung dalam mendiagnosis pasien dengan CAD [36] serta menentukan keputusan medis lanjutan. Selain itu, diagnosis CAD juga dapat dilakukan melalui analisis berbasis data tabular [37], sebagaimana ditunjukkan pada hasil penelitian awal dalam Disertasi ini.

Penilaian rasio stenosis umumnya diklasifikasikan ke dalam dua kategori utama, yaitu stenosis bermakna dan stenosis tidak bermakna. Stenosis bermakna

mengindikasikan adanya CAD, ditandai dengan penyempitan diameter lumen arteri koroner sebesar $\geq 50\%$ pada angiografi koroner. Kondisi ini berhubungan dengan penurunan suplai darah dan oksigen ke miokardium dan berisiko menimbulkan gejala klinis seperti nyeri dada (*angina*), sesak napas, hingga serangan jantung. Sebaliknya, stenosis tidak bermakna ditandai oleh penyempitan lumen arteri koroner yang relatif ringan, umumnya $<50\%$ dari diameter normal. Pada kondisi ini, aliran darah koroner masih relatif kuat dan biasanya tidak menimbulkan gejala klinis signifikan.

Meskipun metode penilaian dengan PVA banyak digunakan, pendekatan ini memiliki keterbatasan, terutama karena adanya variasi antar pengamat yang berpotensi menimbulkan bias. Tantangan utama lainnya adalah ukuran arteri koroner yang relatif kecil, hanya sekitar 3–4 mm [38], sehingga pengamatan titik penyempitan membutuhkan keahlian dan pengalaman klinis yang tinggi. Akurasi penilaian pun kerap menjadi kendala. Untuk meningkatkan ketepatan diagnosis, telah dikembangkan perangkat QCA yang memungkinkan penilaian stenosis secara kuantitatif [39]. Walaupun menawarkan akurasi lebih tinggi, QCA memiliki sejumlah kelemahan, antara lain biaya perangkat yang sangat mahal, prosedur yang masih bersifat manual, serta kebutuhan sumber daya yang besar.

Selain itu, penilaian rasio stenosis dalam format video juga kerap dipersulit oleh berbagai faktor, seperti pergerakan jantung selama siklus pemompaan darah, variasi fisiologi antar individu, serta perbedaan bentuk dan ukuran stenosis pada setiap pasien. Berbagai pendekatan telah diusulkan untuk mengatasi tantangan tersebut, namun hingga kini belum ada metode yang mampu menghasilkan performa optimal sesuai kebutuhan aplikasi klinis [40, 41]. Oleh karena itu, pengembangan metode yang lebih akurat, efisien, dan andal dalam menilai stenosis arteri koroner sangat diperlukan guna mendukung diagnosis serta pengambilan keputusan klinis yang lebih tepat, sekaligus meminimalkan variabilitas antar pengamat.

Untuk mengatasi permasalahan tersebut, pendekatan berbasis DL telah banyak digunakan dalam identifikasi stenosis. DL memiliki berbagai kemampuan, antara lain segmentasi, klasifikasi, deteksi, dan pengenalan (*recognition*), yang dapat dimanfaatkan untuk menganalisis citra stenosis arteri koroner. Salah satu algoritma DL yang paling umum digunakan adalah CNN, yang terbukti efektif dalam pengolahan citra medis. Melalui penerapan CNN, analisis stenosis dapat dilakukan secara lebih objektif dan akurat. Selain itu, kondisi arteri koroner yang direkam dalam bentuk video

memungkinkan proses observasi dinamis terhadap permasalahan yang terjadi pada arteri, sehingga analisis menggunakan CNN dapat memberikan informasi yang lebih komprehensif mengenai stenosis.

Saat ini, penerapan DL dalam analisis stenosis untuk identifikasi CAD telah banyak dilakukan oleh berbagai penelitian, seperti diuraikan dalam kajian berikut.

Studi yang dilakukan oleh Au et al. [39] mengkarakterisasi stenosis pada arteri koroner kanan dari ICA melalui proses lokalisasi, segmentasi, dan klasifikasi menggunakan CNN. *Dataset* terdiri dari citra ICA pasien yang dianotasi pakar sebagai *ground truth*, kemudian dilatih dan diuji. Pada penelitian ini, luaran lokalisasi disegmentasi, sedangkan luaran lokalisasi dan segmentasi diklasifikasi menggunakan regresi dengan ambang batas 70%. Hasil penelitian menunjukkan bahwa model CNN mampu mengidentifikasi stenosis secara akurat dengan performa sebanding dengan penilaian pakar, sehingga berpotensi mengurangi beban kerja klinis dan meningkatkan konsistensi evaluasi. Namun, studi ini memiliki beberapa keterbatasan, antara lain penggunaan dataset terbatas dari satu sumber, ketergantungan pada anotasi manual sebagai standar referensi yang berpotensi menimbulkan bias, tidak adanya validasi eksternal untuk menilai generalisasi model, serta belum menghitung rasio stenosis secara kuantitatif sehingga informasi numerik presisi penyempitan lumen masih terbatas.

Chen dkk. [23] mengusulkan segmentasi arteri koroner berbasis 3D *multi-channel* UNet dengan masukan citra CCTA dan *vesselness map*, didukung *preprocessing* berupa ekstraksi *Volume of Interest* (VOI), augmentasi data, serta rekonstruksi dengan *largest connected component*. Model mencapai nilai Dice 80%, lebih tinggi dibanding pendekatan CNN sebelumnya dan setara dengan pembaca ahli. Namun, studi ini terbatas oleh ukuran dataset yang kecil, ketergantungan pada pascaproses, serta tidak menghitung rasio stenosis sehingga kuantifikasi derajat penyempitan lumen belum tersedia.

Zreik dkk. [36] mengembangkan metode deteksi dan klasifikasi tipe plak arteri koroner serta penilaian derajat stenosis menggunakan dataset CCTA dari 163 pasien. Garis pusat arteri diekstrak untuk merekonstruksi MPR, kemudian anotasi manual dilakukan untuk menentukan tipe plak (*no plaque*, *non-calcified*, *mixed*, *calcified*) dan kebermaknaan stenosis ($<50\% \text{ non-significant}$, $\geq 50\% \text{ significant}$). Data dari 98 pasien digunakan untuk pelatihan dan 96 pasien untuk pengujian, menghasilkan akurasi 77%

untuk plak dan 80% untuk stenosis. Metode ini memiliki kelemahan, antara lain ketergantungan pada kualitas citra dan artefak, potensi kesalahan segmentasi pada arteri tortuosa atau stenosis berat, keterbatasan menangkap plak kompleks, kebutuhan komputasi tinggi, ketergantungan pada anotasi manual yang rentan bias, serta tidak melaporkan rasio stenosis yang membatasi analisis kuantitatif lebih lanjut.

Wu dkk. [24] mengembangkan metode deteksi otomatis stenosis arteri koroner pada XCA dengan memanfaatkan *preprocessing* berupa seleksi *contrast-filled frames* menggunakan UNet serta augmentasi citra. Model utama menggunakan CNN berbasis DSSD dengan *sequence-false positive suppression* untuk memanfaatkan konsistensi *temporal* antar *frame*. Evaluasi pada 148 sequence dari 63 pasien menunjukkan sensitivitas 87,2%, PPV 79,5%, dan F1-score 83,2%, lebih unggul dibanding pendekatan sebelumnya. Namun, keterbatasan studi ini terletak pada ukuran dataset yang kecil, ketergantungan pada parameter yang masih perlu optimasi, serta tidak menghitung rasio stenosis sehingga kuantifikasi derajat penyempitan lumen belum tersedia.

Ovalle-Magallanes dkk. [42] menerapkan *preprocessing* berupa normalisasi intensitas citra XCA serta penggunaan *patch* sintetis dan nyata untuk pelatihan model. CNN pra-latih (VGG16, ResNet50, Inception-v3) dengan strategi *fine-tuning* diuji, dan Inception-v3 memberikan performa terbaik dengan akurasi 95%, presisi 93%, sensitivitas 98%, spesifitas 92%, dan F1-score 95%. Studi ini menunjukkan potensi *transfer learning* dalam mendeteksi stenosis, namun terbatas pada pendekatan berbasis *patch*, ketergantungan pada data sintetis yang mungkin kurang merepresentasikan variasi klinis, serta tidak menghitung rasio stenosis secara kuantitatif.

Rodrigues dkk. [41] bertujuan mengembangkan kerangka dua tahap berbasis DL untuk mendeteksi stenosis pada citra XCA. *Preprocessing* dilakukan dengan anotasi manual stenosis oleh ahli, propagasi anotasi menggunakan *object tracking* untuk seluruh sekuens, penghapusan citra dengan artefak, serta augmentasi data (variasi *brightness* dan kontras). Dataset terdiri atas 9378 sekuens invasif angiografi koroner dari 438 pasien, yang setelah seleksi menghasilkan 1294 sekuens optimal dengan 20819 *frame*. Model yang digunakan adalah ResNet-50 untuk klasifikasi *viewing angle* (RCA/LCA) dan RetinaNet dengan *feature pyramid networks* untuk deteksi stenosis melalui *bounding box*. Evaluasi menunjukkan akurasi 97% untuk klasifikasi *angle* dan *recall/precision* sekitar 72%–74% untuk deteksi stenosis.

Keterbatasan studi ini mencakup kesulitan mendeteksi stenosis multipel, kecenderungan menghasilkan *false positive* pada area latar belakang, ketergantungan pada anotasi manual ahli, serta belum menghitung rasio stenosis atau derajat penyempitan secara kuantitatif, sehingga informasi klinis yang dihasilkan masih terbatas.

Moon dkk. [43] bertujuan mengembangkan metode otomatis berbasis CNN untuk mengenali stenosis pada XCA. *Preprocessing* dilakukan melalui konversi citra ke skala abu-abu, normalisasi, serta augmentasi berupa penyesuaian intensitas piksel dan *cropping* citra angiografi pada posisi tetap (tengah dan keempat sudut), sehingga berbeda dengan *cropping* area stenosis yang berfokus langsung pada bagian arteri menyempit. Dataset terdiri dari citra angiografi koroner yang dikumpulkan secara klinis dan diberi anotasi manual oleh pakar sebagai *ground truth*. Model yang digunakan adalah arsitektur CNN dengan beberapa lapisan konvolusi, *pooling*, dan *fully connected* yang dirancang khusus untuk klasifikasi stenosis. Evaluasi menunjukkan akurasi deteksi stenosis mencapai sekitar rata-rata 91,6% untuk metode evaluasi *clip-wise* akurasi, dengan sensitivitas dan spesifisitas yang cukup tinggi, menunjukkan potensi CNN dalam mendukung diagnosis klinis. Namun, keterbatasan model terletak pada ukuran dataset yang relatif kecil, ketergantungan pada anotasi manual, potensi *overfitting*, kelemahan *cropping* augmentasi yang berisiko tidak selalu merepresentasikan area stenosis, serta tidak adanya perhitungan rasio stenosis sehingga model hanya memberikan hasil klasifikasi biner tanpa informasi kuantitatif derajat penyempitan lumen.

Zhao et al. [22] mengusulkan sebuah pendekatan baru untuk mengekstraksi arteri koroner dan mendeteksi stenosis dalam citra ICA menggunakan model MIMS UNet yang dilatih dalam dua tahap. *Preprocessing* data dilakukan dengan meningkatkan kontras citra dan melakukan augmentasi data untuk memperbanyak sampel, serta memotong citra menjadi ukuran yang lebih kecil. Model ini diuji pada dataset retrospektif 294 citra dari 73 pasien dan menunjukkan hasil evaluasi yang menjanjikan, dengan skor Dice rata-rata 83,29% untuk segmentasi pembuluh darah dan tingkat *true positive* 66,68% untuk deteksi stenosis. Namun, keterbatasan utama dari penelitian ini adalah ukuran dataset yang relatif kecil, yang dapat membatasi kemampuan generalisasi model, dan yang paling penting, model ini tidak menghitung rasio stenosis secara spesifik, melainkan hanya mendeteksi keberadaannya.

Zreik dkk. [44] melakukan deteksi stenosis arteri koroner bermakna secara non-invasif dengan mengombinasikan analisis pohon arteri koroner dan miokardium LV pada CCTA menggunakan dataset 126 pasien yang juga menjalani pengukuran FFR sebagai standar emas. Tahap preprocessing meliputi ekstraksi *centreline* arteri koroner dan rekonstruksi MPR beresolusi isotropik untuk memudahkan analisis morfologi. Arteri koroner direpresentasikan dengan dua CAE, sedangkan miokardium LV dikarakterisasi melalui CNN multiskala dan CAE, lalu fitur gabungan diklasifikasikan menggunakan *multiple instance learning* berbasis *attention neural network* untuk menentukan stenosis bermakna sesuai FFR. Hasil *cross-validation* menunjukkan AUC 74%, dengan analisis gabungan lebih unggul dibanding analisis tunggal. Keterbatasan penelitian mencakup ukuran dataset kecil, data dari satu pusat, belum ada validasi pada populasi klinis luas, dan tidak menghitung rasio stenosis secara anatomic, sehingga interpretasi klinis hanya bersifat fungsional tanpa informasi kuantitatif penyempitan lumen.

Berdasarkan kajian-kajian tersebut, terlihat bahwa penerapan DL dalam analisis stenosis arteri koroner telah menunjukkan hasil yang menjanjikan melalui berbagai pendekatan seperti segmentasi, klasifikasi, ekstraksi fitur, hingga pembuatan data sintetik. Namun demikian, penelitian-penelitian tersebut masih memiliki keterbatasan, terutama dalam hal diagnosis dini CAD secara otomatis pada citra XCA, *preprocessing* stenosis dan model yang dikembangkan untuk mencapai peningkatan performa sesuai kebutuhan aplikasi klinis, dan belum menunjukkan persentase hitungan rasio stenosis untuk menginterpretasi penyempitan lumen secara kuantitatif. Oleh karena itu, pengembangan metode DL untuk analisis stenosis pada XCA terkait identifikasi CAD masih sangat diperlukan.

Disertasi ini memfokuskan pada peningkatan performa model dalam identifikasi CAD. Metode yang diusulkan pada tahap *preprocessing* meliputi *cropping* dan *scaling* pada area stenosis di XCA serta pengembangan model CNN. *Cropping* dilakukan secara manual dengan tujuan fokus langsung pada area stenosis. Teknik *square crop* dan *scaling* diterapkan untuk mengubah dimensi *frame* citra XCA sehingga menghasilkan potongan stenosis (*a patch of stenosis*) dengan tinggi dan lebar yang seragam. Untuk mengevaluasi stenosis, penelitian ini telah melaksanakan 2 jenis analisis, yaitu analisis area stenosis dan analisis rasio stenosis. Analisis area stenosis

dilakukan menggunakan metode segmentasi, sedangkan analisis rasio stenosis dilakukan dengan pendekatan klasifikasi.

Untuk melakukan analisis area stenosis dengan pendekatan segmentasi, digunakan 4 arsitektur varian CNN, yaitu SegNet, ResNet34, UNet, dan Residual UNet, sebagai predictor dalam eksperimen evaluasi stenosis pada frame baru hasil *cropping* dan *scaling*. Eksperimen ini difokuskan pada area stenosis arteri koroner yang masih memungkinkan aliran darah. Evaluasi dilakukan dengan memanfaatkan dataset kontur stenosis, di mana citra stenosis arteri koroner telah melalui proses *cropping* dan *scaling* sehingga menghasilkan *patch of stenosis*. Keempat model tersebut dilatih menggunakan *hyperparameter* yang sama dengan memanfaatkan dataset yang telah disiapkan, dengan tujuan menjaga konsistensi kondisi pelatihan sehingga perbedaan hasil evaluasi lebih merefleksikan kemampuan arsitektur masing-masing model, bukan akibat variasi pengaturan pelatihan. Selanjutnya, eksperimen ini melakukan segmentasi dua kelas stenosis, yaitu penyempitan $\geq 50\%$ (abnormal) dan penyempitan $< 50\%$ (normal), dengan distribusi data yang seimbang antara kelas abnormal dan normal.

Sementara itu, untuk analisis rasio stenosis dengan pendekatan klasifikasi, digunakan dua arsitektur CNN, yaitu CNN dasar dan CNN pengembangan (CNN-Plus), sebagai *predictor* dalam eksperimen evaluasi stenosis pada *frame* baru hasil *cropping*. Eksperimen ini difokuskan pada bagian arteri yang mengalami kerusakan (*lesion*) sehingga tidak dapat mengalirkan darah. Kerusakan tersebut menyebabkan penyempitan diameter arteri, yang menimbulkan perbedaan antara diameter arteri sebelum (normal) dan sesudah mengalami kerusakan (abnormal), sehingga menghasilkan rasio stenosis. Untuk mengevaluasi rasio stenosis, digunakan *dataset* rasio stenosis yang diproses melalui klasifikasi 2 kelas, yaitu normal dan abnormal, dengan distribusi data yang seimbang pada kedua kelas tersebut.

Untuk menilai keberhasilan kedua eksperimen, evaluasi dilakukan berdasarkan performa luaran model setelah proses pelatihan. Performa model segmentasi dan klasifikasi diukur menggunakan metrik akurasi, Intersection over Union (IoU), presisi, recall, dan F1-score guna membangun sekaligus memvalidasi model. Selain itu, untuk mengukur tingkat kekokohan (robustness), kedua model diuji dengan menggunakan *unseen data*. Selanjutnya, hasil evaluasi dibandingkan dengan pendekatan terdahulu guna memperoleh gambaran kuantitatif mengenai peningkatan performa yang

dihasilkan. Analisis komprehensif juga dilakukan untuk mengidentifikasi kontribusi tiap komponen metode terhadap efektivitas keseluruhan model.

1.2. Perumusan Masalah

Identifikasi CAD melalui deteksi stenosis pada arteri koroner yang relatif kecil secara visual sering menghasilkan akurasi yang rendah, membutuhkan waktu serta keahlian khusus, dan rentan terhadap kesalahan antar pengamat. Pendekatan DL yang telah diterapkan oleh peneliti sebelumnya juga masih menunjukkan keterbatasan, terutama dalam memberikan informasi yang akurat terkait stenosis dan kontur. Selain itu, model yang ada belum sepenuhnya mampu menangani variasi ukuran dan bentuk stenosis, serta belum memenuhi standar klinis. Di sisi lain, indikasi CAD pada pasien umumnya ditentukan oleh rasio stenosis arteri koroner. Kondisi ini kerap menimbulkan keraguan bagi tenaga medis dalam menegakkan diagnosis dan menentukan tindakan lanjutan bagi pasien. Oleh karena itu, penelitian ini mengusulkan pengembangan metode identifikasi CAD berbasis analisis stenosis dengan bantuan model DL yang berfokus pada kontur dan rasio stenosis. Untuk menjawab permasalahan tersebut, penelitian ini merumuskan masalah penelitian sebagai berikut.

1. Bagaimana meningkatkan performa yang tinggi pada model segmentasi SegNet, ResNet34, UNet, dan Residual UNet untuk mengidentifikasi CAD berdasarkan stenosis arteri koroner.
2. Bagaimana meningkatkan performa yang tinggi model klasifikasi CNN untuk mengidentifikasi CAD menggunakan stenosis arteri koroner.

1.3. Tujuan Penelitian

Pada rumusan permasalahan telah diuraikan bahwa analisis stenosis dengan metode PVA secara visual masih rentan terhadap kesalahan dalam memprediksi rasio penyempitan arteri koroner, terutama pada arteri yang berukuran relatif kecil. Beberapa model berbasis DL yang telah ada juga menunjukkan keterbatasan, karena selain belum mampu memberikan informasi stenosis secara akurat, juga belum sepenuhnya dapat menangani variasi bentuk dan ukuran stenosis sesuai kebutuhan aplikasi klinis. Kondisi ini menyebabkan dokter mengalami keraguan serta membutuhkan waktu lebih lama dalam menentukan tindakan lanjutan. Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan dua kajian utama.

Pertama, kajian mengenai stenosis pada arteri koroner berukuran kecil dengan membentuk kontur stenosis melalui tahap *preprocessing* berupa *cropping* dan *scaling*. Kontur yang telah dianotasi menghasilkan *dataset* kontur stenosis, yang kemudian diuji menggunakan 4 arsitektur CNN, yaitu SegNet, ResNet34, UNet, dan Residual UNet, guna memprediksi kontur. Evaluasi performa model dilakukan menggunakan metrik akurasi, *Intersection over Union* (IoU), presisi, recall, dan F1-score. Kedua, kajian pengembangan model CNN dengan melakukan modifikasi pada lapisan rekayasa fitur sehingga menghasilkan 2 varian model, yaitu CNN dasar dan CNN-Plus. Kedua model ini diuji menggunakan *dataset* stenosis yang dianotasi pada area arteri yang rusak, di mana analisis difokuskan pada diameter arteri yang menyempit. Anotasi pada area tersebut memberikan nilai rasio stenosis untuk mengevaluasi tingkat keparahan kerusakan. Hasil anotasi menghasilkan *dataset* rasio stenosis, yang kemudian diuji pada arsitektur CNN dasar dan CNN-Plus. Evaluasi performa model dilakukan dengan menggunakan metrik akurasi, IoU, presisi, recall, dan F1-score. Dengan demikian, untuk menjawab rumusan permasalahan yang telah dikemukakan, tujuan penelitian ini ditetapkan sebagai berikut.

1. Meningkatkan performa yang tinggi pada model segmentasi SegNet, ResNet34, UNet, dan Residual UNet dengan menerapkan *preprocessing* pada area stenosis XCA menggunakan metode *cropping* dan *scaling* untuk identifikasi CAD;
2. Meningkatkan performa model klasifikasi yang tinggi dengan cara memodifikasi lapisan rekayasa fitur pada CNN untuk identifikasi CAD.

1.4. Ruang Lingkup

Ruang lingkup penelitian ini meliputi:

1. Arsitektur segmentasi untuk identifikasi CAD berdasarkan area stenosis dua kelas adalah SegNet, ResNet34, UNet, dan Residual UNet.
2. Arsitektur klasifikasi untuk identifikasi CAD berdasarkan tingkat keparahan stenosis dua kelas adalah CNN dengan modifikasi lapisan rekayasa fitur.
3. *Dataset stenosis* yang digunakan terdiri atas dua dataset yaitu dataset kontur dan dataset rasio stenosis, dataset ini bersumber dari rumah sakit A dan B Palembang yang dibuat sendiri oleh peneliti.
4. Tingkat keparahan stenosis yang dievaluasi meliputi dua kelas yaitu rasio stenosis $\geq 50\%$ (abnormal) dan $< 50\%$ (normal) pada pasien yang mengalami CAD.

5. *Tool* yang digunakan adalah python, jcopml, jcopdl, pytorch, tensor flow.

1.5. Keterbaruan dan kontribusi

Untuk mencapai tujuan yang telah diuraikan, maka keterbaruan (*novelty*) dan kontribusi Disertasi ini diuraikan sebagai berikut. *Novelty* Disertasi ini adalah pertama memfokuskan peningkatan performa model melalui *preprocessing* area stenosis dengan cara *cropping-scaling* yang menghasilkan sebuah model terbaik dan kedua memfokuskan peningkatan performa model melalui pengembangan CNN dasar dan CNN-Plus dengan cara memodifikasi lapisan rekayasa fitur yang menghasilkan sebuah model terbaik. Penjelasan kedua *novelty* tersebut adalah sebagai berikut.

Pada tahap *preprocessing*, dilakukan penerapan teknik *cropping* pada area stenosis arteri koroner dengan tujuan memperjelas area penyempitan atau *region of interest* (RoI). Teknik ini memposisikan stenosis pada bagian tengah (*central frame*) sehingga ukuran stenosis tampak lebih besar dibandingkan dengan citra asal. Hal ini diperlukan mengingat ukuran arteri koroner relatif kecil, yaitu sekitar 3–4 mm [37]. Teknik *cropping* yang digunakan adalah *square crop* [45], untuk menghasilkan potongan (*patch*) citra stenosis baru dengan dimensi yang seragam. Proses *cropping* dilakukan pada citra berukuran 512×512 piksel menjadi 100×100 piksel. Selanjutnya, citra hasil *cropping* dilakukan proses *scaling* untuk mengembalikan dimensi ke ukuran asal 512×512 piksel. Proses ini bertujuan menambahkan piksel pada area stenosis sehingga ukuran piksel sesuai dengan citra asli. Citra stenosis hasil *cropping* dan *scaling* tersebut dikumpulkan menjadi satu *dataset* yang terdiri atas 2 kelas, yaitu stenosis normal dan stenosis abnormal. *Dataset* yang telah terbentuk selanjutnya dianotasi menggunakan dua pendekatan. Pendekatan pertama adalah anotasi pada area stenosis yang digunakan untuk analisis segmentasi. Pendekatan kedua adalah anotasi pada rasio diameter arteri yang mengalami kerusakan, yang digunakan untuk analisis klasifikasi. Untuk membuktikan peningkatan performa, dataset sebelum *cropping-scaling* dan setelah *cropping-scaling* diujikan pada 4 model segmentasi SegNet, ResNet34, UNet, dan Residual UNet. Dari hasil eksperimen, semua model mengalami peningkatan performa setelah mengalami *cropping-scaling*. Model Residual UNet lebih unggul dibandingkan model lainnya.

Pada tahap rancangan rekayasa fitur, lapisan konvolusi dan *pooling* CNN dimodifikasi. Untuk CNN dasar, lapisan rekayasa fitur mempunyai 2 lapisan konvolusi

dan 1 *pooling*. Konvolusi ke-1 mempunyai ukuran kanal 1x128x128, dimana 1 menunjukkan ukuran kanal karena data berwarna abu-abu, 128x128 adalah ukuran citra input. Konvolusi ke-2 berukuran 8x64x64, dimana 8 adalah data mempunyai 8 kanal, 64x64 adalah ukuran data citra setelah melalui *pooling* menjadi 64x64. *Pooling* ditempatkan setelah konvolusi ke-1 sebelum konvolusi ke-2. Untuk CNN-Plus, lapisan rekayasa fitur terdiri atas 6 konvolusi dan 5 *pooling* yang disusun secara serial: konvolusi ke-1 dengan kanal 1x128x128, *pooling* ke-1, konvolusi ke-2 dengan kanal 32x64x64, *pooling* ke-2, konvolusi ke-3 dengan kanal 32x32x32, *pooling* ke-3, konvolusi ke-4 dengan kanal 64x16x16, *pooling* ke-4, konvolusi ke-5 dengan kanal 64x8x8, *pooling* ke-5, dan konvolusi ke-6 dengan kanal 128x4x4. Setelah konvolusi ke-6, ukuran citra stenosis memiliki 128 kanal dan ukuran citra 4x4, yang semula berukuran 1 kanal dan ukuran citra 128x128. Kemudian, untuk membuktikan 2 arsitektur CNN mengalami peningkatan performa, 2 arsitektur tersebut diujikan pada dataset rasio setelah *cropping*. Hasil menunjukkan 2 model tersebut dapat membaca data dengan baik, dengan hasil untuk CNN dasar menghasilkan 4 metrik performa sangat baik dan 1 metrik performa baik, sedangkan CNN-Plus menghasilkan semua metrik performa sangat baik. CNN-Plus lebih unggul dan mengalami peningkatan performa yang signifikan dibandingkan CNN dasar.

Kontribusi Disertasi ini diuraikan sebagai berikut.

1. Pembuatan *dataset* stenosis yang telah di *preprocessing* dengan metode *square crop* dan *scaling* yaitu anotasi segmentasi pada kontur dan anotasi rasio pada diameter arteri koroner yang lesi;
2. Pengujian *dataset* kontur sebelum dan setelah *cropping-scaling* pada *area* stenosis untuk segmentasi dengan model SegNet, ResNet34, UNet, dan Residual UNet yang menghasilkan peningkatan performa;
3. Pengujian *dataset* rasio dengan model CNN dasar dan CNN-Plus yang menghasilkan peningkatan performa model.
4. Menghasilkan 1 model segmentasi yang unggul dari 4 model yang dievaluasi adalah Residual UNet dan 1 model klasifikasi yang unggul dari 2 model yang dievaluasi adalah CNN-Plus;

5. Perancangan arsitektur CNN dasar yang memiliki 2 lapis konvolusi dan 1 *pooling*, ReLU dan *batch normalization* untuk masing-masing konvolusi, dan *fully connected* pada akhir arsitektur CNN diberi fungsi aktivasi *softmax*;
6. Perancangan arsitektur CNN-Plus yang memiliki 6 lapis konvolusi dan 5 *pooling*. ReLU, dan *batch normalization* untuk masing-masing konvolusi. *Fully connected* pada akhir arsitektur CNN diberi fungsi aktivasi *softmax*.

1.5. Sistematika Penulisan

Adapun sistematika Penulisan Disertasi ini yaitu

BAB I PENDAHULUAN

Dalam bab ini meliputi latar belakang penelitian, perumusan masalah, tujuan penelitian, ruang lingkup penelitian, keterbaruan dan kontribusi, serta sistematika Penulisan Disertasi.

BAB II STUDI LITERATUR

Bab ini berisikan *state of the art*, penelitian sejenis, teori dasar tentang penyakit jantung koroner dan stenosis, *convolutional neural network*, *convolutional layer*, kernel dan operasinya, *pooling*, *rectified linear unit* (ReLU), *softmax*, *sigmoid*, *dropout*, *batch normalization* (BN) dan *dropout*, fungsi optimasi AdamW, fungsi *loss*, *fully connected layer*, arteri koroner jantung, penyakit jantung koroner dan stenosis, *preprocessing* stenosis: *cropping* dan *scaling*, evaluasi performa model, dan pengertian segmentasi dan klasifikasi secara umum.

BAB III. METODOLOGI PENELITIAN

Dalam bab ini berisi tentang langkah kerja penelitian yang dimulai dari studi literatur, *preprocessing* stenosis arteri koroner, anotasi *dataset*, split dataset, rancangan model segmentasi dan klasifikasi stenosis arteri koroner, pengujian model, serta evaluasi performa model.

BAB IV. HASIL DAN PEMBAHASAN

Pada bab ini mendeskripsikan deskripsi data, hasil konversi video ke *frame* citra stenosis, hasil peningkatan kualitas citra XCA, hasil *preprocessing* stenosis arteri koroner, hasil anotasi stenosis: anotasi kontur dan anotasi rasio, hasil rancangan

arsitektur, dan pembahasan dengan membandingkan hasil pengujian model segmentasi terhadap dataset sebelum dan sesudah *preprocessing* stenosis arteri koroner, dan juga membandingkan dengan pendekatan lain.

BAB. V. KESIMPULAN

Bab ini menjelaskan kesimpulan jawaban yang diminta tujuan dan kontribusi penelitian dalam Disertasi ini, serta penjelasan penelitian lanjutan ke depannya.

DAFTAR PUSTAKA

- [1] Liu, P., Lu, L., Zhang, J., Huo, T., Liu, S., Ye, Z., 2021, Application of Artificial Intelligence in Medicine: An Overview. *Curr Med Sci* 41, 1105–1115. <https://doi.org/10.1007/s11596-021-2474-3>
- [2] Jamaaluddin, Sulistyowati, I., 2021, Buku Ajar Kecerdasan Buatan (Artificial Intelligence), UMSIDA PRESS, Sidoarjo Jawa Timur <https://doi.org/10.21070/2021/978-623-6292-25-9>
- [3] Alowais, S.A., Alghamdi, S. S., Alsuhbany, N., Alqahtani, T., Alshaya, A. I., et. al., 2023, Revolutionizing healthcare: the role of artificial intelligence in clinical practice. *BMC Medical Education*, 23:689. <https://doi.org/10.1186/s12909-023-04698-z>.
- [4] Basu, K., Sinha, R., Ong, A., Basu, T., 2020, Artificial Intelligence: How is it changing medical sciences and its future? *Indian J Dermatol*, 65:365-70. DOI: 10.4103/ijd.IJD_421_20.
- [5] Kumar, P., Chaudhary, B., Arya, P., Chauhan, R., Devi, S., Parejiya, P.B., et. al., 2025, Advanced Artificial Intelligence Technologies Transforming Contemporary Pharmaceutical Research. *Bioengineering*, 12, 363. <https://doi.org/10.3390/bioengineering12040363>.
- [6] Sarkar, M., Gaman, M., Puyana, J. C., Bonilla-Escobar, F., J., 2024, Artificial Intelligence in Medicine and Medical Education: Current Applications, Challenges, and Future Directions, *Int J Med Stud*, Vol 12, Issue 1. DOI 10.5195/ijms.2023.2626.
- [7] Nurmaini, S., Tondas, A. E., Darmawahyuni, A., Rachmatullah, M. N., Partan, R. U., Firdaus, Tutuko, B., Pratiwi, F, Juliano, A. H., Khoirani, R., 2020, Robust detection of atrial fibrillation from short-term electro cardiogram using convolutional neural networks, *Future Generation Computer Systems* 113, 304–317. <https://doi.org/10.1016/j.future.2020.07.021>.
- [8] Mirza, A.H., Nurmaini, S., Partan, R.U., 2022, Automatic Classification of 15 Leads ECG Signal of Myocardial Infarction Using One Dimension Convolutional Neural Network. *Appl. Sci.* 12, 5603. <https://doi.org/10.3390/app12115603>.
- [9] Atika, L., Nurmaini, S., Partan, R. U., Sukandi, E., 2022, Image Segmentation for Mitral Regurgitation with Convolutional Neural Network Based on UNet, Resnet, Vnet, FractalNet and SegNet: A Preliminary Study. *Big Data Cogn. Comput.*, 6, 141. <https://doi.org/10.3390/bdcc6040141>.
- [10] Nova, R., Nurmaini, S., Partan, R.U., Putra, S.T., 2021, Automated image segmentation for cardiac septal defects based on contour region with convolutional neural networks: A preliminary study, *Informatics in Medicine Unlocked*, 24, 100601. <https://doi.org/10.1016/j.imu.2021.10060>.
- [11] Shinde, S. B., Sree, V.S., Borkar, P., 2023, Experimental Analysis of Heart Disease Prediction Using Machine Learning with Emphasis on Hyper Parameter Tuning and Recursive Feature Elimination, *International Journal of Intelligent Engineering and Systems*, Vol.16, No.6, DOI: 10.22266/ijies2023.1231.08.
- [12] Nisha, B., Jose, M.V., 2023, Brain Cancer Object Segmentation Using LPSIT Method and Back Propagation Network, *International Journal of Intelligent Engineering and Systems*, Vol.16, No.5. DOI: 10.22266/ijies2023.1031.11.

- [13] Pradhan, M., Coman, I. L., Mishra, S., Bhuiyan, A., Thieu, T., 2023, LSTM based Modified Remora Optimization Algorithm for Lung Cancer Prediction, International Journal of Intelligent Engineering and Systems, Vol.16, No.6. DOI: 10.22266/ijies2023.1231.05.
- [14] Hedstrom, A., Weber, L., Bareeva, D., Krakowczyk, D., Motzkus, F., Samek, W., *et. al.*, 2023, Quantus: An Explainable AI Toolkit for Responsible Evaluation of Neural Network Explanations and Beyond. <https://doi.org/10.48550/arXiv.2202.06861>.
- [15] Qing, C., Yang, N., Tang, S., Chen, J., Wang, J., 2024, CNN-aided timing synchronization in OFDM systems by exploiting lightweight cascaded mode, ICT Express 10, Issue:1, pp: 9–14. <https://doi.org/10.1016/j.icte.2023.03.003>
- [16] Thupae, R., Isong, B., Gasela, N., Abu-Mahfouz, A., M., 2018, Machine Learning Techniques for Traffic Identification and Classification in SDWSN: A Survey, IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society, Washington, DC, USA, 2018, pp. 4645-4650, doi: 10.1109/IECON.2018.8591178.
- [17] Agarwa, A., 2020, Machine Learning and Deep Learning Frameworks and Libraries for Large-Scale Data Mining, International Journal of Science and Research (IJSR), Vol. 9, Issue 8. DOI: 10.21275/SR20804130059.
- [18] Xie, J., Liu, R., Luttrell, J., Zhang, C., 2019, Deep Learning Based Analysis of Histopathological Images of Breast Cancer, Front. Genet., Sec. Computational Genomics, Vol. 10. DOI:<https://doi.org/10.3389/fgene.2019.00080>
- [19] Khan, N., Singh, A., V., Agrawal, A., 2022, Enhanced Deep Learning Hybrid Model Of CNN Based On Spatial Transformer Network For Facial Expression Recognition, Int. J. Pattern Recognit. Artif. Intell., Vol. 36, No. 14. Doi: 10.1142/S0218001422520280.
- [20] Alnussairi, M. H. D., Ibrahim, A., A., 2022, Malaria parasite detection using deep learning algorithms based on (CNNs) technique, Computers and Electrical Engineering 103, 108316. <https://doi.org/10.1016/j.compeleceng.2022.108316>
- [21] Kumar, T., Ponnusamy, R., 2023, Design of Barnacle Mating Optimizer with Deep Learning Based Classification Model for Medical X-Ray Images, International Journal of Intelligent Engineering and Systems, Vol.16, No.6. DOI:10.22266/ijies2023.1231.04.
- [22] Zhao, C., Tang, H., McGonigle, D., He, Z., Zhang, C., Wang, Y., Deng, H.W., Bober, R., Zhou, W., 2022, Development of an approach to extracting coronary arteries and detecting stenosis in invasive coronary angiograms, Journal of Medical Imaging, Vol. 9, Issue 4, 044002. <https://doi.org/10.1117/1.JMI.9.4.044002>
- [23] Chen, Y., Lin, Y., Wang, C., Lee, C., Lee, W., Wang, T., *et. al.*, 2019, Coronary Artery Segmentation in Cardiac CT Angiography Using 3D Multi-Channel U-net, MIDL. <https://doi.org/10.48550/arXiv.1907.12246>
- [24] Wu, W., Zhang, J., Xie, H., Zhao, Y., Zhang, S, Gu, L., 2020. Automatic Detection of Coronary Artery Stenosis by Convolutional Neural Network with

- Temporal Constraint. Computers in Biology and Medicine 118, 103657. <https://doi.org/10.1016/j.combiomed.2020.103657>.
- [25] Di Cesare, M., Perel P, Taylor, S., Kabudula, C., Bixby H, Gaziano, T.A., *et. al.*, 2025, The Heart of the World. Glob Heart 2024,19(1):11. doi: 10.5334/gh.1288. PMID: 38273998; PMCID: PMC10809869.
- [26] S.L. Oh, E. Y. Ng. R. San Tan, U. R. Acharya, 2018, Automated diagnosis of arrhythmia using combination CNN and LSTM Techniques with variable length heart beats. Computer in biology and medicine volume 102, 278-287. DOI: 10.1016/j.combiomed.2018.06.002.
- [27] Oh, S. L., Eddie, Y. Ng., Tan, S. R., Acharya, U. R., 2019, Automated Beat wise Arrhythmia Diagnosis Using Modified U-Net on Extended Cardiographic Recordings with Heterogenous Arrhythmia Types. Computer in biology and medicine. DOI: 10.1016/j.combiomed.2018.12.012 105, 92-101.
- [28] Sharma M., Tan, R. S., Acharya, U. R., 2019, Automated heartbeat classification and detection of arrhythmia using optimal orthogonal wavelet filter, Informatic in medicine Unlocked 16, 100221. <https://doi.org/10.1016/j.imu.2019.100221>.
- [29] Kermani, S., Oghli, M. G., Mohammadzadeh, A., Kafieh, R., 2020, NF-RCNN: Heart Localization and Right Ventricle Wall Motion Abnormality Detection in Cardiac MRI, Physica Medica 70, 65–74. <https://doi.org/10.1016/j.ejmp.2020.01.011>.
- [30] Acharya, U. R., Fujita, H., Sudarshan, V. K., Oh, S. L., Adam, M., Tan, J., H., Koo, J. H., Jain, A., Lim, C., M., Chua, K., C., 2017, Automated characterization of coronary artery disease, myocardial infarction, and congestive heart failure using contourlet and shearlet transforms of electrocardiogram signal, Knowledge-Based Systems, Volume 132, 2017, Pages 156-166. <https://doi.org/10.1016/j.knosys.2017.06.026>
- [31] Kong, B., Wang, X., Bai, J., Lu, Y., Gao, F., Cao, K., Xia, J., Song, Q., Yin, Y., 2020, Learning tree-structured representation for 3D coronary artery segmentation, Computerized Medical Imaging and Graphics, 80, 101688. <https://doi.org/10.1016/j.compmedimag.2019.101688>
- [32] Samanta, P., Pathak, A., Mandana, K., Saha, G, 2019, Classification of Coronary Artery Diseased and Normal Subjects Using Multi-Channel Phonocardiogram Signal. Biocybernetics and Biomedical Engineering 39, 2, 426-443. <https://doi.org/10.1016/j.bbe.2019.02.003>.
- [33] Nassif, A. B., Mahdi, O., Nasir, Q., Talib, M. A., Azzeh, M., 2018. Machine Learning Classifications of Coronary Artery Disease. 2018 International Joint Symposium on Artificial Intelligence and Natural Language Processing (iSAI-NLP), Pattaya, Thailand, IEEE, 1-6. doi: 10.1109/iSAI NLP.2018.8692942.
- [34] Shahid, A. H., Singh, M. P., Roy, B., and Aadars, A., 2020, Coronary Artery Disease Diagnosis Using Feature Selection Based Hybrid Extreme Learning Machine, 2020 3rd International Conference on Information and Computer Technologies (ICICT), San Jose, CA, USA, 2020, pp. 341-346, doi: 10.1109/ICICT50521.2020.00060.

- [35] Zhao, F., Wu, B., Chen, F., Cao, X., Yi, H., Hou, Y., et. al., 2019. An Automatic Multi-Class Coronary Atherosclerosis Plaque Detection And Classification Framework. *Med Biol Eng Comput* 57, 245–257. <https://doi.org/10.1007/s11517-018-1880-6>.
- [36] Zreik, M., van Hamersveld, R. W., Wolterink, J. M., Leiner, T., Viergever, M. A., Isgum, I., 2019. A Recurrent CNN for Automatic Detection and Classification of Coronary Artery Plaque and Stenosis in Coronary CT Angiography. *IEEE Transactions on Medical Imaging*, 38, 7, 1588-1598. doi: 10.1109/TMI.2018.2883807.
- [37] Supani, A., Nurmaini, S., Radiyati Umi Partan, R. U., Suprapto, B. Y., 2024, The Classification of Coronary Artery Disease Using A Machine Learning Approach: A Preliminary Study, Atlantis press, Proceedings of the 7th FIRST 2023 International Conference on Global Innovations (FIRST-ESCSI 2023), Vol. 232 Series: advanced in enginering research (AER). https://doi.org/10.2991/978-94-6463-386-3_2
- [38] Muneeb, M., Nuzhat, N., Niazi, A. K., Khan, A. H., Chatha Z., Kazmi, T., et. al., 2023, Assessment of the Dimensions of Coronary Arteries for the Manifestation of Coronary Artery Disease, *Cureus*, 15(10): e46606. DOI: 10.7759/cureus.46606.
- [39] Au, B., Shaham, U., Dhruva, S., Bouras, G., Cristea, E., Lansky, A., et. al., 2018, Automated Characterization of Stenosis in Invasive Coronary Angiography Images with Convolutional Neural Networks. <https://doi.org/10.48550/arXiv.1807.10597>
- [40] Abdeltawab, H., Khalifa, F., Taher, F., Alghamdi, S., N., Ghazal, M., Beach, G., et. al., 2020, A deep learning-based approach for automatic segmentation and quantification of the left ventricle from cardiac cine MR images, *Computerized Medical Imaging and Graphics* 81, 101717. <https://doi.org/10.1016/j.compmedimag.2020.101717>
- [41] Rodrigues, D. L., Menezes, M. N., Pinto, F. J., Oliveira, A. L., 2021. Automated Detection of Coronary Artery Stenosis in X-ray Angiography Using Deep Neural Networks. <https://arXiv:2103.02969v1>.
- [42] Ovalle-Magallanes, E., Avina-Cervantes, J. G., Ruiz-Pinales, J., Cruz-Aceves, I., Transfer Learning for Stenosis Detection in X-ray Coronary Angiography, *Mathematics* 2020, 8, 1510; doi:10.3390/math8091510.
- [43] Moon, J. H., Lee, D. Y., Cha, W. C., Chung, M. J., Lee, K. S., Cho, B. H., et. al., 2021, Automatic Stenosis Recognition from Coronary Angiography Using Convolutional Neural Networks. *Computer Methods and Programs in Biomedicine* 198, 105819. <https://doi.org/10.1016/j.cmpb.2020.105819>
- [44] Zreik, M., Leiner, T., Khalili, N., van Hamersveld, R. W., Wolterink, J. M., Voskuil, M., et. al., 2019, Combined Analysis of Coronary Arteries and The Left Ventricular Myocardium in Cardiac CT Angiography for Detection of Patients with Functionally Significant Stenosis. <http://arXiv:1911.04940v1>.
- [45] Widianti, L., W., Sudiro, S., A., Madenda, S., Harlan, S., 2020, Cropping Method on Grayscale Images for Periapical Radiographs of Human Teeth, *IOP Conf. Series: Materials Science and Engineering* 879, 012114, doi:10.1088/1757-899X/879/1/012114.

- [46] Liu, Y., Zhang, X., Wan, W., Liu, S., Liu, Y., Liu, H., *et. al.*, 2022, Two New Stenosis Detection Methods of Coronary Angiograms. *Int J CARS.*, 17, 521–530. https://doi.org/10.1007/s11548_021-02551-6.
- [47] Li, Y., Wu, Y., He, J., Jiang, W., Wang, J., Peng, Y., *et. al.*, 2022, Automatic Coronary Artery Segmentation and Diagnosis of Stenosis by Deep Learning Based on Computed Tomographic Coronary Angiography. *Eur Radiol* 32, 6037–6045. <https://doi.org/10.1007/s00330-022-08761-z>.
- [48] Kirisli, H. A., Schaap, M., Metz, C. T., Dharampal, A., S., Meijboom, W. B., Papadopoulou, S. L., *et. al.*, 2013, Standardized evaluation framework for evaluating coronary artery stenosis detection, stenosis quantification and lumen segmentation algorithms in Computed Tomography Angiography, *Medical Image Analysis* 17, 859–876. <http://dx.doi.org/10.1016/j.media.2013.05.007>.
- [49] Paul, J. F., Rohnean, A., Giroussens H., Pressat-Laffouilhere, T., Wong, T., 2022. Evaluation of a Deep Learning Model on Coronary CT Angiography for Automatic Stenosis Detection. *Diagnostic and Interventional Imaging* 103, 316–323. <https://doi.org/10.1016/j.diii.2022.01.004>.
- [50] Wolterink, J. M., Leiner, T., and Isgum, I., 2019, Graph Convolutional Networks for Coronary Artery Segmentation in Cardiac CT Angiography. <https://doi.org/10.48550/arXiv.1908.05343>.
- [51] Yang, J., Tong, L., Faraji, M., Basu, A., 2018. IVUS-Net: An Intravascular Ultrasound Segmentation Network. <https://arXiv:1806.03583v2>
- [52] Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., De, D., 2020, Fundamental Concepts of Convolutional Neural Network. In: Balas, V., Kumar, R., Srivastava, R. (eds) Recent Trends and Advances in Artificial Intelligence and Internet of Things. Intelligent Systems Reference Library, vol 172. Springer, Cham. https://doi.org/10.1007/978-3-030-32644-9_36.
- [53] Taye, M. M., 2023. Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions, *Computation*, 11, 52. <https://doi.org/10.3390/computation11030052>.
- [54] Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adam, M., Gertych, A., San, T., R., 2017. A Deep Convolutional Neural Network Model to Classify Heartbeats, *Comput. Biol. Med.*, 89, 389–396. doi: [10.1016/j.compbio.2017.08.022](https://doi.org/10.1016/j.compbio.2017.08.022).
- [55] Chen, C., Hua, Z., Zhang, R., Liu, G., Wen. W., 2020. Automated Arrhythmia Classification Based on A Combination network of CNN and LSTM, *Biomed. Signal Process. Control*, 57, 101819. doi: [10.1016/j.bspc.2019.101819](https://doi.org/10.1016/j.bspc.2019.101819).
- [56] Krichen, M., 2023, Convolutional Neural Networks, *Computers*, 12, 151. <https://doi.org/10.3390/computers12080151>.
- [57] Raj, R., Kos, A., 2025, An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions. *Sensors*, 25, 1033. <https://doi.org/10.3390/s25041033>.
- [58] Jiang, S., Qin, S., Pulcipher, J. L., and Zavala, V. M., 2022, Convolutional Neural Networks: Basic Concepts and Applications in Manufacturing. <https://doi.org/10.48550/arXiv.2210.07848>.

- [59] Zafar, A., Saba, N., Arshad, A., Alabrah, A., Riaz, S., Suleman, M., Zafar, S., Nadeem, M., 2024, Convolutional Neural Networks: A Comprehensive Evaluation and Benchmarking of Pooling Layer Variants. *Symmetry*, 16, 1516. <https://doi.org/10.3390/sym16111516>.
- [60] Alzubaidi, L., Zhang, J., Humaidi, A. J., Ayad Al-Dujaili, A., Ye Duan, Y., Omran Al-Shamma, O., Santamaría, J., Mohammed A. Fadhel, M. A., Al-Amidie, M., and Farhan, L., Review of deep learning: concepts, CNN architectures, challenges, applications, future directions, *J Big Data*, 8:53, <https://doi.org/10.1186/s40537-021-00444-8>.
- [61] Koushik, J., 2016, Understanding Convolutional Neural Networks. <https://doi.org/10.48550/arXiv.1605.09081>.
- [62] Agarap, A., F., 2018, Deep Learning using Rectified Linear Units (ReLU). <https://doi.org/10.48550/arXiv.1803.08375>.
- [63] Bai, Y., 2022, RELU-Function and Derived Function Review, *SHS Web of Conferences*, 144, 02006. <https://doi.org/10.1051/shsconf/202214402006>
- [64] Mehra, S, Raut, G., Kumarvishvakarma, S., Biasizzo, A., 2022, An Empirical Evaluation of Enhanced Performance Softmax Function in Deep Learning. *IEEEAccess*, Vol. 4. DOI: 10.1109/ACCESS.2023.3265327.
- [65] Hamdan, M. H., Roach, D. C., 2022, The Sigmoid Neural Network Activation Function and its Connections to Airy's and the Nield-Kuznetsov Functions. DOI: 10.37394/232020.2022.2.13.
- [66] Ioffe, S., Szegedy, C., 2015, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. <https://doi.org/10.48550/arXiv.1502.03167>.
- [67] Salehin, I., Kang, D.-K., 2023, A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain. *Electronics*, 12, 3106. <https://doi.org/10.3390/electronics12143106>.
- [68] Zhuang, Z., Liu, M., Cutkosky, A., 2022, Understanding AdamW through Proximal Methods and Scale-Freeness. *arXiv:2202.00089v1*.
- [69] Kingma, D., P., Ba, J., L., 2017, ADAM: A Method For Stochastic Optimization. <https://doi.org/10.48550/arXiv.1412.6980>.
- [70] Sun, H., Zhou, W., Yang, J., Shao, Y., Xing, L., Zhao, Q., Zhang, L., 2024, An Improved Medical Image Classification Algorithm Based on Adam Optimizer, *Mathematics*, 12, 2509. <https://doi.org/10.3390/math12162509>.
- [71] Dereich, S, Jentzen, A., Riekert, A., 2025, Averaged Adam accelerates stochastic optimization in the training of deep neural network approximations for partial differential equation and optimal control problems. <https://doi.org/10.48550/arXiv.2501.06081>.
- [72] Jadon, S., 2020, A survey of loss functions for semantic segmentation, <https://doi.org/10.1109/CIBCB48159.2020.9277638>.
- [73] Ciampiconi, L., Elwood, A., Leonardi, M., Ashraf Mohamed, A., Rozza, A. 2025, A survey and taxonomy of loss functions in machine learning, <https://doi.org/10.48550/arXiv.2301.05579>.

- [74] Sithamparanathan, S., Padley, S. P. G., Rubens, M. B., Gatzoulis, M. A., Ho, S. Y., Nicol, E. D., 2013. Great Vessel and Coronary Artery Anatomy in Transposition and Other Coronary Anomalies, *Cardiovascular Imaging*, 6, 5. <http://dx.doi.org/10.1016/j.jcmg.2012.10.027>.
- [75] Maherian, E., Maulana, R., Syauqy, D., 2021. Implementasi Sistem Pendekripsi Myocardial Ischemia menggunakan Metode Support Vector Machine (SVM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5, 9, 3917-3923. <http://j-ptiik.ub.ac.id>.
- [76] Satoto, H. H., Patofisiologi Penyakit Jantung Koroner, 2014. *Anestesiologi Indonesia*, VI, 3, 209-224. DOI: <https://doi.org/10.14710/jai.v6i3.9127>.
- [77] Mishra, B. K., Thakker, D., Mazumdar, S., Neagu, D., Gheorghe, M., Simpson, S, 2020, A novel application of deep learning with image cropping: a smart city use case for flood monitoring, *Journal of Reliable Intelligent Environments*, 6:51–61. <https://doi.org/10.1007/s40860-020-00099-x>.
- [78] Wang, S., Sun, G., Zheng, B., Du, Y., 2021, A Crop Image Segmentation and Extraction Algorithm Based on Mask RCNN. *Entropy*, 23, 1160. <https://doi.org/10.3390/e23091160>.
- [79] Kakaei, S., 2021, Automatic Image Cropping And Semantic Object Selection, *Journal Of Applied Intelligent Systems & Information Sciences*, VoL. 2, Issue 2, PP. 22-32. DOI: <https://10.22034/JAISIS.2021.307161.1035>.
- [80] Ennab,M., Mccheick,H., 2025, Advancing AI Interpretability in Medical Imaging: A Comparative Analysis of Pixel-Level Interpretability and Grad-CAM Models. *Mach. Learn. Knowl. Extr.*, 7, 12. <https://doi.org/10.3390/make7010012>.
- [81] Wang, B., Si, H., Fu, H., Gao, R., Zhan, M., Jiang, H., Wang, A., 2023, Content-Aware Image Resizing Technology Based on Composition Detection and Composition Rules. *Electronics*, 12, 3096. <https://doi.org/10.3390/electronics12143096>.
- [82] Dickman, E., Diefenbach, P., 2024, A Hybrid Deep-Learning Approach to Content-Aware Image Retargeting and Resizing. *Electronics*, 13, 4459. <https://doi.org/10.3390/electronics13224459>.
- [83] Taha A.A., Hanbury A., 2015. Metrics for evaluating 3D Medical Image Segmentation: Analysis, Selection, And Tool. *BMC Medical Imaging*, 15, 29. DOI 10.1186/s12880-015-0068-x.
- [84] Hossin, M. and Sulaiman, M.N., 2015. A Review on Evaluation Metrics for Data Classification Evaluations. *International Journal of Data Mining & Knowledge Management Process (IJDkp)*, 5, 2. DOI: 10.5121/ijdkp.2015.5201.
- [85] Chicco, D. and Jurman, G., 2020. The Advantages of the Matthews Correlation Coefficient (MCC) over F1 Score and Accuracy in Binary Classification Evaluation. *BMC Genomics*, 21, 6. <https://doi.org/10.1186/s12864-019-6413-7>.
- [86] Supani, A. Alpian, Andriani, Y., Oktavianti, E., 2023. The Tuning of Machine Learning Models for The Classification of Cardiovascular Disease. 2023 6th International Conference of Computer and Informatics Engineering (IC2IE), Lombok, Indonesia, 979-8-3503-4516-2/23/\$31.00 ©2023 IEEE, 381-384. doi: 10.1109/IC2IE60547.2023.10331436.

- [87] Abuhayi, B. M. dan Mossa, A. A., 2023. Coffee Disease Classification Using Convolutional Neural Network Based on Feature Concatenation. *Informatics in Medicine Unlocked* 39, 101245. <https://doi.org/10.1016/j.imu.2023.101245>.
- [88] Bishop, C. M., 2006. Pattern Recognition and Machine Learning. Springer Science+Business Media, LLC, New York. Link: Bishop/Bishop - Pattern Recognition and Machine Learning.pdf.
- [89] Sun, J., Yang, S., Gao, X., Ou, D., Tian, Z., Wu, J., Wang, M. MASA-SegNet: A Semantic Segmentation Network for PolSAR Images. *Remote Sens.* 2023, 15, 3662. <https://doi.org/10.3390/rs15143662>.
- [90] Hasanah, S.A., Pravitasari, A.A., Abdullah, A.S., Yulita, I.N., Asnawi, M. H., 2023, A Deep Learning Review of ResNet Architecture for Lung Disease Identification in CXR Image. *Appl. Sci.* 13, 13111. <https://doi.org/10.3390/app132413111>.
- [91] Supani, A., Andriani, Y., Indarto, Saputra, H., Joni, A. B., Alfian, D., Taqwa, A., Handayani, A. S., "Enhancing Deeper Layers with Residual Network on CNN Architecture: A Review." *Proceedings of the 6th FIRST 2022 International Conference (FIRST 2022)*. Vol. 14. Springer Nature, 2023. DOI: 10.2991/978-94-6463-118-0_46.
- [92] Nechaev, D., Zhizhin, M., Poyda, A., Ghosh, T., Hsu, F.-C., Elvidge, C., 2021, Cross-Sensor Nighttime Lights Image Calibration for DMSP/OLS and SNPP/VIIRS with Residual U-Net. *Remote Sens.* 13, 5026. <https://doi.org/10.3390/rs13245026>.
- [93] Cong, C., Kato, Y., Vasconcellos, H. D., Lima, J., and Venkatesh, B., 2019, Automated Stenosis Detection and Classification in X-ray Angiography Using Deep Neural Network, 2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), San Diego, CA, USA, pp. 1301-1308, doi: 10.1109/BIBM47256.2019.8983033.
- [94] Jiang, Z., Ou, C., Qian, Y., Rehan, R., 2021, Coronary vessel segmentation using multiresolution and multiscale deep learning, *Informatics in Medicine Unlocked* 24, 100602. <https://doi.org/10.1016/j.imu.2021.100602>.
- [95] Stralen, P. V., Rodrigues, D., L., Menezes, M., N., Pinto, F. J., Oliveira, A. L., 2022, Stenosis Detection in X-ray Coronary Angiography with Deep Neural Networks Leveraged by Attention Mechanisms, *ICBRA 2022*. <https://doi.org/10.1145/3569192.3569212>.
- [96] AlOthman, A. F., Sait, A. R. W., and Alhussain, T. A., 2022, Detecting Coronary Artery Disease from Computed Tomography Images Using a Deep Learning Technique, *Diagnostics*, vol. 12, no. 9. doi: 10.3390/diagnostics12092073.
- [97] Z. Gao *et al.*, "Vessel segmentation for X-ray coronary angiography using ensemble methods with deep learning and filter-based features," *BMC Med. Imaging*, vol. 22, no. 1, pp. 1–17, 2022, doi: 10.1186/s12880-022-00734-4.
- [98] Eschen, C. K., Banasik, K., Anders Bjorholm Dahl, A. B., Chmura, P. J., Peter Bruun-Rasmussen, P., Pedersen, F., 2025, Automated stenosis estimation of coronary angiographies using end-to-end learning. *Int. J. Cardiovasc. Imaging*, vol. 41, no. 3, pp. 441–452, 2025. doi: 10.1007/s10554-025-03324-x.