

**PENGEMBANGAN SISTEM *COMPUTER-AIDED DETECTION AND
DIAGNOSIS* (CAD): ANALISIS CITRA KANKER PAYUDARA
BERDASARKAN *POSSIBILISTIC FUZZY C-MEANS* (PFCM) DAN
TRANSFER LEARNING MENGGUNAKAN *PSEUDO-STADIUM LABELING***

Skripsi

Oleh

**OJA WIDIYATAMA
NPM. 2217031136**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2026

ABSTRACT

DEVELOPMENT OF A COMPUTER-AIDED DETECTION AND DIAGNOSIS (CAD) SYSTEM: BREAST CANCER MAMMOGRAM ANALYSIS BASED ON POSSIBILISTIC FUZZY C-MEANS (FPCM) AND TRANSFER LEARNING USING PSEUDO-STADIUM LABELING

By

Oja Widiyatama

Breast cancer is one of the leading causes of cancer-related mortality among women, making early detection and accurate assessment of tumor severity critically important. Mammography, as the primary screening modality, faces challenges related to the high workload of radiologists and limitations in diagnostic consistency. Therefore, this study develops an integrated mammogram-based Computer-Aided Detection and Diagnosis (CAD) system that combines the Computer-Aided Detection (CAdE) and Computer-Aided Diagnosis (CAdx) phases within a single pipeline. In the CAdE stage, the Possibilistic Fuzzy C-Means (PFCEM) method is employed to perform automatic tumor area segmentation that is robust to noise and variations in image intensity. The resulting segmentation outputs are then utilized to generate semi-automatic pseudo-stadium labeling based on tumor size estimation, which is mapped to T1–T4 stages according to the AJCC–TNM standard. The CAdx stage applies a transfer learning (TL) approach to classify breast cancer severity levels. System evaluation includes cluster validation metrics at the CAdE stage as well as classification metrics and ROC–AUC analysis at the CAdx stage. Experimental results demonstrate that the DenseNet121 model achieves the best performance, with an accuracy of 0.9000, an F1-score of 0.8996, a micro-average AUC of 0.9804, and a macro-average AUC of 0.9783. These findings indicate that the proposed CAD system has strong potential to support automated early diagnosis and severity assessment of breast cancer.

Keywords: Breast Cancer, Mammography, Computer-Aided Detection and Diagnosis, Possibilistic Fuzzy C-Means, Transfer Learning.

ABSTRAK

PENGEMBANGAN SISTEM *COMPUTER-AIDED DETECTION AND DIAGNOSIS* (CAD): ANALISIS CITRA KANKER PAYUDARA BERDASARKAN *POSSIBILISTIC FUZZY C-MEANS* (PFCM) DAN *TRANSFER LEARNING* MENGGUNAKAN *PSEUDO-STADIUM LABELING*

Oleh

Oja Widiyatama

Kanker payudara merupakan salah satu penyebab utama kematian akibat kanker pada perempuan, sehingga deteksi dini dan penilaian tingkat keparahan tumor menjadi sangat penting. Pemeriksaan mammografi sebagai metode skrining utama menghadapi tantangan berupa beban kerja radiolog yang tinggi serta keterbatasan konsistensi diagnosis. Oleh karena itu, penelitian ini mengembangkan sistem *Computer-Aided Detection and Diagnosis* (CAD) terintegrasi berbasis citra mammogram yang menggabungkan fase *Computer-Aided Detection* (CADE) dan fase *Computer-Aided Diagnosis* (CADx) dalam satu *pipeline*. Pada tahap CADE, metode *Possibilistic Fuzzy C-Means* (PFCM) digunakan untuk melakukan segmentasi area tumor secara otomatis dan adaptif terhadap noise serta variasi intensitas citra. Hasil segmentasi selanjutnya dimanfaatkan untuk membentuk *pseudo-stadium labeling* secara semi-otomatis berdasarkan estimasi ukuran tumor yang dipetakan ke stadium T1–T4 sesuai standar AJCC–TNM. Tahap CADx dilakukan menggunakan pendekatan *transfer learning* (TL) untuk mengklasifikasikan tingkat keparahan kanker payudara. Evaluasi sistem mencakup metrik validasi kluster pada tahap CADE serta metrik klasifikasi dan ROC–AUC pada tahap CADx. Hasil eksperimen menunjukkan bahwa model DenseNet121 memberikan performa terbaik dengan *accuracy* 0.9000, *f1-score* 0.8996, *micro-average* AUC 0.9804 dan *macro-average* AUC sebesar 0,9783. Hasil ini menunjukkan bahwa sistem CAD yang dikembangkan berpotensi mendukung diagnosis dini dan penilaian tingkat keparahan kanker payudara secara otomatis.

Kata-kata kunci: Kanker Payudara, Mammografi, *Computer-Aided Detection and Diagnosis*, *Possibilistic Fuzzy C-Means*, *Transfer Learning*.

**PENGEMBANGAN SISTEM *COMPUTER-AIDED DETECTION AND
DIAGNOSIS (CAD)*: ANALISIS CITRA KANKER PAYUDARA
BERDASARKAN *POSSIBILISTIC FUZZY C-MEANS (PFCM)* DAN
TRANSFER LEARNING MENGGUNAKAN *PSEUDO-STADIUM LABELING***

OJA WIDIYATAMA

Skripsi

Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2026

Judul Skripsi : **PENGEMBANGAN SISTEM
COMPUTER-AIDED DETECTION AND
DIAGNOSIS (CAD): ANALISIS CITRA
KANKER PAYUDARA BERDASARKAN
POSSIBILISTIC FUZZY C-MEANS
(PFCM) DAN TRANSFER LEARNING
MENGUNAKAN PSEUDO-STADIUM
LABELING**

Nama Mahasiswa : **Oja Widiyatama**

Nomor Pokok Mahasiswa : **2217031136**

Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**




Dr. Dian Kurniasari, S.Si.,M.Sc.
NIP. 198406272006042001


Dr. Purnomo Husnul Khotimah, M.T.
NIP. 198003232005022002

2. Ketua Jurusan Matematika


Dr. Aang Nuryaman, S.Si.,M.Si.
NIP. 197403162005011001

MENGESAHKAN

I. Tim Penguji

Ketua : Dr. Dian Kurniasari, S.Si., M.Sc.



Sekretaris : Dr. Purnomo Husnul Khotimah,
M.T.



Penguji
Bukan Pembimbing : Ir. Warsono, M.S., Ph.D.



2 Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam




Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: 28 Januari 2026

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : Oja Widiyatama
Nomor Pokok Mahasiswa : 2217031136
Jurusan : Matematika
Judul Skripsi : **Pengembangan Sistem *Computer-Aided Detection and Diagnosis* (CAD): Analisis Citra Kanker Payudara Berdasarkan *Possibilistic Fuzzy C-Means* (PFCM) dan *Transfer Learning* Menggunakan *Pseudo-Stadium Labeling***

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 28 Januari 2026

Penulis


F1737ANX247661344
Oja Widiyatama

RIWAYAT HIDUP

Penulis bernama Oja Widiyatama, lahir di Gilih Suka Negeri pada 11 Agustus 2005. Penulis merupakan anak kedua dari lima bersaudara yang berasal dari pasangan Bapak Junaidi dan Ibu Sumiyati.

Pendidikan formal penulis dimulai dari Sekolah Dasar (SD) di SD Negeri Cabang Abung Raya, kemudian dilanjutkan ke Sekolah Menengah Pertama (SMP) di SMP Negeri 2 Abung Selatan, dan Sekolah Menengah Atas (SMA) di SMA Negeri 1 Anak Ratu Aji. Pada tahun 2022, penulis terdaftar sebagai mahasiswa Program Studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Universitas Lampung, dan secara aktif mengikuti kegiatan akademik selama masa studi.

Selama menempuh pendidikan di perguruan tinggi, penulis memiliki ketertarikan pada bidang matematika dan statistika, khususnya dalam analisis data, *machine learning*, dan *artificial intelligence*. Ketertarikan tersebut diwujudkan melalui keikutsertaan dalam berbagai kompetisi nasional, antara lain Lomba SATRIA DATA tahun 2024 dan 2025 serta GEMASTIK tahun 2024 dan 2025. Selain itu, penulis juga aktif dalam kegiatan organisasi kemahasiswaan, di antaranya sebagai Ketua Bidang Keilmuan Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) Universitas Lampung periode 2024 dan Koordinator Sponsor dan Keamanan Dies Natalis Jurusan Matematika (DINAMIKA) ke-XXV.

Selain kegiatan akademik dan organisasi, penulis memiliki pengalaman magang di berbagai instansi, antara lain di Regional Office Bank Rakyat Indonesia (BRI) Bandar Lampung, Badan Riset dan Inovasi Nasional (BRIN), serta Kantor Perwakilan Bank Indonesia Provinsi Lampung. Pengalaman magang tersebut memberikan wawasan mengenai penerapan ilmu pengetahuan, analisis data, serta proses kerja di lingkungan profesional dan institusi strategis.

KATA INSPIRASI

“Tapi skripsinya dibantu sama pacarnya”

Rapatin semua barisan kita gelar sajadah memohon bantuan sama ALLAH SWT.

#IZIN #PRINSIP

“Selalu menerapkan ATM (Aman, Tenang, Menang)”

Karena yang tenang selalu menang.

#IZIN #PRINSIP

“Kesabaran dan ketekunan adalah kunci dari setiap keberhasilan.”

(Ki Hajar Dewantara)

”Please, normalisasi saling support temen saat fase skripsian. Sekedar ngasih saran kalo mereka kebingungan, bimbingan bareng, atau ngerjain skripsi bareng. Jangan rusak pertemanan karena ego pengen unggul sendiri. Ingatlah skripsi bukan perlombaan!”

PERSEMBAHAN

Dengan mengucapkan Alhamdulillah dan syukur kepada Allah SWT atas nikmat serta hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan rasa syukur dan Bahagia, saya persembahkan rasa terimakasih saya kepada:

Ayah dan Ibuku Tercinta

Terimakasih kepada orang tuaku atas segala pengorbanan, motivasi, doa dan ridho serta dukungannya selama ini. Terimakasih telah memberikan pelajaran berharga kepada anakmu ini tentang makna perjalanan hidup yang sebenarnya sehingga kelak bisa menjadi orang yang bermanfaat bagi banyak orang.

Dosen Pembimbing dan Pembahas

Terimakasih kepada dosen pembimbing dan pembahas yang sudah sangat membantu, memberikan motivasi, memberikan arahan serta ilmu yang berharga.

Sahabat-sahabatku

Terimakasih kepada semua orang-orang baik yang telah memberikan pengalaman, semangat, motivasinya, serta doa-doanya dan senantiasa memberikan dukungan dalam hal apapun.

Almamater Tercinta

Universitas Lampung

SANWACANA

Alhamdulillah, puji dan syukur penulis panjatkan kepada Allah SWT atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini yang berjudul "Pengembangan Sistem *Computer-Aided Detection and Diagnosis* (CAD): Analisis Citra Mammogram Berdasarkan *Possibilistic Fuzzy C-Means* (PFCM) dan *Transfer Learning* Menggunakan *Pseudo-Stadium Labeling*" dengan baik dan lancar serta tepat pada waktu yang telah ditentukan. Shalawat serta salam semoga senantiasa tercurahkan kepada Nabi Muhammad SAW.

Dalam proses penyusunan skripsi ini, banyak pihak yang telah membantu memberikan bimbingan, dukungan, arahan, motivasi serta saran sehingga skripsi ini dapat terselesaikan. Oleh karena itu, dalam kesempatan ini penulis mengucapkan terimakasih kepada:

1. Ibu Dr. Dian Kurniasari, S.Si., M.Sc. selaku Pembimbing 1 yang telah banyak meluangkan waktunya untuk memberikan arahan, bimbingan, motivasi, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Purnomo Husnul Khotimah, M.T. selaku Pembimbing II yang telah memberikan arahan, bimbingan dan dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Bapak Ir. Warsono, M.S., Ph.D. selaku Penguji yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Ibu Dr. Fitriani, S.Si., M.Sc. selaku dosen pembimbing akademik.
6. Seluruh dosen, staff dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

7. Keluarga tercinta, terutama untuk Bapak Junaidi dan Ibu Sumiyati, terima kasih atas doa yang tidak pernah putus, pengorbanan yang tidak pernah terlihat, serta kepercayaan yang selalu diberikan dalam setiap langkah yang dijalani. Setiap proses panjang yang dilalui tidak lepas dari dukungan, kesabaran, dan kasih sayang yang selalu menguatkan, bahkan di saat penulis merasa lelah dan ragu. Kepada adik-adik tersayang, Cinta Pramudia, Faizza Cantika Alya Rahmadani, dan Azzahira Nur Adzkiyya, terima kasih telah menjadi sumber semangat terbesar dalam perjalanan ini. Kehadiran kalian menjadi pengingat untuk terus berjuang, bermimpi lebih tinggi, dan berusaha menjadi pribadi yang lebih baik.
8. Sahabat-sahabat tersayang, terima kasih kepada teman-teman dari MBKM BRIN dan satu bimbingan yang telah menemani, mendukung, dan menguatkan selama proses perjalanan ini. Terima kasih secara khusus kepada Fatur, Anita, dan Erin yang hadir di kedua perjalanan tersebut dan menjadi teman seperjuangan dalam berbagai proses. Terima kasih juga kepada sahabat MBKM BRIN, Annisa dan Nazla, serta sahabat satu bimbingan, Fadilah, Khusni, Mei, Nadia, Rizki, dan Benaya, atas kebersamaan, diskusi, dan semangat yang membuat setiap proses terasa lebih ringan. Kehadiran kalian menjadi bagian berharga dalam perjalanan ini dan semoga persahabatan ini tetap terjaga ke depannya.
9. Keluarga Besar HIMATIKA Periode 2023 dan Pimpinan HIMATIKA Periode 2024, terima kasih atas kebersamaan, kepercayaan, dan pengalaman berharga yang telah diberikan selama berproses bersama. Dukungan, kerja sama, serta ruang untuk bertumbuh yang diberikan menjadi bagian penting dalam perjalanan dan pembentukan karakter penulis.

Semoga skripsi ini dapat bermanfaat bagi kita semua. Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, sehingga penulis mengharapkan kritik dan saran yang membangun untuk menjadikan skripsi ini lebih baik lagi.

Bandar Lampung, 28 Januari 2026

Oja Widiyatama

DAFTAR ISI

Halaman

DAFTAR ISI.....	xiii
DAFTAR TABEL.....	xvi
DAFTAR GAMBAR.....	xvii
I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	7
II TINJAUAN PUSTAKA	8
2.1 Penelitian Terkait	8
2.2 Kanker Payudara	12
2.3 Citra Mammogram	13
2.4 <i>Artificial Intelligence</i> (AI)	14
2.4.1 <i>Machine Learning</i> (ML)	15
2.4.2 <i>Deep Learning</i> (DL)	16
2.4.3 <i>Convolutional Neural Network</i> (CNN)	17
2.4.4 <i>Transfer Learning</i> (TL)	22
2.4.5 <i>Computer-Aided Detection and Diagnosis</i> (CAD)	32
2.5 <i>Image Preprocessing</i>	33
2.5.1 <i>Image Format Conversion</i>	33
2.5.2 <i>Additive Noise Reduction</i>	34
2.5.3 <i>Multiplicative Noise Reduction</i>	34
2.5.4 <i>Image Enhancement</i>	34
2.5.5 <i>Background Removal</i>	35
2.5.6 <i>Pectoral Muscle Removal</i>	35

2.5.7	<i>Resize</i>	36
2.5.8	<i>Intensity Normalization</i>	36
2.5.9	<i>Cropping</i>	36
2.6	<i>Image Segmentation</i>	37
2.6.1	<i>Region of Interest (ROI)</i>	37
2.6.2	<i>Possibilistic Fuzzy C-Means (PFCM)</i>	38
2.6.3	Metrik Evaluasi <i>Clustering</i>	43
2.7	<i>Klasifikasi</i>	45
2.7.1	Augmentasi Data	46
2.7.2	<i>Stratified Splitting</i>	47
2.7.3	<i>Hyperparameter Tuning</i>	48
2.7.4	Metrik Evaluasi Klasifikasi	50
III METODOLOGI PENELITIAN		55
3.1	Tempat dan Waktu Penelitian	55
3.1.1	Tempat Penelitian	55
3.1.2	Waktu Penelitian	55
3.2	Data dan Alat	55
3.2.1	Data	55
3.2.2	Alat	57
3.2.3	Metode Penelitian	58
IV HASIL DAN PEMBAHASAN.....		61
4.1	Input Data	61
4.2	<i>Preprocessing Data</i>	62
4.2.1	<i>Image Format Conversion</i>	63
4.2.2	<i>Additive Noise Reduction</i>	64
4.2.3	<i>Multiplicative Noise Reduction</i>	65
4.2.4	<i>Image Enhancement</i>	66
4.2.5	<i>Background Removal</i>	67
4.2.6	<i>Pectoral Muscle Removal</i>	68
4.2.7	<i>Resize</i>	69
4.2.8	<i>Intensity Normalization</i>	70
4.2.9	<i>Cropping</i>	71
4.3	<i>Image Segmentation</i>	74
4.3.1	<i>K Kluster Optimal</i>	74
4.3.2	<i>Region of Interest (ROI)</i>	77

4.3.3	<i>Feature Extraction</i>	81
4.3.4	<i>Mapping Pseudo-Stadium Labeling</i>	82
4.4	<i>Image Classification</i>	90
4.4.1	Augmentasi Data	90
4.4.2	<i>Stratified Splitting</i>	93
4.4.3	<i>Hyperparameter Tuning</i>	95
4.4.4	Evaluasi Model	100
4.5	Perbandingan dengan Metode <i>Benchmark</i>	187
V	KESIMPULAN DAN SARAN.....	190
5.1	Kesimpulan	190
5.2	Saran	192
	DAFTAR PUSTAKA.....	194

DAFTAR TABEL

Tabel	Halaman
1 Penelitian Terkait	9
2 Hasil Evaluasi Validitas Kluster	75
3 Hasil Evaluasi Validitas Kluster PFCM $K = 3$	80
4 Tranformasi Nilai <i>Radius</i> (r) ke Milimeter (mm)	84
5 <i>Membership Matrix</i>	87
6 <i>Typicality Matrix</i>	88
7 <i>Combined Matrix</i>	89
8 Distribusi Jumlah Sampel Augmentasi pada Setiap Label	92
9 Distribusi <i>Splitting Data</i> pada Setiap Skema	94
10 Konfigurasi <i>Hyperparameter</i> Pada Proses Pelatihan Model	96
11 Hasil Evaluasi Model dengan <i>Hyperparameter Tuning</i>	97
12 <i>Classification Report</i> Model InceptionV3	114
13 <i>Classification Report</i> Model VGG19	128
14 <i>Classification Report</i> Model ResNet50	140
15 <i>Classification Report</i> Model DenseNet121	153
16 <i>Classification Report</i> Model MobileNetV2	167
17 <i>Classification Report</i> Model EfficientNetB3	180
18 Hasil Evaluasi Model <i>Pre-trained</i>	182
19 Perbandingan Kinerja Sistem CAD dengan Metode <i>Benchmark</i>	188

DAFTAR GAMBAR

Gambar	Halaman
1 Arsitektur DL (Ghozia dkk., 2020)	16
2 Arsitektur CNN (Ayeni, 2022)	17
3 <i>Convolutional Layer</i> ((Bhatt dkk., 2021)	18
4 <i>Global Average Pooling</i> (Alzubaidi dkk., 2021)	20
5 <i>Average Pooling</i> (Bhatt dkk., 2021)	20
6 <i>Max Pooling</i> (Bhatt dkk., 2021)	20
7 <i>Fully Connected Layer</i> (Bhatt dkk., 2021)	21
8 Arsitektur TL (Tao dkk., 2020)	23
9 Arsitektur Inception (Yilmaz & Trocan, 2021)	25
10 Arsitektur InceptionV3 (Ikechukwu dkk., 2021)	25
11 Arsitektur VGG (Alzubaidi dkk., 2021)	26
12 Arsitektur VGG19 (Ikechukwu dkk., 2021)	26
13 Arsitektur ResNet (Alzubaidi dkk., 2021)	27
14 Arsitektur ResNet50 (Ikechukwu dkk., 2021)	27
15 Arsitektur DenseNet (Huang dkk., 2017)	28
16 Arsitektur DenseNet121 (Huynh dkk., 2022)	29
17 Arsitektur MobileNet (Al-Wesabi dkk., 2021)	30
18 Arsitektur MobileNetV2 (Al-Wesabi dkk., 2021)	30
19 Arsitektur EfficientNetB0 (<i>baseline</i>) (Alhichri dkk., 2021)	31
20 Arsitektur EfficientNetB3 (Alhichri dkk., 2021)	31
21 <i>Confusion Matrix</i> : (a) Biner; (b) <i>Multiclass</i> (Markoulidakis dkk., 2021)	54
22 Distribusi Data	56
23 Alur Penelitian	59
24 Sampel Input Data: (a) mdb001.pgm; (b) mdb002.pgm; (c) mdb005.pgm; (d) mdb010.pgm; (e) mdb012.pgm; (f) mdb013.pgm	62

25 Penerapan <i>Image Format Conversion</i> : (a) <i>Original image</i> (PGM); (b) PNG format	63
26 Penerapan <i>Additive Noise Reduction</i> : (a) PNG Format; (b) <i>Additive Noise Reduction</i>	64
27 Penerapan <i>Multiplicative Noise Reduction</i> : (a) <i>Additive Noise Reduction</i> ; (b) <i>Multiplicative Noise Reduction</i>	65
28 Penerapan <i>Image Enhancement</i> : (a) <i>Multiplicative Noise Reduction</i> ; (b) <i>Image Enhancement</i>	66
29 Penerapan <i>Background Removal</i> : (a) <i>Image Enhancement</i> ; (b) <i>Background Removal</i>	67
30 Penerapan <i>Pectoral Muscle Removal</i> : (a) <i>Background Removal</i> ; (b) <i>Pectoral Muscle Removal</i>	68
31 Penerapan <i>Resize</i> : (a) <i>Pectoral Muscle Removal</i> ; (b) <i>Resize</i>	69
32 Penerapan <i>Intensity Normalization</i> : (a) <i>Resize</i> ; (b) <i>Intensity Normalization</i>	70
33 Penerapan <i>Cropping</i> : (a) <i>Intensity Normalization</i> ; (b) <i>Cropping</i>	71
34 <i>Before-After</i> Sampel Data: (a) <i>Before</i> mdb001; (b) <i>After</i> mdb001; (c) <i>Before</i> mdb002; (d) <i>After</i> mdb002; (e) <i>Before</i> mdb005; (f) <i>After</i> mdb005; (g) <i>Before</i> mdb010; (h) <i>After</i> mdb010; (i) <i>Before</i> mdb012; (j) <i>After</i> mdb012	73
35 <i>Average</i> Metrik Evaluasi Setiap <i>K</i> : (a) PC; (b) PE; (c) FS; (d) XB	76
36 ROI: (a) <i>original_preprocessed_image</i> mdb001; (b) segmentasi mdb001; (c) <i>binary_mask</i> mdb001; (d) <i>original_preprocessed_image</i> mdb002; (e) segmentasi mdb002; (f) <i>binary_mask</i> mdb002; (g) <i>original_preprocessed_image</i> mdb005; (h) segmentasi mdb005; (i) <i>binary_mask</i> mdb005	78
37 <i>Average</i> Metrik Evaluasi: (a) PC; (b) PE; (c) FS; (d) XB	79
38 Ekstraksi Fitur <i>Centroid</i> (x, y) dan <i>Radius</i> (r)	82
39 Distribusi Frekuensi Diameter Tumor	85
40 Distribusi Hasil PFCM Diameter Tumor	85
41 Frekuensi Distribusi Kelas: (a) <i>Before</i> Augmentasi; (b) <i>After</i> Augmentasi	91
42 Penerapan Augmentasi Data: (a) Original; (b) <i>Rotation</i> ($5-10^\circ$); (c) <i>Horizontal Flip</i> ; (d) <i>Zoom/Scale</i> (0.9–1.1); (e) <i>Translation</i> (0.05–1.0); (f) <i>Rotation + Flip</i>	93
43 <i>Confusion Matrix</i> InceptionV3: (a) Tanpa Augmentasi; (b) Augmentasi	101
44 ROC-AUC InceptionV3: (a) Tanpa Augmentasi; (b) Augmentasi	114
45 <i>Confusion Matrix</i> VGG19: (a) Tanpa Augmentasi; (b) Augmentasi	116
46 ROC-AUC VGG19: (a) Tanpa Augmentasi; (b) Augmentasi	128
47 <i>Confusion Matrix</i> ResNet50: (a) Tanpa Augmentasi; (b) Augmentasi	130
48 ROC-AUC ResNet50: (a) Tanpa Augmentasi; (b) Augmentasi	141
49 <i>Confusion Matrix</i> DenseNet121: (a) Tanpa Augmentasi; (b) Augmentasi	142

50	ROC-AUC DenseNet121: (a) Tanpa Augmentasi; (b) Augmentasi	154
51	<i>Confusion Matrix</i> MobileNetV2: (a) Tanpa Augmentasi; (b) Augmentasi	155
52	ROC-AUC MobileNetV2: (a) Tanpa Augmentasi; (b) Augmentasi	167
53	<i>Confusion Matrix</i> EfficientNetB3: (a) Tanpa Augmentasi; (b) Augmentasi	169
54	ROC-AUC EfficientNetB3: (a) Tanpa Augmentasi; (b) Augmentasi	181

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Kanker payudara merupakan jenis kanker dengan prevalensi tertinggi pada perempuan di seluruh dunia dan menjadi salah satu penyebab utama kematian akibat kanker pada wanita. Berdasarkan laporan *Global Cancer Observatory* (GLOBOCAN) 2022 yang dirilis oleh *World Health Organization* (WHO), terdapat sekitar 2,3 juta kasus baru kanker payudara dengan lebih dari 670.000 kematian secara global pada tahun tersebut (Zhang dkk., 2025). Kanker ini tercatat sebagai jenis kanker paling umum pada perempuan di 157 dari 185 negara yang dipantau (WHO, 2025) (IARC, 2024). Menurut Kementerian Kesehatan RI (Kementerian Kesehatan RI, 2023), kanker payudara di Indonesia menempati urutan pertama dengan kasus baru mencapai 65.858 (16,6%) dari seluruh kasus kanker dan angka kematian 22.430 kasus (9,6%) pada tahun 2022. Tingginya angka kejadian dan kematian tersebut menegaskan urgensi program pencegahan, deteksi dini, serta penanganan yang komprehensif untuk meningkatkan peluang kesembuhan melalui intervensi dan pengobatan tepat waktu (Vijayargahavan dkk., 2023).

Salah satu metode utama yang digunakan untuk deteksi dini tersebut adalah pemeriksaan mammografi, yang mampu mengidentifikasi kelainan pada jaringan payudara bahkan sebelum gejala klinis muncul (Gao dkk., 2023). Banyaknya citra yang harus diperiksa dalam praktik klinis menyebabkan radiolog menghadapi beban kerja tinggi dan berisiko mengalami kelelahan visual maupun *oversight* yang berdampak pada terlewatnya kelainan halus (Gandomkar dkk., 2023). Kondisi tersebut menimbulkan tantangan bagi radiolog dalam menjaga konsistensi diagnosis dan efisiensi waktu pembacaan. Oleh karena itu, dibutuhkan sistem pendukung berbasis komputer yang mampu membantu proses deteksi maupun diagnosis lesi secara objektif dan cepat. Salah satu pendekatan yang berkembang untuk tujuan tersebut adalah sistem *Computer-Aided Detection and Diagnosis* (CAD), yang

dirancang sebagai *second opinion* bagi radiolog dalam menilai hasil mammogram secara otomatis (Firmino dkk., 2016).

Berbagai penelitian telah mengembangkan sistem CAD di berbagai bidang pencitraan medis untuk mengatasi keterbatasan tersebut. Pada kasus kanker paru, Firmino dkk. (2016) mengusulkan integrasi antara tahap *Computer-Aided Detecion* (CADE) dan *Computer-Aided Diagnosis* (CADx) guna menilai tingkat keganasan nodul paru, namun sistem tersebut masih bergantung pada input manual radiolog dan menunjukkan tingkat *false positives* (FP) yang cukup tinggi. Pendekatan lain dikembangkan oleh Liao dkk. (2023) melalui kombinasi *contrastive self-supervised learning* dan *transfer learning* (TL) untuk diagnosis *Non-Erosive Reflux Disease* (NERD), yang mampu meningkatkan akurasi klasifikasi meskipun masih terbatas pada prediksi biner tanpa pelabelan tingkat keparahan penyakit. Sementara itu, meta-analisis oleh Bang dkk. (2021) terhadap berbagai studi CAD untuk kanker *esofagus* menunjukkan performa tinggi dengan rata-rata *Area Under Curve* (AUC) mencapai 0,97, namun menyoroti kurangnya validasi eksternal, ketergantungan pada anotasi manual, serta minimnya sistem yang menggabungkan tahap deteksi dan diagnosis secara terintegrasi.

Pendekatan serupa juga diterapkan di bidang oftalmologi pada penelitian Jiang dkk. (2022) memanfaatkan arsitektur *Vision Transformer* untuk diagnosis retinopati berdasarkan citra *Optical Coherence Tomography* (OCT), yang berhasil mencapai akurasi hingga 99,69% tetapi masih berfokus pada klasifikasi penyakit tanpa tahapan deteksi atau *staging*. Penelitian Liu dkk. (2021) dalam diagnosis kelainan serviks mengembangkan sistem CAD berbasis *ResNet50* untuk klasifikasi citra kolposkopi dan menunjukkan performa sebanding dengan kolposkopis senior, meskipun proses anotasi *Region Of Interest* (ROI) masih dilakukan secara manual dan klasifikasi terbatas pada dua kategori keparahan. Sementara itu, Kim dkk. (2021) mengusulkan sistem CAD berbasis U-Net dan *Convolutional Neural Network* (CNN) untuk deteksi melanoma, yang mengintegrasikan tahap segmentasi dan klasifikasi dalam satu *pipeline*, namun akurasi klasifikasinya masih terbatas karena ukuran dataset yang kecil serta ketergantungan pada label manual.

Pengembangan sistem CAD juga menghadapi tantangan yang sejalan dalam konteks kanker payudara. Berbagai penelitian telah berupaya mengoptimalkan deteksi lesi dan klasifikasi jaringan menggunakan pendekatan berbasis *deep learning* (DL). Zebari dkk. (2021) melalui kajian sistematis menunjukkan bahwa meskipun metode

seperti CNN dan TL meningkatkan akurasi deteksi, sistem CAD masih bergantung pada anotasi manual dan belum mampu mengidentifikasi tingkat keparahan tumor secara otomatis. Maqsood dkk. (2022) kemudian memperkenalkan model TTCNN yang menggabungkan *texture feature fusion* dan TL untuk meningkatkan performa klasifikasi tiga kelas tersebut, sementara Rose dkk. (2022) mengusulkan model CAD-ORGSMN dengan *Optimal Region Growing Segmentation* dan *MobileNet* untuk meningkatkan efisiensi dan sensitivitas deteksi. Meskipun ketiganya berhasil mengoptimalkan deteksi jenis jaringan payudara, sistem-sistem tersebut masih terbatas pada klasifikasi konvensional tanpa mempertimbangkan stadium perkembangan tumor. Sebelum mencapai tahap klasifikasi tersebut, sistem CAD perlu memiliki mekanisme segmentasi yang kuat untuk memastikan area lesi dapat diidentifikasi secara akurat.

Kinerja CAD yang bergantung pada citra medis dipengaruhi secara signifikan oleh kualitas tahapan *preprocessing* dan segmentasi sebelum dilakukan proses deteksi maupun klasifikasi. Namun, tahap ini kerap menemui berbagai tantangan teknis. Citra mammogram sering kali mengandung *noise*, memiliki tingkat kontras rendah, serta menunjukkan variasi anatomi antarpasien yang tinggi (Rose dkk., 2022). Keberadaan struktur non-tumor seperti otot *pectoralis major* dan elemen latar belakang lain juga dapat mengaburkan batas antara jaringan normal dan abnormal karena kesamaan intensitas pada area superior citra (Larroza dkk., 2024). Tantangan lain muncul ketika perbedaan intensitas antara jaringan tumor dan sekitarnya tidak cukup signifikan, terutama pada payudara dengan densitas tinggi. Sehingga proses pemisahan lesi dari jaringan sehat menjadi sulit (Oza dkk., 2024). Kompleksitas tersebut menuntut penerapan metode segmentasi dan klusterisasi yang lebih adaptif serta tahan terhadap *noise* agar ROI dapat diisolasi dengan tepat. Kebutuhan ini menjadi fondasi penting dalam pengembangan sistem CADe yang andal sebagai tahap awal dari keseluruhan sistem CAD.

Beragam metode segmentasi dan klusterisasi seperti *Expectation Maximization-Gaussian Mixture Model* (EM-GMM), *K-Means*, *hierarchical clustering*, *Fuzzy C-Means* (FCM), *Possibilistic C-Means* (PCM), dan *Fuzzy Possibilistic C-Means* (FPCM) telah banyak diterapkan dalam analisis citra mammogram. Namun, masing-masing menghadapi keterbatasan yang memengaruhi akurasi serta stabilitas hasil. Misalnya EM-GMM dan *K-Means* sensitif terhadap inisialisasi dan jumlah klaster yang harus ditentukan di awal (Nisa dkk., 2025); (Salloum, 2025), sementara *hierarchical clustering* cenderung lambat serta

mudah terpengaruh oleh noise maupun pemilihan *linkage* yang bersifat heuristik (Taghipour-Gorjikolaie dkk., 2025). FCM memiliki keunggulan dalam menangani ketidakpastian batas antarjaringan, tetapi kinerjanya menurun ketika terdapat *noise* tinggi (Satriyanto dkk., 2024). Sebaliknya, PCM lebih tahan terhadap *outlier*. Namun, berpotensi menghasilkan *overlap* antar kluster apabila parameter tidak disetel dengan tepat (Chen dkk., 2024). Menanggapi konteks tersebut, *Possibilistic Fuzzy C-Means* (PFCM) hadir sebagai metode yang menggabungkan keunggulan FCM dan PCM serta sebagai pembaruan dari metode FPCM. Menjadikannya lebih tahan terhadap *noise*, adaptif terhadap variasi intensitas, serta mampu menghasilkan segmentasi yang stabil pada citra medis kompleks (Satriyanto dkk., 2024). Oleh karena itu, penelitian ini memanfaatkan PFCM sebagai komponen utama tahap ROI *Extraction* pada sistem CAD untuk mengidentifikasi area tumor secara otomatis dan adaptif, tanpa memerlukan anotasi manual dari radiolog.

Hasil segmentasi otomatis yang diperoleh melalui PFCM pada fase CADe kemudian dimanfaatkan untuk memperkenalkan inovasi utama dalam fase CADx pada penelitian ini, yaitu konsep *pseudo-stadium labeling*. Pendekatan ini melakukan pelabelan stadium tumor secara semi-otomatis berdasarkan estimasi ukuran area tumor yang dihitung dari nilai *radius* (r) pada ROI hasil segmentasi (LBBC, 2023). Nilai tersebut kemudian dipetakan ke dalam kategori stadium T1, T2, T3, dan T4 dengan mengacu pada standar *American Joint Committee on Cancer – Tumor, Node, Metastasis* (AJCC–TNM) (Teichgraeber dkk., 2021). Melalui proses ini, sistem mampu menghasilkan label stadium tumor tanpa intervensi manual dari ahli radiologi, sehingga mengurangi ketergantungan terhadap anotasi pakar yang selama ini menjadi hambatan utama dalam pengembangan dataset medis. *Pseudo-stadium labeling* dengan demikian berperan sebagai pendekatan *semi-supervised annotation* yang objektif dan efisien, sekaligus memperkenalkan elemen *explainability* karena label yang dihasilkan memiliki dasar metrik geometris yang dapat diverifikasi secara medis.

Tahap selanjutnya adalah proses klasifikasi berbasis TL yang memanfaatkan ROI hasil segmentasi PFCM beserta label semi-otomatis dari *pseudo-stadium labeling* sebagai data model. Pendekatan ini dipilih karena TL mampu memanfaatkan representasi fitur spasial dan tekstural yang telah dipelajari oleh model DL besar, kemudian menyesuaikannya dengan domain medis menggunakan jumlah data yang relatif terbatas (Rahman dkk., 2020). Integrasi antara PFCM (*unsupervised*), *pseudo-stadium labeling* (*semi-supervised*), dan TL (*supervised*) membentuk

sistem *hybrid* CAD yang menyatukan fungsi deteksi dan diagnosis dalam satu *pipeline* komprehensif. Pada *framework* ini, fase CADe berperan untuk mendeteksi dan mengekstraksi area tumor secara otomatis, sedangkan fase CADx berfungsi mengklasifikasikan tingkat keparahan tumor berdasarkan label stadium yang dihasilkan secara semi-otomatis. Pendekatan terintegrasi ini tidak hanya meningkatkan efisiensi dan akurasi diagnosis, tetapi juga membuka arah baru bagi penerapan metode *fuzzy-TL hybrid* dalam pengembangan sistem CAD cerdas yang adaptif terhadap variasi anatomi pasien.

Secara keseluruhan, penelitian ini memberikan tiga kontribusi utama dalam pengembangan sistem CAD untuk deteksi kanker payudara. Pertama, penerapan PFCM dengan evaluasi metrik internal yang terukur untuk menghasilkan segmentasi tumor yang lebih akurat dan adaptif terhadap variasi anatomi maupun *noise* citra. Kedua, pengembangan konsep *pseudo-stadium labeling* sebagai inovasi dalam *pseudo-annotated tumor staging*, yang memungkinkan pelabelan dilakukan secara semi-otomatis berdasarkan estimasi ukuran ROI tanpa memerlukan anotasi manual dari radiolog. Ketiga, integrasi antara PFCM, *pseudo-stadium labeling*, dan TL ke dalam satu kerangka kerja *hybrid* CAD yang menyatukan CADe dan CADx dalam pipeline terpadu. Keseluruhan pendekatan ini diharapkan dapat memberikan kontribusi terhadap pengembangan sistem CAD yang lebih adaptif, efisien, dan mandiri, sekaligus memperkuat peran kecerdasan buatan dalam mendukung diagnosis dini kanker payudara. Sebagai arah penelitian, Bab selanjutnya akan menguraikan secara rinci tahap-tahap implementasi mulai dari *preprocessing data* mammogram, penerapan PFCM untuk segmentasi ROI, rancangan mekanisme *pseudo-stadium labeling*, hingga integrasi dengan model klasifikasi berbasis TL dan evaluasi performa sistem secara keseluruhan.

1.2 Rumusan Masalah

Berdasarkan pemaparan latar belakang tersebut, adapun rumusan masalah dalam penelitian ini diantaranya:

1. Bagaimana mengembangkan sistem CAD untuk analisis citra mammogram secara terintegrasi?
2. Bagaimana tahapan *preprocessing* dapat meningkatkan kualitas citra sehingga mendukung hasil deteksi dan klasifikasi yang lebih akurat pada sistem CAD?

3. Bagaimana metode PFCM dapat diterapkan pada tahap CADe untuk melakukan segmentasi area tumor?
4. Bagaimana hasil segmentasi CADe dapat dimanfaatkan untuk membentuk *pseudo-stadium labeling* berdasarkan ukuran tumor sesuai sistem AJCC–TNM sebagai dasar diagnosis pada tahap CADx?
5. Bagaimana model klasifikasi berbasis TL dapat diterapkan menggunakan *pseudo-stadium labeling* tersebut untuk menilai tingkat keparahan kanker payudara secara otomatis?
6. Bagaimana strategi evaluasi sistem CAD dapat dirancang untuk menilai performa tahap CADe dan CADx secara objektif dan komprehensif?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Mengembangkan sistem CAD yang terdiri dari dua tahap utama, yaitu CADe untuk deteksi area tumor dan CADx untuk klasifikasi tingkat keparahan kanker payudara.
2. Menerapkan tahapan *preprocessing* citra mammogram yang sistematis guna meningkatkan kualitas dan konsistensi citra sebelum analisis.
3. Mengimplementasikan metode PFCM sebagai pendekatan segmentasi pada tahap CADe untuk mendeteksi area tumor secara otomatis dan adaptif.
4. Menghasilkan *pseudo-stadium labeling* berdasarkan hasil segmentasi PFCM dengan mengacu pada sistem AJCC–TNM, sebagai dasar diagnosis pada tahap CADx.
5. Menerapkan model TL untuk klasifikasi kanker payudara berdasarkan *pseudo-stadium labeling* yang dihasilkan.
6. Menetapkan dan menerapkan strategi evaluasi sistem CAD secara menyeluruh, mencakup metrik performa tahap CADe dan CADx.

1.4 Manfaat Penelitian

Hasil dari penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Menyediakan pendekatan komprehensif untuk pengembangan sistem CAD pada kanker payudara berbasis citra mammogram.
2. Menghadirkan solusi CADe berbasis PFCM yang adaptif terhadap variasi intensitas dan noise, serta mampu melakukan segmentasi tumor secara otomatis.
3. Menghasilkan *pseudo-stadium labeling* sebagai inovasi dalam diagnosis tanpa memerlukan anotasi manual, sekaligus memperluas fungsionalitas sistem CAD dari sekadar deteksi menjadi diagnosis kuantitatif.
4. Menyediakan dataset berlabel *pseudo-stadium* yang dapat dimanfaatkan dalam pelatihan dan validasi model TL untuk diagnosis kanker payudara.
5. Memberikan kontribusi terhadap pengembangan *medical image analysis* melalui integrasi metode *unsupervised clustering* dan TL dalam satu *pipeline* CAD yang terukur dan efisien.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Berbagai penelitian mengenai CAD telah banyak dilakukan di bidang medis, khususnya pada analisis citra mammogram untuk deteksi dan diagnosis kanker payudara. Pendekatan yang digunakan dalam penelitian-penelitian tersebut beragam, di mana sebagian hanya berfokus pada tahap CAd untuk mendeteksi area abnormal, sebagian lainnya berfokus pada CADx untuk mengklasifikasikan jenis lesi, dan beberapa penelitian mengombinasikan keduanya menjadi *pipeline CAD end-to-end* yang mampu melakukan deteksi dan diagnosis secara otomatis. Secara umum, perbedaan juga ditemukan pada tahap segmentasi dan klasifikasi, di mana metode seperti *clustering*, *fuzzy logic*, serta *deep convolutional neural networks* banyak dimanfaatkan untuk memperoleh representasi fitur yang lebih adaptif. Meskipun demikian, mayoritas sistem CAD yang telah dikembangkan masih terbatas pada klasifikasi konvensional dengan tiga kelas utama, yaitu normal, *benign*, dan *malignant*.

Kondisi tersebut menunjukkan bahwa sistem CAD belum banyak diarahkan untuk mendukung analisis tingkat keparahan lesi berdasarkan kriteria klinis yang lebih rinci. Berdasarkan celah penelitian tersebut, penelitian ini berupaya mengimplementasikan sistem CAD yang tidak hanya melakukan segmentasi dan klasifikasi otomatis, tetapi juga menghasilkan label baru berupa *pseudo-stadium labeling*. Label ini dirancang untuk merepresentasikan tingkat keparahan lesi berdasarkan kategori stadium T1–T4 menurut klasifikasi AJCC–TNM, sehingga sistem CAD yang dikembangkan dapat memberikan keluaran yang lebih bermakna secara klinis dan mendukung estimasi tingkat progresivitas tumor. Ringkasan dari berbagai penelitian terdahulu yang berkaitan dengan pengembangan sistem CAD untuk deteksi dan diagnosis kanker payudara disajikan pada Tabel 1.

Tabel 1. Penelitian Terkait

No	Penelitian	Data	Sistem CAD	Hasil
1	TTCNN: A Breast Cancer Detection and Classification towards Computer-Aided Diagnosis Using Digital Mammography in Early Stages (Maqsood dkk., 2022)	CBIS - DDSM, INbreast, MIAS	CADx: Image Acquisition, Preprocessing, TTCN Architecture, Deep Feature Extraction (Transfer Learning), Feature Fusion, Classification	• CBIS - DDSM: Accuracy 99.08%, Sensitivity 99.19%, Specificity 98.96% • INbreast: Accuracy 96.82%, Sensitivity 95.99%, Specificity 97.68% • MIAS: Accuracy 96.57%, Sensitivity 96.11%, Specificity 97.03%
2	Computer-Aided Diagnosis for Breast Cancer Detection and Classification Using Optimal Region Growing Segmentation with MobileNet Model (Rose dkk., 2022)	Mini-MIAS	CAD: Preprocessing, Segmentation (CAdE), Feature Extraction, Hyperparameter Tuning, Classification (CADx)	Accuracy 86.26%, Sensitivity 93.51%, Specificity 77.68%, F1-Score 89.72%
3	An Integrated Computer-Aided Diagnosis BCanD Model for Detection, Segmentation, and Classification of Breast Cancer (Arfi dkk., 2024)	Mini-MIAS, BreakHis, INbreast	CAD: Preprocessing, Detection (CAdE), Segmentation (CAdE), Feature Extraction, Selection & Optimization, Classification (CADx)	• Mini-MIAS: Accuracy 98.11%, Sensitivity 97.86%, Specificity 98.40%, Dice 96.90% • BreakHis: Accuracy 97.24%, Sensitivity 96.65%, Specificity 97.82%, Dice 95.82% • INbreast: Accuracy 98.66%, Sensitivity 98.10%, Specificity 98.90%, Dice 97.25%
4	Artificial Intelligence Based Computer-Aided Diagnosis for Breast Cancer	Dataset screening kanker payudara (2015 – 2022)	AI-CAD: Detection (CAdE), Diagnosis (CADx), Confidence Scoring, Radiologist-AI Collaboration	• Radiologist 1 (Tanpa AI): Accuracy 80.4%, Sensitivity 84.2%, Specificity 78.6%, AUC 0.84

	<i>Detection on Digital Mammography in Hong Kong</i> (Yu dkk., 2024)			• Radiologist 2 (Tanpa AI): Accuracy 79.2%, Sensitivity 82.7%, Specificity 77.9%, AUC 0.82 • AI-CAD Otomatis: Accuracy 89.6%, Sensitivity 92.8%, Specificity 86.5%, AUC 0.93 • Radiologist + AI: Accuracy 91.3%, Sensitivity 94.9%, Specificity 88.2%, AUC 0.95
5	<i>A New Computer-Aided Diagnosis System for Breast Cancer Detection from Thermograms Using Metaheuristic Algorithms and Explainable AI</i> (Dihmani dkk., 2024)	DMR-IR	CAD-XAI: Preprocessing, Segmentation (CAdE), Feature Extraction, Selection, Classification (CADx), Explainability (XAI)	• CNN baseline: Accuracy 92.46%, Sensitivity 90.10%, Specificity 93.80%, AUC 0.94 • CNN+MPA: Accuracy 94.11%, Sensitivity 93.20%, Specificity 94.60%, AUC 0.96 • CNN+WOA: Accuracy 95.03%, Sensitivity 94.50%, Specificity 95.20%, AUC 0.97 • Proposed MPA-WOA+XAI: Accuracy 97.80%, Sensitivity 98.10%, Specificity 97.40%, AUC 0.99
6	<i>Computer-Aided Diagnosis of Breast Cancer from Mammogram Images Using Deep Learning Algorithms</i> (Dada dkk., 2024)	MaMaTT2	CADx: Preprocessing, Feature Extraction, Classification	• CNN: Accuracy 83.02%, Sensitivity 0.83, Specificity 0.93, Balanced Accuracy 0.87 • InceptionV3: Accuracy 60.93%, Sensitivity 0.68, Specificity 0.82, Balanced Accuracy 0.76

				• <i>EfficientNet-B4</i>: Accuracy 98.29%, Sensitivity 0.98, Specificity 0.99, Balanced Accuracy 0.99
7	<i>Transformative Approaches in Breast Cancer Detection: Integrating Transformers into Computer-Aided Diagnosis for Histopathological Classification</i> (Alwateer dkk., 2025)	BACH	<i>Twin-Stream CAD: Virchow2 (Histopathological Stream), Nomic (ViT Stream), Feature Fusion</i>	Average Accuracy 98.60%, Precision 97.28%, Sensitivity 97.20%, F1-Score 97.24%
8	BREAST - CAD: A Computer-Aided Diagnosis System for Breast Cancer Detection Using Machine Learning (Masoud dkk., 2025)	WDBC	Breast-CAD: Dataset & Model Selection, Training & Evaluation (CADx), Real-Time Diagnosis (IoT Integration)	• <i>Decision Tree</i>: Accuracy 0.97, Precision 0.97, Sensitivity 0.95, F1 0.96, AUC 0.97 • <i>SVM</i>: Accuracy 0.96, Precision 1.00, Sensitivity 0.89, F1 0.93, AUC 0.94 • <i>KNN</i>: Accuracy 0.95, Precision 1.00, Sensitivity 0.89, F1 0.93, AUC 0.94 • <i>NB</i>: Accuracy 0.94, Precision 0.94, Sensitivity 0.92, F1 0.93, AUC 0.94
9	(KAUH - BCUSD): Computer-Aided Breast Cancer Diagnosis Using Transformer and CNN Using Ultrasound Dataset (Alshdaifat dkk., 2025)	KAUH - BCUSD	CADx: Preprocessing, Feature Extraction, Classification	• <i>CNN</i>: Accuracy. 90.40%, Precision 93.48%, Sensitivity 86.86%, F1-Score 90.05% • <i>ViT</i>: Accuracy 68.89%, Precision 74.40%, Sensitivity 57.60%, F1-Score 64.93% • <i>VGG16</i>: Accuracy

				86.29%, <i>Precision</i> 75.98%, <i>Sensitivity</i> 97.64%, <i>F1-Score</i> 87.69% • <i>MobileNetV2</i> : <i>Accuracy</i> 86.60%, <i>Precision</i> 82.32%, <i>Sensitivity</i> 93.22%, <i>F1-Score</i> 87.43% • <i>ResNet50</i> : <i>Accuracy</i> 66.48%, <i>Precision</i> 62.21%, <i>Sensitivity</i> 83.89%, <i>F1-Score</i> 71.47% • <i>CNN+ViT (Proposed)</i> : <i>Accuracy</i> 95.12%, <i>Precision</i> 93.05%, <i>Sensitivity</i> 97.54%, <i>F1-Score</i> 95.24%
--	--	--	--	--

2.2 Kanker Payudara

Kanker payudara adalah penyakit yang ditandai oleh pertumbuhan *sel-epitel* atau *lobulus* payudara yang tidak terkendali, membentuk massa atau tumor dan berpotensi menyebar ke jaringan sekitarnya serta organ jauh melalui sistem *limfatik* atau peredaran darah (WHO, 2025). Seluruh proses biologis ini seringkali dipicu oleh akumulasi mutasi genetik, faktor hormon, dan faktor lingkungan yang menyebabkan sel kehilangan kontrol proliferasi dan diferensiasi. Karena sifatnya yang invasif dan kemampuannya untuk metastasis, kanker payudara menjadi fokus penting dalam upaya deteksi dini dan terapi yang tepat.

Secara epidemiologis, kanker payudara telah menjadi jenis kanker terbanyak di dunia pada perempuan. Menurut data dari WHO, pada 2022 diperkirakan sekitar 2,3 juta wanita di dunia menderita kanker payudara dengan sekitar 670 000 kematian (WHO, 2025). Laporan lain menunjukkan bahwa pada tahun 2020 terdapat lebih dari 2,3 juta kasus baru dan sekitar 685.000 kematian di seluruh dunia (Arnold dkk., 2022). Angka-angka ini menunjukkan bahwa beban penyakit ini sangat besar, terutama di negara-negara yang sedang mengalami transisi ekonomi dan peningkatan gaya hidup urban, di mana insidensi naik lebih cepat daripada kemajuan sistem *screening* atau pengobatan (Lei dkk., 2021).

Urgensi deteksi dini pada kanker payudara sangat tinggi karena ukuran dan luas penyebaran tumor pada saat diagnosis terbukti menjadi salah satu indikator utama prognosis pasien. Semakin kecil ukuran tumor saat ditemukan, misalnya dalam kategori awal maka keberhasilan terapi dan *survival rate* akan jauh lebih tinggi dibandingkan bila ditemukan pada ukuran besar atau telah menyebar ke jaringan lain (AACR, 2025). Karena itu, dalam konteks analisis citra medis seperti mammogram dan sistem berbasis komputer, kemampuan untuk mengukur dan mengekstrak ukuran tumor dari citra menjadi sangat penting sebagai bagian dari sistem pendukung keputusan.

Salah satu sistem klasifikasi yang banyak digunakan secara klinis adalah sistem *American Joint Committee on Cancer* (AJCC) dengan skema TNM (*Tumor, Node, Metastasis*) yang menilai tiga parameter utama: ukuran tumor primer (T), keterlibatan kelenjar getah bening (N), serta adanya metastasis jauh (M) (Teichgraeber dkk., 2021). Pada komponen “T”, kategori T1 hingga T4 membedakan ukuran dan penetrasi tumor; misalnya, T1 biasanya memiliki ukuran tumor ≤ 2 cm, T2 lebih dari 2 cm hingga ≤ 5 cm, T3 > 5 cm, dan T4 menunjukkan tumor yang menyusupi dinding dada atau kulit (LBBC, 2023). Karena ukuran tumor menjadi unsur kunci dalam stratifikasi risiko dan pilihan terapi, maka dalam penelitian citra medis, estimasi ukuran tumor dari hasil segmentasi citra berperan sebagai jembatan penting antara citra dan konteks klinis.

2.3 Citra Mammogram

Citra mammogram berfungsi sebagai modalitas utama dalam *screening* dan penegakan diagnosis awal *mammography* pada kanker payudara (Gandomkar dkk., 2023). Prinsip dasar mammogram adalah pemanfaatan sinar-X berenergi rendah yang diteruskan melalui payudara yang ditekan secara lembut, sehingga struktur jaringan di dalamnya termasuk jaringan lemak (*fatty tissue*), jaringan kelenjar (*glandular tissue*), dan area padat (*dense region*) akan mengurangi sinar X secara berbeda dan menghasilkan citra *grayscale* sebagai hasil proyeksi dua dimensi (Fico dkk., 2023). Area latar (*background*) maupun bagian luar payudara pada citra ini akan tampak dengan kontras lebih rendah dibandingkan struktur internal yang menyerap sinar lebih banyak.

Struktur citra mammogram kemudian secara khusus menampilkan komponen utama: jaringan lemak yang cenderung tampak lebih gelap (lebih sedikit redaman sinar X), jaringan kelenjar/*fibroglandular* yang menampilkan tingkat redaman menengah hingga tinggi, area berdensitas tinggi (*dense tissue*) yang tampak lebih terang, serta lesi atau tumor yang sering muncul sebagai massa atau bayangan bercak yang lebih terang atau berbeda tekstur dibanding jaringan sekitarnya (Garrucho dkk., 2023). Sistem klasifikasi BI-RADS (*Breast Imaging-Reporting and Data System*) juga mengaitkan kategori densitas jaringan payudara. Misalnya kategori A (*almost entirely fatty*), B (*scattered fibroglandular*), C (*heterogeneously dense*), hingga D (*extremely dense*) dengan intensitas citra mammogram dan sensitivitas deteksi lesi melalui mammogram (Nissan dkk., 2025).

Kualitas citra mammogram juga dipengaruhi oleh berbagai faktor teknis dan biologis, seperti *noise* berkas sinar-X tersebar atau detektor elektronik, artefak dari kompresi payudara, debu pada detektor, atau posisi payudara yang kurang optimal, kontras rendah ketika perbedaan redaman jaringan lemah, serta variasi posisi payudara atau ketebalan yang tidak seragam (Gulati dkk., 2022). Masalah khusus pada mammogram adalah otot pektoral (*pectoral muscle*) yang sering terlihat dalam proyeksi *Mediolateral-oblique* (MLO) dan dapat menghalangi atau membingungkan analisis area posterior payudara. Ketika otot pektoral muncul sebagai struktur terang atau bayangan dalam citra, hal ini dapat mengganggu proses segmentasi otomatis atau analisis berbasis komputer karena struktur tersebut dapat disalahartikan sebagai lesi atau mengaburkan jaringan penting (Larroza dkk., 2024).

2.4 Artificial Intelligence (AI)

Artificial Intelligence (AI) merupakan bidang ilmu komputasi yang berfokus pada pengembangan sistem atau mesin yang mampu melakukan tugas-tugas yang selama ini memerlukan kecerdasan manusia, seperti pengenalan pola, inferensi, dan pengambilan keputusan secara otomatis (Wenderott dkk., 2024). Seiring waktu, AI berevolusi menuju pendekatan yang lebih spesifik seperti *Machine Learning* (ML), di mana algoritma belajar dari data, kemudian DL yang menggunakan jaringan *neural* dengan banyak lapis *multi-layer neural networks* dengan kemampuan ekstraksi fitur otomatis, dan kemudian TL yang memanfaatkan model *pre-trained* untuk diterapkan pada domain baru dengan data terbatas (Gao dkk., 2023). AI dalam konteks medis, khususnya istem CAD dalam konteks medis telah digunakan untuk mendeteksi

dan mendiagnosis kelainan pada citra medis seperti mammogram, CT, MRI, dan ultrasound dengan penerapan ML, DL, dan TL untuk mendukung fase deteksi dan klasifikasi secara otomatis (Fasterholdt dkk., 2022).

Pada tahap awal pengembangan AI, ML mulai menjadi populer karena kemampuannya dalam mengenali pola dari data berlabel (*supervised*) maupun tidak berlabel (*unsupervised* atau *semi-supervised*), dan telah banyak diterapkan dalam bidang medis untuk klasifikasi penyakit, prediksi risiko, dan segmentasi citra. Namun, ML konvensional menghadapi keterbatasan ketika diterapkan pada data citra medis yang kompleks, misalnya fitur perlu diekstraksi secara manual, performa menurun pada dataset kecil, dan kurang mampu menangkap struktur spasial yang dalam (An dkk., 2023). Kemudian muncul DL, sebuah sub-bidang AI yang menggunakan *multi-layer neural networks* sehingga mampu secara otomatis mengekstraksi fitur hierarkis dari data citra mentah, yang membuatnya sangat cocok untuk tugas seperti klasifikasi, deteksi, dan segmentasi pada citra medis (Suganyadevi dkk., 2022). Selain itu, TL telah menjadi strategi penting terutama di bidang medis dimana data beranotasi banyak sulit diperoleh. TL memungkinkan model *pre-trained* pada domain besar untuk diadaptasi ke tugas spesifik citra medis dengan dataset kecil, serta meningkatkan kecepatan pelatihan dan akurasi generalisasi (Tao dkk., 2020).


2.4.1 Machine Learning (ML)

Machine Learning (ML) adalah cabang kecerdasan buatan yang mengembangkan algoritma untuk mempelajari pola dari data dan membuat prediksi atau pengambilan keputusan tanpa pemrograman eksplisit untuk tiap kasus, dan penerapannya meliputi *supervised*, *unsupervised*, dan *semi-supervised learning* sesuai sifat label data yang tersedia (An dkk., 2023). *Supervised learning* memanfaatkan data berlabel untuk memetakan input ke output, sedangkan *unsupervised learning* mencari struktur atau klasterisasi dari data tanpa label, dan *semi-supervised learning* menggabungkan kedua pendekatan tersebut untuk memanfaatkan jumlah besar data tak berlabel dengan sebagian kecil label (Chen dkk., 2024). Meskipun ML konvensional telah berhasil pada banyak tugas klinis, pendekatan ini menghadapi keterbatasan ketika diaplikasikan pada citra medis: kebutuhan akan fitur yang diekstrak secara manual, performa yang menurun pada dataset berukuran kecil atau tidak seimbang, kesulitan menangani variasi domain, serta risiko bias dan kurangnya interpretabilitas yang menghambat adopsi klinis (Li dkk., 2023). Penelitian-penelitian terbaru menekankan

pemanfaatan teknik *semi-supervised*, *domain adaptation*, dan *pipeline preprocessing* bahkan augmentasi khusus medis dalam memperbaiki generalisasi model ML pada data citra klinis Untuk mengatasi beberapa keterbatasan tersebut (Eckardt dkk., 2022).

2.4.2 Deep Learning (DL)


Deep Learning (DL) adalah sub-bidang dari ML yang menggunakan jaringan *deep neural networks* untuk mempelajari representasi bertingkat (*hierarchical*) dari data mentah melalui pembelajaran *end-to-end*, sehingga model mampu mengekstrak fitur tingkat rendah hingga tinggi secara otomatis tanpa membutuhkan fitur yang diekstraksi secara manual (Zhang & Qie, 2023). Konsep inti DL adalah penggabungan banyak lapisan neuron (*input*, *hidden layer*, dan *output*) dengan fungsi aktivasi non-linear sehingga jaringan dapat memodelkan relasi non-linear kompleks di dalam data, yang secara teoritis meningkatkan kapasitas representasi seiring bertambahnya kedalaman jaringan (Ghozia dkk., 2020). Keunggulan DL untuk data citra terutama terletak pada kemampuannya melakukan *automatic feature learning* melalui operasi konvolusi, memanfaatkan translasi-invarian untuk mengenali pola lokal, serta kemampuan menangkap konteks spasial berlapis yang sangat penting pada tugas-tugas vision seperti deteksi, segmentasi, dan klasifikasi citra medis (Zhang & Qie, 2023). Selain itu, teknik-teknik pendukung seperti *data augmentation*, TL, dan arsitektur khusus membuat DL lebih tahan terhadap keterbatasan ukuran dataset dan mampu mencapai kinerja yang unggul pada banyak *benchmark* medis (Arfi dkk., 2024).



Gambar 1. Arsitektur DL (Ghozia dkk., 2020)

2.4.3 Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) merupakan arsitektur DL yang dirancang khusus untuk mengolah data berbentuk *grid* seperti citra dengan meniru mekanisme kerja visual *cortex* pada manusia (Rahman dkk., 2020). CNN mampu mengekstraksi fitur penting secara otomatis melalui proses konvolusi sehingga tidak memerlukan rekayasa fitur manual seperti pada metode ML tradisional (Alzubaidi dkk., 2021). Setiap lapisannya mempelajari pola visual secara bertahap, mulai dari tepi dan tekstur pada lapisan awal hingga bentuk objek yang lebih kompleks pada lapisan yang lebih dalam. Kemampuan ini menjadikan CNN sebagai model yang sangat efektif untuk berbagai tugas *vision* seperti klasifikasi, deteksi, dan segmentasi citra (Bhatt dkk., 2021). Untuk mencapai kemampuan tersebut, CNN dibangun melalui tiga komponen arsitektur utama, yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*, kemudian bekerja bersama *activation function* dan *loss function* sebagai pendukung proses pembelajaran (Rahman dkk., 2020).



Gambar 2. Arsitektur CNN (Ayeni, 2022)

Convolutional layer merupakan inti dari arsitektur CNN yang berfungsi mengekstraksi fitur lokal melalui operasi filter yang digeser secara sistematis pada area input untuk menghasilkan *feature map* yang merepresentasikan pola penting dalam citra (Rahman dkk., 2020). Lapisan ini menerapkan konsep *sparse connectivity*, yaitu setiap *neuron* hanya terhubung pada sebagian kecil area lokal dari

input sehingga jumlah parameter menjadi lebih sedikit dan proses pembelajaran lebih efisien (Alzubaidi dkk., 2021). Selain itu, *convolutional layer* juga memanfaatkan *weight sharing*, yakni satu set bobot yang sama digunakan oleh filter yang sama di seluruh posisi citra sehingga model dapat menangkap pola serupa pada berbagai lokasi tanpa menambah parameter baru (Alzubaidi dkk., 2021). Kombinasi kedua prinsip ini membuat *convolutional layer* mampu mempelajari representasi visual secara efektif sekaligus menjaga efisiensi komputasi.



Gambar 3. *Convolutional Layer* ((Bhatt dkk., 2021)

Activation function digunakan untuk memberikan sifat non-linear pada jaringan sehingga model dapat mempelajari pola kompleks yang tidak dapat ditangkap oleh operasi linear semata (Rahman dkk., 2020). Fungsi ini diletakkan setelah *convolutional layer* maupun *fully connected layer* untuk memastikan bahwa setiap lapisan mampu membentuk transformasi fitur yang lebih representatif (Bhatt dkk., 2021). Penggunaan *activation function* juga mempengaruhi stabilitas proses *training* karena berkaitan dengan propagasi gradien dalam jaringan (Alzubaidi dkk., 2021). Berbagai fungsi aktivasi telah dikembangkan untuk mengatasi masalah non-linearitas tersebut sehingga perlu dijelaskan ragam fungsi aktivasi yang umum digunakan.

Fungsi Sigmoid memetakan nilai input ke rentang 0 hingga 1 sehingga sering digunakan dalam konteks probabilistik, meskipun rentan terhadap *vanishing gradient* (Alzubaidi dkk., 2021). Representasi matematis dari fungsi Sigmoid diberikan sebagai berikut:

$$f(x)_{\text{Sigmoid}} = \frac{1}{1 + e^{-x}} \quad (1)$$

Fungsi Tanh menghasilkan output antara -1 hingga 1 dan memiliki kurva yang lebih terpusat sehingga dapat mempercepat konvergensi dibandingkan Sigmoid (Alzubaidi dkk., 2021). Persamaan fungsi Tanh ditunjukkan pada persamaan berikut:

$$f(x)_{\text{Tanh}} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

ReLU merupakan fungsi aktivasi yang paling umum digunakan karena mampu mengatasi saturasi nilai positif sekaligus mempercepat proses komputasi melalui operasi sederhana (Alzubaidi dkk., 2021). Fungsi ReLU direpresentasikan sebagai:

$$f(x)_{\text{ReLU}} = \max(0, x) \quad (3)$$

Leaky ReLU merupakan variasi ReLU yang memberikan kemiringan kecil pada nilai negatif sehingga membantu mengatasi masalah *dying ReLU* (Alzubaidi dkk., 2021). Fungsi ini dinyatakan sebagai:

$$f(x)_{\text{LeakyReLU}} = \begin{cases} x, & \text{jika } x > 0 \\ \alpha x, & \text{jika } x \leq 0 \end{cases} \quad (4)$$

Noisy ReLU menambahkan komponen noise terkontrol pada nilai input untuk meningkatkan kemampuan generalisasi jaringan (Alzubaidi dkk., 2021). Bentuk matematisnya adalah:


$$f(x)_{\text{NoisyReLU}} = \max(x + Y), \quad \text{dengan } Y \sim \mathcal{N}(0, \sigma(x)) \quad (5)$$

Parametric ReLU (PReLU) merupakan variasi lain yang mirip dengan Leaky ReLU, tetapi nilai kemiringan pada bagian negatif dipelajari secara adaptif selama proses *training* (Alzubaidi dkk., 2021). Persamaannya ditunjukkan sebagai:


$$f(x)_{\text{PReLU}} = \begin{cases} x, & \text{jika } x > 0 \\ ax, & \text{jika } x \leq 0 \end{cases} \quad (6)$$

Pooling layer merupakan komponen penting dalam CNN yang berfungsi mengurangi dimensi *feature map* sehingga komputasi menjadi lebih efisien dan risiko *overfitting* dapat diminimalkan (Rahman dkk., 2020). Operasi ini bekerja dengan mengambil nilai representatif dari wilayah tertentu pada *feature map*, sehingga fitur penting tetap dipertahankan meskipun resolusi berkurang (Alzubaidi dkk., 2021). Terdapat empat


jenis *pooling* yang umum digunakan, yaitu *max pooling* yang memilih nilai terbesar dalam jendela *pooling*, *average pooling* yang mengambil nilai rata-rata, *min pooling* yang memilih nilai terkecil, dan *global average pooling* yang menghitung rata-rata seluruh *feature map* sebagai representasi global (Bhatt dkk., 2021). Kombinasi berbagai teknik pooling ini memberikan fleksibilitas bagi model untuk menangkap informasi spasial sesuai kebutuhan arsitektur CNN yang digunakan.



Gambar 4. *Global Average Pooling* (Alzubaidi dkk., 2021)




Gambar 5. *Average Pooling* (Bhatt dkk., 2021)



Gambar 6. *Max Pooling* (Bhatt dkk., 2021)

Fully connected layer merupakan bagian akhir pada arsitektur CNN yang menghubungkan seluruh *neuron* dari lapisan sebelumnya untuk menghasilkan keputusan klasifikasi (Rahman dkk., 2020). Pada lapisan ini, fitur-fitur yang telah diekstraksi oleh *convolutional* dan *pooling layer* digabungkan menjadi representasi vektor yang siap dipetakan ke kelas keluaran (Alzubaidi dkk., 2021). Setiap *neuron* pada *fully connected layer* memiliki bobot yang menentukan kontribusinya terhadap prediksi akhir, sehingga lapisan ini berperan sebagai pengambil keputusan utama dalam jaringan. Kehadiran *fully connected layer* memungkinkan CNN mengonversi informasi visual yang kompleks menjadi prediksi kelas yang terstruktur dan bermakna (Bhatt dkk., 2021).



Gambar 7. *Fully Connected Layer* (Bhatt dkk., 2021)

Loss function merupakan komponen penting yang digunakan untuk mengukur seberapa jauh hasil prediksi model dibandingkan nilai target sebenarnya selama proses *training* (Alzubaidi dkk., 2021). Nilai *loss* akan digunakan oleh algoritma optimisasi untuk memperbarui bobot model agar tingkat kesalahan semakin kecil pada iterasi berikutnya. Pemilihan *loss function* yang tepat sangat berpengaruh terhadap stabilitas dan performa pelatihan CNN (Ayeni, 2022). Beberapa jenis *loss function* yang umum digunakan dalam tugas klasifikasi antara lain *Cross-Entropy* atau *Softmax Loss Function*, *Euclidean Loss Function*, dan *Hinge Loss Function* (Alzubaidi dkk., 2021).

Cross-Entropy atau *Softmax Loss Function* digunakan secara luas dalam tugas klasifikasi karena mampu mengukur perbedaan antara distribusi probabilitas prediksi dan label sebenarnya (Alzubaidi dkk., 2021). Fungsi ini memanfaatkan aktivasi softmax untuk menghasilkan probabilitas kelas, yang direpresentasikan pada Persamaan (7).

$$p_i = \frac{e^{a_i}}{\sum_{k=1}^N e^{a_k}} \quad (7)$$

a_i merupakan nilai keluaran tidak ternormalisasi dari lapisan sebelumnya (Alzubaidi dkk., 2021). Persamaan *cross-entropy loss* ditunjukkan pada Persamaan (8).

$$H(p, y) = - \sum_i y_i \log(p_i) \quad (8)$$

Euclidean Loss Function, juga dikenal sebagai L2 loss atau mean square error, menghitung jarak kuadrat antara nilai prediksi dan target sehingga lebih sesuai untuk regresi (Alzubaidi dkk., 2021). Bentuk matematisnya terdapat pada Persamaan (9).

$$H(p, y) = \frac{1}{2N} \sum_{i=1}^N (p_i - y_i)^2 \quad (9)$$


Hinge Loss Function banyak digunakan dalam model berbasis margin seperti *Support Vector Machine* (SVM) karena menekankan penalti pada prediksi yang berada pada sisi margin yang salah (Alzubaidi dkk., 2021). Formulasinya ditunjukkan pada Persamaan (10).

$$H(p, y) = \sum_{i=1}^N \max(0, m - (2y_i - 1)p_i) \quad (10)$$

2.4.4 Transfer Learning (TL)

Transfer Learning (TL) adalah metode di mana sebuah model yang telah dilatih pada tugas atau domain sumber digunakan kembali pada tugas target yang berbeda tetapi berkaitan, sehingga memungkinkan pemanfaatan pengetahuan yang telah ada dan mengurangi kebutuhan pelatihan dari awal (Liao dkk., 2023). Terdapat beberapa jenis TL yang umum digunakan, antara lain *feature-extractor transfer* yaitu model *pre-trained* dipakai sebagai ekstraktor fitur tanpa *fine-tuning* besar, *fine-tuning*

transfer yaitu model *pre-trained* dilatih ulang sebagian atau seluruhnya pada data target, dan *domain adaptation/inductive transfer* yaitu adaptasi domain ketika distribusi data berbeda antara sumber dan target (Liao dkk., 2023). Arsitektur sistem TL pada citra medis umumnya terdiri atas *backbone pre-trained*, blok ekstraksi fitur, satu atau beberapa lapisan klasifikasi/*fine-tuning*, serta modul pasca-proses atau *ensemble* untuk *output* diagnosis, dan artikel terkini telah menyertakan diagram lengkap aliran sistem tersebut (Maqsood dkk., 2022). Keunggulan utama metode TL adalah mampu mengatasi keterbatasan ukuran dataset medis yang kecil atau label yang terbatas dengan memanfaatkan representasi fitur dari dataset besar sebelumnya, sehingga mempercepat konvergensi dan meningkatkan performa klasifikasi citra medis (Zhang & Qie, 2023).




Gambar 8. Arsitektur TL (Tao dkk., 2020)

Perkembangan TL pada citra medis sangat dipengaruhi oleh hadirnya berbagai arsitektur CNN yang dikembangkan dalam kurun waktu 2014 hingga 2019 dan menjadi fondasi utama bagi model-model *pre-trained* (Yang dkk., 2021). Dimulai dari GoogleNet atau Inception pada tahun 2014 yang memperkenalkan konsep *multi-scale convolution*, diikuti *Visual Geometry Group* (VGG) dengan desain berlapis sederhana namun dalam, serta *Residual Network* (ResNet) yang hadir pada 2015 dengan mekanisme *skip connection* untuk mengatasi masalah *vanishing gradient*. Perkembangan berikutnya melahirkan *Densely Connected*

Convolutional Network (DenseNet) pada 2017 yang menghubungkan setiap lapisan secara langsung untuk meningkatkan pemanfaatan fitur, dilanjutkan dengan *Mobile Neural Network* (MobileNet) yang dirancang pada 2017–2019 sebagai arsitektur ringan berbasis *depthwise separable convolution*. Pada tahun 2019, muncul EfficientNet yang memperkenalkan strategi *compound scaling* untuk menyeimbangkan perluasan kedalaman, lebar, dan resolusi jaringan secara efisien, sehingga semakin memperkaya pilihan *backbone pre-trained* dalam implementasi TL pada berbagai tugas klasifikasi citra medis.

2.4.4.1 InceptionV3

Inception diperkenalkan pertama kali oleh Szegedy dkk. (2014) dengan ide utama menggabungkan beberapa ukuran filter dalam satu modul untuk menangkap variasi fitur pada berbagai skala. Desain multi-skala ini memungkinkan jaringan belajar pola lokal dan global secara bersamaan tanpa menghasilkan jumlah parameter yang berlebihan (Szegedy dkk., 2014). Seiring perkembangan arsitektur ini, InceptionV3 kemudian hadir sebagai versi yang lebih dioptimalkan melalui sejumlah teknik seperti *factorized convolutions*, *aggressive regularization*, dan perbaikan pada struktur modul untuk meningkatkan efisiensi komputasi (Yang dkk., 2021). Pembaruan tersebut menjadikan InceptionV3 lebih dalam dan lebih ekspresif dibandingkan pendahulunya, sehingga mampu mempelajari representasi visual yang lebih kompleks. Namun, kompleksitas ini juga membuat pelatihannya membutuhkan sumber daya komputasi yang besar (Mujahid dkk., 2022). Oleh karena itu, pada penelitian ini InceptionV3 digunakan melalui pendekatan TL, di mana lapisan terakhir dimodifikasi untuk menyesuaikan kategori baru sementara bobot lapisan sebelumnya tetap dipertahankan. Strategi ini memungkinkan pemanfaatan kemampuan ekstraksi fitur InceptionV3 yang kuat tanpa memerlukan proses pelatihan dari awal, sehingga lebih efisien dan sesuai untuk tugas analisis citra medis.



Gambar 9. Arsitektur Inception (Yilmaz & Trocan, 2021)




Gambar 10. Arsitektur InceptionV3 (Ikechukwu dkk., 2021)


2.4.4.2 VGG19

Arsitektur VGG diperkenalkan oleh Simonyan dan Zisserman (2015) sebagai pengembangan jaringan konvolusional berlapis dalam dengan konfigurasi filter 3×3 yang konsisten di setiap blok, menjadikannya salah satu model paling sederhana namun efektif dalam ekstraksi fitur visual (Simonyan & Zisserman, 2015). VGG dirancang dengan prinsip memperdalam jaringan secara bertahap untuk menangkap pola spasial yang semakin kompleks tanpa mengubah ukuran filter sehingga stabilitas representasinya tetap terjaga (Yang dkk., 2021). Seiring perkembangan arsitektur tersebut, VGG kemudian dikembangkan menjadi berbagai variasi kedalaman, salah satunya VGG-19 yang terdiri atas 19 lapisan terhubung secara mendalam. Varian ini mempertahankan karakteristik inti VGG namun menawarkan kapasitas representasi yang lebih besar, sehingga mampu mengekstraksi fitur visual dengan detail yang lebih kaya. VGG-19 juga memanfaatkan *convolutional layer* dan *fully-connected* yang padat untuk meningkatkan kemampuan jaringan dalam mempelajari pola kompleks, serta menggunakan *max-pooling* untuk melakukan *downsampling* sebelum klasifikasi (Ikechukwu dkk., 2021). Melalui kedalaman dan

struktur yang stabil, VGG-19 menjadi pilihan yang andal sebagai model *pre-trained* untuk tugas pengenalan citra, termasuk pada penelitian ini yang memanfaatkan kekuatan ekstraksi fiturnya untuk mendukung proses analisis berbasis TL.



Gambar 11. Arsitektur VGG (Alzubaidi dkk., 2021)




Gambar 12. Arsitektur VGG19 (Ikechukwu dkk., 2021)


2.4.4.3 ResNet50

ResNet diperkenalkan oleh He dkk. (2015) dengan inovasi utama berupa *residual connection* yang memungkinkan aliran gradien tetap stabil meskipun jaringan dibuat sangat dalam. Pendekatan ini mengatasi masalah *vanishing gradient* yang sering muncul pada arsitektur konvensional, sehingga model dapat mencapai kedalaman ratusan lapisan tanpa degradasi performa (He dkk., 2015). Kemampuan untuk mempertahankan kedalaman jaringan inilah yang menjadikan ResNet50 relevan untuk pemrosesan citra medis, karena detail abnormalitas pada radiologi sering kali berskala halus dan membutuhkan representasi fitur tingkat tinggi. Pada konteks

concept detection, kedalaman dan stabilitas ResNet50 membuatnya lebih mampu menangkap pola visual kompleks seperti lesi, fraktur, maupun perubahan anatomi, yang pada penelitian Ram dkk. (2024) terbukti menghasilkan performa terbaik dibandingkan model lainnya.




Gambar 13. Arsitektur ResNet (Alzubaidi dkk., 2021)




Gambar 14. Arsitektur ResNet50 (Ikechukwu dkk., 2021)

2.4.4.4 DenseNet121

DenseNet diperkenalkan oleh Huang dkk. (2017) dengan konsep koneksi densitas penuh, di mana setiap lapisan menerima input dari semua lapisan sebelumnya untuk memaksimalkan aliran informasi. Mekanisme ini menghasilkan representasi fitur yang sangat kompak sekaligus mengurangi jumlah parameter karena fitur tidak perlu dipelajari ulang oleh lapisan yang lebih dalam (Huang dkk., 2017). Karakteristik ini sangat menguntungkan untuk citra medis yang memiliki struktur anatomi saling terkait dan membutuhkan propagasi informasi yang kaya untuk mengenali anomali secara konsisten (Yang dkk., 2021). DenseNet121 dengan *feature reuse* mampu mempertahankan detail-detail penting yang sering kali menjadi indikator diagnostik. Pada studi Ram dkk. (2024), DenseNet121 digunakan karena kemampuannya mengidentifikasi berbagai konsep radiologi secara luas, meskipun dengan kecenderungan *sensitivity* yang lebih tinggi daripada presisi, menjadikannya tetap relevan dalam tugas deteksi konsep medis.



Gambar 15. Arsitektur DenseNet (Huang dkk., 2017)




Gambar 16. Arsitektur DenseNet121 (Huynh dkk., 2022)


2.4.4.5 MobileNetV2

MobileNet pertama kali diperkenalkan oleh Howard dkk. (2017) dengan memanfaatkan *depthwise separable convolution* untuk menghasilkan model ringan yang efisien secara komputasi. Arsitektur ini berkembang melalui beberapa iterasi hingga MobileNetV3, yang menggabungkan optimasi *neural architecture search* (NAS) dan blok SE untuk mencapai keseimbangan terbaik antara akurasi dan efisiensi (Howard dkk., 2017). Efisiensi arsitektur ini menjadi sangat penting dalam

domain citra medis, terutama ketika model diterapkan pada sistem klinis yang membutuhkan komputasi cepat namun tetap akurat (Yang dkk., 2021). MobileNetV2 menawarkan kompromi ideal tersebut, karena struktur ringan memungkinkan proses inferensi yang efisien tanpa mengorbankan kemampuan mendeteksi fitur radiologi yang krusial. Hal ini sejalan dengan temuan Ram dkk. (2024), di mana MobileNetV2 menunjukkan performa yang stabil dan presisi tinggi dalam mendeteksi konsep medis.



Gambar 17. Arsitektur MobileNet (Al-Wesabi dkk., 2021)




Gambar 18. Arsitektur MobileNetV2 (Al-Wesabi dkk., 2021)


2.4.4.6 EfficientNetB3

EfficientNet merupakan keluarga arsitektur CNN yang diperkenalkan oleh Tan dan Le (2019) dengan pendekatan baru bernama *compound scaling*, yaitu strategi penskalaan yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara serempak untuk meningkatkan akurasi tanpa menaikkan kompleksitas model secara berlebihan. Tidak seperti arsitektur sebelumnya yang umumnya melakukan penskalaan hanya pada satu dimensi, EfficientNet mengoptimalkan ketiga dimensi tersebut berdasarkan koefisien yang diperoleh melalui pencarian arsitektur *neural*, sehingga mampu menghasilkan struktur model yang lebih efisien dan hemat komputasi (Tan & Le, 2019). Pada keluarga arsitektur ini, EfficientNetB0 berperan sebagai model dasar (*baseline*) yang dirancang dengan kompleksitas ringan

namun tetap mampu menghasilkan performa klasifikasi yang kompetitif, sehingga sering digunakan sebagai titik awal dalam pengembangan serta evaluasi model. Sementara itu, varian yang lebih besar seperti EfficientNetB3 menawarkan kapasitas representasi fitur yang lebih baik melalui peningkatan dimensi skala (Alhichri dkk., 2021), sehingga banyak dimanfaatkan dalam berbagai studi klasifikasi citra medis dan juga digunakan pada penelitian ini karena kemampuannya menangkap detail visual yang lebih kompleks sekaligus mempertahankan efisiensi komputasi.



Gambar 19. Arsitektur EfficientNetB0 (*baseline*) (Alhichri dkk., 2021)



Gambar 20. Arsitektur EfficientNetB3 (Alhichri dkk., 2021)

2.4.5 Computer-Aided Detection and Diagnosis (CAD)

Sistem CAD merupakan teknologi yang dirancang untuk mendukung radiolog atau profesional medis dalam menginterpretasi citra medis dengan menggunakan algoritma ML atau DL untuk menemukan dan menandai kelainan secara otomatis (Firmino dkk., 2016). CAD banyak diterapkan pada *screening* dan deteksi dini penyakit seperti kanker payudara, nodul paru, retinopati diabetik, serta penyakit jantung, sehingga membantu meningkatkan akurasi dan efisiensi diagnosis klinis (Zebari dkk., 2021). Tahapan utama dalam CAD dibagi menjadi dua fase yakni *Computer-Aided Detection* (CADE) yang bertugas mendeteksi keberadaan kelainan atau lesion, dan *Computer-Aided Diagnosis* (CADx) yang bertugas mengkarakterisasi kelainan tersebut atau memberikan rekomendasi diagnosis (Rose dkk., 2022). Dengan demikian, CAD bukan semata alat markah visual tetapi juga dapat memasuki tahap evaluasi lebih lanjut melalui CADx guna mendukung keputusan klinis (Dihmani dkk., 2024).

Fase CADE berfokus pada pemrosesan citra medis untuk mengenali dan menandai ROI yang berpotensi abnormal, misalnya tumor kecil, mikrokalsifikasi, atau nodul paru, sehingga memberikan “*alert*” bagi radiolog untuk pemeriksaan lebih lanjut (Zebari dkk., 2021). Sistem CADE biasanya menggabungkan *preprocessing* citra, ekstraksi fitur, segmentasi atau deteksi objek, lalu output berupa koordinat atau *bounding box* dari area mencurigakan yang kemudian diverifikasi oleh manusia (Rose dkk., 2022). Keunggulan utama CADE adalah kemampuannya mempercepat proses *screening* dan mengurangi beban kerja radiolog, terutama dalam tugas yang memerlukan pemeriksaan citra volume besar atau banyak jumlah kasus (Dada dkk., 2024). Namun, tantangan pada fase CADE meliputi tingkat FP yang masih cukup tinggi serta kebutuhan akan validasi eksternal agar hasil deteksi dapat diterapkan secara klinis dengan andal (Liao dkk., 2023).

Fase CADx melanjutkan hasil deteksi dari CADE dengan melakukan karakterisasi lesi, seperti membedakan antara jinak dan ganas atau memprediksi tingkat keparahan penyakit, sehingga menghasilkan output klinis yang lebih bermakna daripada sekadar penandaan visual (Zebari dkk., 2021). Algoritma CADx sering menggunakan model klasifikasi atau regresi berbasis DL yang *difine-tune* dari dataset medis besar untuk memperkuat generalisasi pada kasus nyata klinis (Alshdaifat dkk., 2025). Keberhasilan CADx dalam beberapa studi menunjukkan performa yang

mendekati atau bahkan setara dengan pembaca manusia dalam tugas-tertentu, meskipun masih memerlukan integrasi dan penerapan dalam alur kerja klinik yang nyata (Yu dkk., 2024). Kemampuannya dalam mengintegrasikan hasil deteksi dan diagnosis secara bersamaan, CADx menjadi komponen penting dalam sistem CAD modern yang berorientasi pada pengambilan keputusan klinis berbasis kecerdasan buatan (Dihmani dkk., 2024).

2.5 Image Preprocessing

Preprocessing citra medis memiliki tujuan utama untuk meningkatkan kualitas citra melalui pengurangan *noise*, serta menstandarkan ukuran dan intensitas piksel agar citra siap untuk analisis lanjut (Rose dkk., 2022). Prosedur ini sangat krusial karena metode segmentasi maupun klasifikasi akan bekerja secara konsisten hanya jika input citra telah dilepaskan dari artefak akuisisi, ketidakseragaman intensitas, dan perbedaan resolusi antar citra (Gao dkk., 2023). Melalui pemrosesan awal yang tepat, ekstraksi fitur menjadi lebih stabil dan model ML dapat belajar pola citra yang benar tanpa terbebani fluktuasi kualitas input yang tinggi (Zebari dkk., 2021). Hal ini kemudian menjadikan tahapan *preprocessing* sebagai pondasi penting dalam alur pipeline analisis citra medis, sebelum dilanjutkan ke segmentasi, klasifikasi, atau deteksi kelainan.

2.5.1 Image Format Conversion

Konversi format dari PGM (*Portable Gray Map*) ke PNG (*Portable Network Graphics*) dilakukan karena PGM sering kali tidak menyertakan metadata standar maupun kompresi yang efisien sehingga menyulitkan pemrosesan besar-skala dalam sistem otomatis (Simović dkk., 2022). Format PNG menawarkan kompresi *lossless* serta lebih kompatibel dengan library pemrosesan citra sehingga memudahkan *preprocessing* lanjutan. Selain itu, penggunaan PNG membantu standarisasi input dataset dan meminimalkan perbedaan format yang dapat memengaruhi kinerja model (Rojas-Hernández dkk., 2022). Dengan demikian, konversi ke PNG menjadi langkah awal yang strategis untuk memastikan seluruh citra memiliki format, *bit-depth*, dan struktur yang seragam sebelum analisis lebih lanjut.

2.5.2 Additive Noise Reduction

Tahapan *additive noise reduction* adalah proses mengurangi *noise* yang bersifat penambahan (*additive*) seperti *gaussian noise* akibat fluktuasi sensor atau transmisi, yang dapat mengaburkan detail jaringan halus dalam citra mammogram (Hemali dkk., 2023). Penggunaan *gaussian filter* sebagai *smoothing linear* memungkinkan pengurangan variansi *noise* sambil mempertahankan tepi halus struktur jaringan yang penting untuk analisis lesi. Namun demikian, penerapan harus mempertimbangkan *trade-off* antara penghilangan *noise* dan pelestarian detail struktur penting (seperti jaringan), sesuai *review preprocessing* medis (Zhang dkk., 2016).

2.5.3 Multiplicative Noise Reduction

Multiplicative noise reduction merujuk pada pengurangan *noise* yang karakteristiknya dikalikan dengan sinyal, seperti *speckle noise* pada *imaging* medis atau ultrasonografi, yang lebih kompleks daripada *noise additif* biasa (Hemali dkk., 2023). Salah satu metode yang sering digunakan ialah *Median Filter* — *filter non-linear* yang efektif dalam menghilangkan *noise* impulsif maupun *speckle* ringan sambil mempertahankan tepi kasar dan struktur penting (Zhang dkk., 2016). *Median filter* ini bekerja dengan mengganti nilai piksel dengan *median* tetangganya dalam jendela tertentu, sehingga *outlier noise* dapat dikurangi (Zhang dkk., 2016). Pemilihan ukuran jendela *median* harus disesuaikan agar tidak *over-blur* jaringan halus yang penting dalam analisis citra medis.

2.5.4 Image Enhancement

Tahapan *image enhancement* dalam *preprocessing* citra bertujuan untuk meningkatkan kontras, memperjelas struktur halus, dan mempersiapkan citra agar algoritma selanjutnya dapat bekerja lebih baik (Hemali dkk., 2023). Metode yang dipakai yaitu *Contrast Limited Adaptive Histogram Equalization* (CLAHE) yang membagi citra ke dalam *tile* lokal dan meningkatkan kontras tiap daerah dengan pembatasan agar tidak memperkuat *noise* secara berlebihan (Maqsood dkk., 2022). CLAHE bekerja dengan menyesuaikan distribusi histogram pada setiap *tile* secara adaptif, sehingga detail penting pada area gelap maupun terang tetap terjaga (Zhang dkk., 2016). Teknik ini terbukti efektif dalam meningkatkan kualitas citra medis seperti mammogram tanpa menimbulkan artefak yang signifikan.

2.5.5 Background Removal

Background removal merupakan tahapan penting untuk menghilangkan area non-relevan seperti ruang hitam, label, dan artefak akuisisi yang dapat mengganggu segmentasi atau ekstraksi fitur jaringan payudara (Hemali dkk., 2023). Penghapusan latar belakang membantu algoritma fokus hanya pada jaringan payudara yang relevan dan mengurangi potensi kesalahan ekstraksi fitur (Oza dkk., 2024). Metode *multi-technique approach* digunakan untuk menghasilkan *background removal* yang optimal dan adaptif terhadap variasi citra. Proses ini mencakup *Otsu Thresholding* berbasis analisis histogram, *Percentile-based Thresholding* untuk adaptivitas terhadap distribusi intensitas, dan kombinasi *mask* (*Otsu + Percentile*) melalui operasi *bitwise OR* (Zhang dkk., 2016). Setelah itu dilakukan operasi morfologi berupa *Opening (Erosion–Dilation)* untuk menghilangkan *noise* kecil, *Closing (Dilation–Erosion)* untuk mengisi lubang dan menghubungkan *region*, serta *Connected Components Analysis* untuk memilih komponen jaringan terbesar. Langkah dilanjutkan dengan *Mask Dilation* untuk mencegah kehilangan tepi jaringan dan *Gaussian Blur* guna menciptakan transisi *mask* yang halus tanpa tepi keras yang dapat menimbulkan artefak (Dada dkk., 2024).

2.5.6 Pectoral Muscle Removal

Pectoral muscle removal merupakan proses eliminasi otot pektoral pada citra mammogram, khususnya pada tampilan MLO yang memiliki intensitas serupa dengan jaringan payudara (Hemali dkk., 2023). Keberadaan otot ini dapat menyebabkan kesalahan segmentasi dan menimbulkan FP dalam proses deteksi lesi (Larroza dkk., 2024). Tahapan ini penting dilakukan untuk memastikan area analisis benar-benar merepresentasikan jaringan payudara tanpa gangguan struktural dari otot. Pendekatan multi-strategi diterapkan untuk menjamin *pectoral muscle removal* dilakukan secara akurat dan *robust* pada berbagai kondisi pencitraan. Strategi pertama adalah *Statistical Analysis of Breast Tissue* untuk menetapkan *baseline* intensitas jaringan payudara yang menjadi acuan pemisahan otot. Tahap berikutnya ialah *Contour-Based Detection and Triangular Removal*, yaitu mendeteksi otot pektoral berdasarkan morfologi dan pola segitiga khasnya. Sebagai langkah cadangan, diterapkan *Intensity-Based Fallback Method* apabila deteksi kontur gagal, sehingga otot tetap dapat dihapus tanpa merusak struktur jaringan utama.

2.5.7 *Resize*

Resize adalah tahapan standarisasi dimensi citra menjadi ukuran tetap agar seluruh input dataset memiliki ukuran seragam, yang sangat penting bagi model ML atau DL (Hemali dkk., 2023). Ukuran seragam membantu *batch processing*, mempercepat *training*, dan mengurangi variabilitas ukuran yang bisa memengaruhi performa model, khususnya model TL yang telah dilatih pada dataset besar seperti ImageNet (Jiang dkk., 2022). Ukuran citra diubah menjadi 224×224 piksel, karena ukuran tersebut merupakan standar input bagi sebagian besar model CNN populer seperti VGG19, ResNet50, MobileNetV3, dan DenseNet121 (Rahman dkk., 2020). Selain itu, ukuran 224×224 menyediakan keseimbangan antara pelestarian detail morfologis jaringan payudara dan efisiensi komputasi selama pelatihan maupun inferensi. Dengan demikian, tahapan *resize* tidak hanya menstandarkan input, tetapi juga menjadi langkah penting untuk kompatibilitas dan performa tinggi dalam penerapan TL pada klasifikasi atau deteksi lesi mammogram.

2.5.8 *Intensity Normalization*

Normalisasi intensitas adalah proses transformasi nilai piksel agar rentang intensitas citra menjadi konsisten antar citra. Misalnya ke rentang 0–1 atau 0–255), sehingga skala intensitas yang berbeda antar akuisisi tidak memengaruhi model (Salloum, 2025). Teknik yang digunakan yaitu *Min-Max Normalization*, di mana nilai minimum dan maksimum pada citra digunakan untuk menskalakan setiap piksel (Taghipour-Gorjikolaie dkk., 2025). Proses ini membantu stabilitas pelatihan model dan memastikan bahwa fitur intensitas dapat dibandingkan antar citra tanpa bias akibat perbedaan pengaturan akuisisi.

2.5.9 *Cropping*

Pemotongan (*cropping*) bertujuan mengekstrak ROI sehingga model hanya memproses area jaringan payudara yang relevan, yang mengurangi *noise* dan fokus kontekstual selama pelatihan (Hemali dkk., 2023). Pendekatan *patch/ROI* ini direkomendasikan dalam studi yang mengeksplorasi efek ukuran *patch* pada klasifikasi mammogram (Dada dkk., 2024). Ukuran 160×192 piksel dipilih karena menjaga aspek rasio non-persegi *typical ROI* mammogram, yaitu mempertahankan lebih banyak konteks vertikal atau horizontal tergantung *view* sekaligus menyediakan

cukup resolusi spasial untuk fitur morfologis kecil tanpa membengkakkan beban komputasi.

2.6 Image Segmentation

Segmentasi citra medis adalah proses membagi citra menjadi beberapa *region* yang homogen berdasarkan kemiripan intensitas, tekstur, atau warna, sehingga tiap segmen dapat dianggap mewakili struktur yang bermakna (Gao dkk., 2023). Tujuan utama segmentasi dalam konteks medis adalah memisahkan area anatomi atau jaringan tertentu misalnya tumor, jaringan lemak, atau latar belakang agar analisis lebih lanjut dapat dilakukan dengan fokus dan akurasi yang lebih tinggi (Zebari dkk., 2021). Proses segmentasi membantu dalam diagnosis, perencanaan pengobatan, dan pemantauan penyakit secara kuantitatif dengan memfokuskan pada *region* yang relevan. Tanpa segmentasi yang baik, analisis citra medis dapat terganggu oleh keberadaan struktur tak relevan atau variabilitas intensitas yang tinggi, sehingga mengurangi keandalan hasil.

Pada praktiknya, segmentasi menghadapi tantangan seperti batas anatomi yang kabur, variasi intensitas antar individu, dan kondisi citra yang bising atau artefak, yang semuanya dapat mempersulit pemisahan *region* secara otomatis (Rose dkk., 2022). Banyak penelitian memperkenalkan metode yang mengkombinasikan analisis tekstur, intensitas, dan spasial guna meningkatkan homogenitas *region* yang terbentuk dan meminimalkan kesalahan segmentasi (Soomro dkk., 2023). Dengan demikian, segmentasi tidak hanya membantu dalam identifikasi dan pemisahan struktur anatomi, tetapi juga menjadi fondasi penting dalam ekstraksi fitur lanjutan dan klasifikasi jaringan atau lesi dalam citra medis.

2.6.1 Region of Interest (ROI)

Region of Interest (ROI) dalam citra medis merupakan bagian citra yang mengandung informasi diagnostik paling relevan, seperti area tumor, karena merepresentasikan struktur patologis atau anatomi yang menjadi fokus utama analisis (Nisa dkk., 2025). Ekstraksi ROI memungkinkan sistem untuk memusatkan proses komputasi pada wilayah yang signifikan dan mengabaikan latar belakang atau jaringan normal yang tidak terkait, sehingga meningkatkan efisiensi dan efektivitas tahapan analisis lanjutan (Sharma & Kamra, 2023).

Pada banyak penelitian, ROI ditentukan setelah tahap segmentasi atau *clustering* untuk mengidentifikasi klaster dengan intensitas tertinggi yang diasumsikan sebagai lesi (Nisa dkk., 2025). Dari klaster terpilih tersebut, dilakukan ekstraksi parameter geometris berupa koordinat pusat (*centroid*) (x, y) dan ukuran lesi yang direpresentasikan oleh nilai *radius* (r). Estimasi ukuran tumor dilakukan menggunakan pendekatan *Minimum Enclosing Circle* (MEC), yaitu permasalahan optimasi dalam bidang *computational geometry* yang bertujuan untuk menentukan lingkaran dengan radius minimum yang mampu mencakup seluruh titik kontur lesi (Welzl, 1991). Pendekatan ini menghasilkan representasi geometris berupa pusat lingkaran dan radius yang bersifat stabil serta tidak bergantung pada asumsi bentuk objek, sehingga sesuai untuk lesi dengan morfologi tidak beraturan (Wilk dkk., 2025).

Penentuan ROI tanpa ketersediaan *ground truth* menjadi tantangan utama karena tidak terdapat label pasti yang menunjukkan lokasi lesi secara akurat. Dalam kondisi tersebut, validasi berbasis evaluasi internal dan verifikasi visual sering digunakan untuk memastikan bahwa ROI yang dihasilkan tetap relevan. Metode *clustering* yang digunakan pada tahap ekstraksi ROI perlu dirancang agar robust terhadap variasi intensitas dan tekstur antar pasien, mengingat karakteristik jaringan dan lesi dapat sangat bervariasi. Untuk mengatasi ketidakpastian akibat ketiadaan *ground truth*, beberapa studi menerapkan pendekatan *weakly-supervised* atau *semi-supervised* dengan memanfaatkan informasi tingkat citra atau *patch* yang dikombinasikan dengan verifikasi visual (Sharma & Kamra, 2023). Proses ekstraksi ROI yang robust ini menjadi fondasi penting bagi pengukuran kuantitatif lanjutan, seperti estimasi ukuran tumor atau perubahan temporal, yang mendukung analisis klinis dan penelitian selanjutnya (Wilk dkk., 2025).

2.6.2 *Possibilistic Fuzzy C-Means* (PFCM)

Possibilistic Fuzzy C-Means (PFCM) dikembangkan sebagai pendekatan *clustering fuzzy* yang lebih stabil terhadap keberadaan *noise* dan *outlier*. Algoritma ini lahir dari kebutuhan akan model yang mampu mengombinasikan keunggulan *Fuzzy C-Means* (FCM) dan *Possibilistic C-Means* (PCM) sekaligus meminimalkan kelemahan keduanya. FCM bekerja dengan memberikan nilai keanggotaan (*membership*) pada setiap titik data terhadap seluruh *cluster*, sehingga satu data dapat menjadi anggota lebih dari satu *cluster* dengan derajat yang berbeda-beda (Satriyanto dkk., 2024). Nilai keanggotaan tersebut dipengaruhi oleh jarak relatif antara titik data dan pusat

cluster (centroid). Model FCM didefinisikan sebagai masalah optimasi dengan fungsi objektif (Krishnapuram & Keller, 1993):

$$J_m(U, V; X) = \sum_{i=1}^c \sum_{k=1}^n (u_{ik})^m d_{ik}^2 \quad (11)$$

Parameter $m \in (1, \infty)$ berperan sebagai *fuzzifier* yang mengatur tingkat kefuzzzyan partisi. Himpunan $V = \{v_1, v_2, \dots, v_c\}$ merepresentasikan pusat *cluster*, sedangkan $d_{ik} = \|x_k - v_i\|_A$ menyatakan jarak antara data x_k dan *centroid* v_i . Nilai u_{ik} menunjukkan tingkat keanggotaan data x_k terhadap *cluster* ke- i dengan kendala:

$$\sum_{i=1}^c u_{ik} = 1, \quad \forall k \quad (12)$$

Proses optimasi FCM dilakukan secara iteratif melalui pembaruan nilai keanggotaan dan *centroid* menggunakan persamaan berikut:

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{m-1}}} \quad (13)$$

$$v_i = \frac{\sum_{k=1}^n (u_{ik})^m x_k}{\sum_{k=1}^n (u_{ik})^m} \quad (14)$$

Meskipun FCM mampu menghasilkan partisi *fuzzy* yang fleksibel, algoritma ini memiliki kelemahan mendasar, yaitu sensitivitas terhadap *noise* dan *outlier* (Krishnapuram & Keller, 1993). Kendala $\sum_{i=1}^c u_{ik} = 1$ memaksa setiap data, termasuk *outlier* untuk tetap memiliki keanggotaan signifikan pada salah satu *cluster*. Kondisi ini menyebabkan data yang sebenarnya tidak representatif tetap memengaruhi posisi *centroid*, sehingga kualitas *clustering* dapat menurun, terutama pada data medis yang sering mengandung *noise* dan artefak.

Krishnapuram dan Keller (1993) mengusulkan *Possibilistic C-Means* (PCM) Sebagai solusi awal yang melonggarkan kendala penjumlahan keanggotaan. Nilai keanggotaan diinterpretasikan sebagai tipikalitas (*typicality*), yaitu ukuran seberapa tipikal suatu data terhadap *cluster* tertentu tanpa harus dipengaruhi *cluster* lain. Fungsi objektif PCM didefinisikan sebagai:

$$J_m(T, V; X, \eta) = \sum_{i=1}^c \sum_{k=1}^n (t_{ik})^m d_{ik}^2 + \sum_{i=1}^c \eta_i \sum_{k=1}^n (1 - t_{ik})^m \quad (15)$$

Nilai t_{ik} merepresentasikan tingkat tipikalitas data x_k terhadap *cluster* i , sedangkan η_i berfungsi sebagai parameter penalti agar solusi tidak jatuh ke kondisi trivial ketika seluruh tipikalitas bernilai nol. Nilai tipikalitas dihitung melalui:

$$t_{ik} = \frac{1}{1 + \left(\frac{d_{ik}^2}{\eta_i} \right)^{\frac{1}{m-1}}} \quad (16)$$

$$v_i = \frac{\sum_{k=1}^n (t_{ik})^m x_k}{\sum_{k=1}^n (t_{ik})^m} \quad (17)$$

Parameter η_i umumnya diperoleh dari hasil FCM dan dirumuskan sebagai:

$$\eta_i = K \frac{\sum_{k=1}^n (u_{ik})^m d_{ik}^2}{\sum_{k=1}^n (u_{ik})^m} \quad (18)$$

PCM berhasil mengurangi sensitivitas terhadap *noise*, tetapi menghadirkan kelemahan baru berupa masalah *coincident clusters*, yaitu kondisi ketika dua atau lebih *cluster* bertumpuk pada lokasi yang sama akibat sifat fungsi objektif yang *separable* (Chen & Zhou, 2024). Selain itu, kestabilan hasil PCM sangat bergantung pada inisialisasi dan pemilihan parameter η_i . Pal et al. (1997) kemudian memperkenalkan Fuzzy Possibilistic C-Means (FPCM) yang mengintegrasikan informasi keanggotaan *fuzzy* dan tipikalitas possibilistik secara simultan. Fungsi objektif FPCM didefinisikan sebagai:

$$J_{m,\eta}(U, T, V; X) = \sum_{i=1}^c \sum_{k=1}^n (u_{ik})^m d_{ik}^2 + \sum_{i=1}^c \sum_{k=1}^n (t_{ik})^\eta d_{ik}^2 \quad (19)$$

dengan kendala:

$$\sum_{i=1}^c u_{ik} = 1, \quad \forall k \quad (20)$$

$$\sum_{k=1}^n t_{ik} = 1, \quad \forall i \quad (21)$$

Meskipun lebih baik dibandingkan FCM dan PCM, FPCM masih memiliki kelemahan karena adanya kendala penjumlahan pada tipikalitas. Nilai tipikalitas menjadi sangat kecil ketika jumlah data besar, sehingga informasi tipikalitas kehilangan makna dan sering memerlukan proses penskalaan tambahan (Pal dkk., 1997). Pal et al. (2005) kemudian mengusulkan PFCM sebagai bentuk hibridisasi optimal antara FCM dan PCM. Model ini menghasilkan nilai keanggotaan dan tipikalitas secara simultan tanpa kendala penjumlahan pada tipikalitas. Fungsi objektif PFCM dirumuskan sebagai:

$$J_{m,\eta}(U, T, V; X) = \sum_{i=1}^c \sum_{k=1}^n (a \cdot u_{ik}^m + b \cdot t_{ik}^\eta) d_{ik}^2 + \sum_{i=1}^c \gamma_i \sum_{k=1}^n (1 - t_{ik})^\eta \quad (22)$$

dengan kendala:

$$\sum_{i=1}^c u_{ik} = 1, \quad \forall k \quad (23)$$

Konstanta $a > 0$ dan $b > 0$ menentukan kontribusi relatif keanggotaan fuzzy dan tipikalitas possibilistik, sedangkan γ_i bertindak sebagai parameter penalti. Proses optimasi dilakukan melalui:

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{m-1}}} \quad (24)$$

$$t_{ik} = \frac{1}{1 + \left[\frac{b \cdot d_{ik}^2}{\gamma_i} \right]^{\frac{1}{\eta-1}}} \quad (25)$$

$$v_i = \frac{\sum_{k=1}^n (a \cdot u_{ik}^m + b \cdot t_{ik}^\eta) x_k}{\sum_{k=1}^n (a \cdot u_{ik}^m + b \cdot t_{ik}^\eta)} \quad (26)$$

Persamaan keanggotaan pada PFCM tetap identik dengan FCM sehingga karakteristik partisi *fuzzy* tetap terjaga (Pal dkk., 2005). Formula tipikalitas mengikuti

konsep PCM dengan tambahan faktor pengatur b , sementara pembaruan *centroid* memadukan kontribusi keanggotaan dan tipikalitas melalui bobot a dan b sehingga fleksibilitas pengaturan *trade-off* dapat diperoleh. PFCM menawarkan sejumlah keunggulan dibandingkan pendekatan sebelumnya sehingga sangat relevan pada aplikasi citra medis (Chen & Zhou, 2024). Algoritma ini lebih tahan terhadap noise karena mekanisme tipikalitas memberikan bobot rendah pada data yang tidak representatif. Masalah *coincident clusters* pada PCM dapat dihindari, dan persoalan nilai tipikalitas sangat kecil pada PFCM tidak lagi muncul karena tidak terdapat kendala penjumlahan tipikalitas (Pal dkk., 2005).

Pada algoritma PFCM, proses *clustering* direpresentasikan secara eksplisit melalui dua struktur matriks utama, yaitu *membership matrix* dan *typicality matrix*, yang selanjutnya dapat dikombinasikan untuk mendukung pengambilan keputusan akhir. *Membership matrix* dinotasikan sebagai $\mathbf{U} = [u_{ik}] \in \mathbb{R}^{c \times n}$, di mana setiap elemen u_{ik} menyatakan derajat keanggotaan data ke- k terhadap *cluster* ke- i . Nilai keanggotaan ini dihitung menggunakan formulasi FCM berdasarkan jarak relatif terhadap seluruh pusat *cluster* dan memenuhi kendala $\sum_{i=1}^c u_{ik} = 1$ untuk setiap data. Dengan demikian, setiap data selalu memiliki distribusi keanggotaan *fuzzy* terhadap seluruh *cluster*, sehingga batas antar *cluster* dapat direpresentasikan secara lunak (Pal dkk., 2005).

Selain matriks keanggotaan, PFCM juga memperkenalkan *typicality matrix* yang dinotasikan sebagai $\mathbf{T} = [t_{ik}] \in \mathbb{R}^{c \times n}$. Elemen t_{ik} merepresentasikan tingkat ketipikalitas (*typicality*) data ke- k terhadap *cluster* ke- i , yang dihitung secara independen tanpa adanya kendala penjumlahan antar *cluster*. Nilai tipikalitas ditentukan berdasarkan jarak data terhadap pusat *cluster* dan parameter penalti γ_i , sehingga data yang jauh dari pusat *cluster* akan memperoleh nilai tipikalitas yang sangat kecil. Mekanisme ini memungkinkan PFCM memberikan bobot rendah pada *noise* dan *outlier* tanpa memengaruhi struktur *cluster* lain, yang merupakan keunggulan utama dibandingkan FCM dan FPCM (Pal dkk., 2005).

Penentuan label akhir (*hard assignment*) dan meningkatkan kestabilan keputusan *cluster*, nilai keanggotaan dan tipikalitas digabungkan ke dalam suatu *combined matrix* $\mathbf{C} = [c_{ik}]$. Setiap elemen pada matriks ini dihitung sebagai rata-rata sederhana antara nilai keanggotaan dan tipikalitas, yaitu:

$$c_{ik} = \frac{u_{ik} + t_{ik}}{2} \quad (27)$$

Pendekatan ini memberikan kontribusi yang seimbang antara informasi *fuzzy membership* dan *possibilistic typicality*, sehingga keputusan *cluster* tidak hanya mempertimbangkan kedekatan relatif antar *cluster*, tetapi juga tingkat representativitas data terhadap *cluster* tertentu. Kombinasi ini terbukti menghasilkan penugasan *cluster* yang lebih stabil dan *robust*, khususnya pada data medis yang mengandung *noise* dan variasi intensitas, serta digunakan sebagai dasar pemetaan *pseudo-stadium labeling* pada penelitian ini.

Keunggulan tersebut menjadikan PFCM sangat sesuai diterapkan pada sistem CAD berbasis citra mammografi. Citra medis umumnya mengandung *noise*, artefak, dan variasi intensitas akibat perbedaan peralatan maupun karakteristik jaringan pasien. Mekanisme tipikalitas pada PFCM membantu membedakan struktur jaringan relevan dari komponen non-informatif sehingga segmentasi menjadi lebih akurat (Pal dkk., 2005). Selain itu, algoritma ini mampu mengidentifikasi ROI yang mencerminkan karakteristik lesi sambil tetap menyediakan nilai keanggotaan *fuzzy* untuk analisis batas lesi (Kurniasari dkk., 2024). *Robustnya centroid* yang dihasilkan memastikan representasi *cluster* benar-benar menggambarkan jaringan normal dan abnormal. Oleh karena itu, PFCM menjadi fondasi yang kuat dan reliabel dalam pengembangan sistem CAD untuk deteksi dan klasifikasi kanker payudara berbasis citra medis.

2.6.3 Metrik Evaluasi Clustering

Evaluasi *clustering* internal memegang peranan penting dalam segmentasi citra medis, khususnya pada pendekatan *unsupervised* dan *semi-supervised*, ketika *ground truth* tidak tersedia secara eksplisit. Metrik evaluasi internal memungkinkan penilaian kualitas hasil segmentasi secara kuantitatif berdasarkan struktur data itu sendiri tanpa memerlukan label eksternal (Sims dkk., 2023). Pada konteks segmentasi berbasis *fuzzy clustering*, metrik evaluasi konvensional untuk *hard clustering* tidak selalu sesuai karena tidak mempertimbangkan derajat keanggotaan (*membership degree*) yang bersifat kontinu. Oleh karena itu, diperlukan metrik validitas klaster yang dirancang khusus untuk *fuzzy* dan *possibilistic clustering* (Gürler & Nasibov, 2024).

Partition Coefficient (PC) merupakan salah satu indeks validitas klaster paling awal yang diperkenalkan oleh Bezdek (1973) dan dirancang khusus untuk *fuzzy clustering*. Indeks ini mengukur tingkat kekaburan (*fuzziness*) dari partisi klaster berdasarkan derajat keanggotaan data terhadap klaster yang terbentuk (Abdulameer & Ali, 2025).

PC didefinisikan sebagai berikut:

$$PC = \frac{1}{n} \sum_{j=1}^n \sum_{i=1}^c u_{ij}^2 \quad (28)$$

Parameter u_{ij} menyatakan derajat keanggotaan data ke- j terhadap kluster ke- i , n jumlah data, dan c jumlah kluster. Nilai PC berada pada rentang $[1/c, 1]$, di mana nilai yang mendekati 1 menunjukkan partisi yang semakin tegas (*crisp*) dan tingkat ketidakpastian yang rendah. Nilai PC yang tinggi dalam segmentasi citra medis mengindikasikan bahwa piksel-piksel cenderung memiliki afiliasi yang kuat terhadap satu kluster tertentu, sehingga struktur jaringan dapat dipisahkan secara lebih jelas.

Partition Entropy (PE) merupakan metrik validitas kluster lain yang juga diperkenalkan oleh Bezdek (1973) untuk mengukur tingkat ketidakpastian atau entropi dari distribusi keanggotaan *fuzzy*. Berbeda dengan PC, PE menilai seberapa tersebar nilai keanggotaan suatu data terhadap seluruh kluster (Abdulameer & Ali, 2025). PE dirumuskan sebagai:

$$PE = -\frac{1}{n} \sum_{j=1}^n \sum_{i=1}^c u_{ij} \log(u_{ij}) \quad (29)$$

Nilai PE yang lebih kecil menunjukkan tingkat entropi yang rendah, yang berarti setiap data memiliki keanggotaan dominan pada satu kluster tertentu. Nilai PE yang rendah dalam konteks segmentasi citra medis mengindikasikan bahwa area jaringan, seperti lesi atau tumor, dapat diidentifikasi dengan tingkat ambiguitas yang minimal. Namun demikian, PE sensitif terhadap jumlah kluster sehingga penggunaannya umumnya dikombinasikan dengan indeks validitas lainnya.

Fuzzy Silhouette Index (FS) merupakan pengembangan dari *Silhouette Index* klasik yang disesuaikan untuk *fuzzy clustering*. Indeks ini mempertimbangkan derajat keanggotaan setiap data dalam mengukur kedekatan intra-kluster dan pemisahan antar-kluster. FS memberikan evaluasi terhadap kualitas kluster dengan memperhitungkan sifat tumpang tindih antar kluster yang umum terjadi pada citra medis (Gürler & Nasibov, 2024). Nilai FS dihitung sebagai rata-rata nilai siluet *fuzzy* setiap data, yang dirumuskan sebagai:

$$FS = \frac{1}{n} \sum_{j=1}^n s_j \quad (30)$$

Parameter s_j menyatakan nilai siluet *fuzzy* untuk data ke- j . Nilai FS berada pada rentang $[-1, 1]$, di mana nilai mendekati 1 menunjukkan bahwa data terkluster dengan baik, sedangkan nilai mendekati 0 mengindikasikan data berada di batas antar kluster. FS dalam segmentasi citra medis memberikan gambaran yang lebih realistis terhadap kualitas pemisahan jaringan yang memiliki intensitas saling tumpang tindih.

Xie–Beni Index (XB) merupakan indeks validitas kluster yang mengombinasikan konsep kekompakan kluster dan pemisahan antar kluster dalam satu metrik tunggal. XB dirancang khusus untuk *fuzzy clustering* dan banyak digunakan dalam evaluasi kualitas segmentasi berbasis FCM dan turunannya (Abdulameer & Ali, 2025). Indeks ini dirumuskan sebagai berikut:

$$XB = \frac{\sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \|x_j - v_i\|^2}{n \cdot \min_{i \neq k} \|v_i - v_k\|^2} \quad (31)$$

Parameter x_j menyatakan data ke- j , v_i pusat kluster ke- i , dan m merupakan parameter fuzzifikasi. Nilai XB yang lebih kecil menunjukkan kluster yang lebih kompak dan terpisah dengan baik. Nilai XB yang rendah dalam segmentasi citra medis menandakan bahwa area tumor atau lesi memiliki batas yang jelas dan tidak bercampur secara signifikan dengan jaringan sekitarnya.

2.7 Klasifikasi

Klasifikasi adalah proses pengelompokan citra ke dalam kategori tertentu berdasarkan fitur yang telah diekstraksi atau dipelajari oleh model. Misalnya, membedakan antara jaringan normal dan abnormal dalam citra medis Kim dkk., 2022. Tujuan klasifikasi dalam konteks citra medis sering kali diarahkan untuk mengidentifikasi stadium kanker atau jenis lesi pada pasien, yang berperan penting dalam penentuan rencana pengobatan (Kaur & Hans, 2025). Penggunaan label *pseudo-stadium* sebagai target dalam klasifikasi memungkinkan model pembelajaran terarah untuk memprediksi kategori seperti stadium I, II, III dan IV berdasarkan ciri citra yang diekstraksi sebelumnya (LBBC, 2023); (Teichgraeber dkk., 2021). Dengan demikian, klasifikasi berbasis TL menjadi pendekatan yang menjanjikan dalam konteks medis karena dapat memanfaatkan model *pre-trained* untuk mempercepat proses dan meningkatkan akurasi meskipun data terbatas (Kaur & Hans, 2025).

2.7.1 Augmentasi Data

Augmentasi data citra merupakan salah satu teknik penting dalam bidang pengolahan citra digital yang bertujuan untuk memperluas jumlah dan variasi data pelatihan tanpa harus mengumpulkan citra baru (Liao dkk., 2023). Teknik ini dilakukan dengan menerapkan berbagai transformasi pada citra asli, seperti *rotation*, *flipping*, *scaling*, *translation*, *cropping*, *zooming*, *noise injection*, hingga transformasi pada *color space* (Oza dkk., 2024). Melalui proses tersebut, dihasilkan data baru yang memiliki karakteristik berbeda namun tetap mempertahankan label aslinya (Saber dkk., 2023). Pendekatan ini terbukti efektif dalam meningkatkan performa model pembelajaran mesin, terutama ketika dataset yang tersedia terbatas atau tidak seimbang antar kelas (Arfi dkk., 2024).

Selain pemilihan jenis transformasi, strategi distribusi augmentasi juga memiliki peran penting dalam menjaga keseimbangan dan keragaman data hasil augmentasi. Pada penelitian ini, augmentasi dilakukan menggunakan pendekatan *class-wise oversampling*, di mana setiap kelas diperlakukan secara independen hingga mencapai jumlah target yang sama. Strategi ini bertujuan untuk mengatasi permasalahan *class imbalance* yang umum terjadi pada dataset medis dan berpotensi menyebabkan bias pembelajaran pada model klasifikasi (Liao dkk., 2023). Salah satu pendekatan yang digunakan untuk menghindari dominasi satu jenis transformasi tertentu, augmentasi diterapkan secara siklik (*cyclic augmentation*), yaitu setiap teknik transformasi digunakan secara bergantian dan merata pada citra-citra asli. Pendekatan ini memastikan bahwa variasi data yang dihasilkan berasal dari kontribusi seimbang antar teknik augmentasi, sehingga model tidak belajar pola spesifik dari satu transformasi saja (Latha dkk., 2024).

Pada penelitian ini, teknik augmentasi disesuaikan secara khusus dengan karakteristik citra mammografi, sehingga hanya transformasi yang tetap menjaga integritas anatomi payudara yang diterapkan (Alzubaidi dkk., 2021). Augmentasi yang digunakan meliputi *rotation* ringan sebesar 5–10 derajat, *horizontal flip*, *zooming* atau *scaling* dalam rentang 0.9–1.1, *translation* sebesar 0.05–0.1, serta kombinasi *rotation* dan *flipping*. Pemilihan rentang transformasi tersebut bertujuan untuk meniru variasi posisi dan orientasi yang umum terjadi selama proses akuisisi mammografi tanpa mengubah struktur klinis penting seperti massa, kalsifikasi, distorsi arsitektur, dan asimetri jaringan (Müller dkk., 2022). Transformasi yang terlalu ekstrem berpotensi mengaburkan atau merusak fitur patologis penting,

sehingga augmentasi ringan dan terkontrol menjadi pilihan yang lebih tepat untuk menjaga validitas diagnostik citra (Saber dkk., 2023).

Perbedaan proporsi jumlah sampel yang dihasilkan oleh masing-masing teknik augmentasi merupakan konsekuensi dari pembagian bilangan bulat ketika jumlah citra yang perlu ditambahkan tidak habis dibagi oleh jumlah teknik transformasi yang digunakan. Oleh karena itu, beberapa teknik menghasilkan satu sampel tambahan dibandingkan teknik lainnya. Distribusi tersebut bersifat sistematis dan bukan ditentukan secara arbitrer, melainkan mengikuti mekanisme augmentasi siklik yang berhenti tepat pada jumlah target per kelas. Pendekatan ini dipilih untuk mempertahankan keseimbangan distribusi transformasi sekaligus memastikan bahwa jumlah total sampel pada setiap kelas tetap identik, sehingga tidak menimbulkan bias pada tahap pelatihan model (Arfi dkk., 2024).

Pada konteks TL, augmentasi data citra berperan penting untuk meningkatkan kemampuan generalisasi model (Liao dkk., 2023). variasi input diperkaya melalui transformasi geometris yang realistis, model dapat belajar mengenali pola lesi dari berbagai sudut pandang dan orientasi yang berbeda. Hal ini membantu mengurangi risiko *overfitting*, yaitu kondisi ketika model hanya mampu mengenali pola pada data pelatihan tetapi gagal beradaptasi dengan data baru (Oza dkk., 2024). Oleh karena itu, augmentasi data menjadi langkah esensial dalam tahap *preprocessing* sebelum proses pelatihan dilakukan, agar sistem klasifikasi mampu mencapai performa yang lebih stabil, robust, dan andal pada data mammografi yang bersifat kompleks.

2.7.2 *Stratified Splitting*

Stratified Splitting merupakan teknik pembagian dataset yang mempertahankan proporsi distribusi kelas pada setiap subset data, sehingga komposisi kelas pada data latih, validasi, dan uji tetap konsisten dengan distribusi awal dataset (Müller dkk., 2022). Pendekatan ini memastikan bahwa kelompok kelas yang lebih jarang tetap terwakili secara proporsional, sehingga mengurangi risiko bias dalam proses pelatihan model (Alzubaidi dkk., 2021). Keunggulan utama dari *stratified split* adalah kemampuannya menjaga keseimbangan distribusi kelas, terutama pada dataset dengan ketidakseimbangan kelas, sehingga performa model yang dihasilkan menjadi lebih stabil dan reliabel (Latha dkk., 2024).

Pada penelitian ini, teknik *stratified splitting* diterapkan untuk membagi dataset

secara proporsional dengan mempertahankan representasi kelas yang konsisten di seluruh subset data, mengikuti pola pembagian 80% data model dan 20% data uji, serta pembagian lanjutan 70% untuk pelatihan dan 30% untuk validasi dari data model. Penerapan pembagian terstratifikasi ini sangat penting karena dataset medis, termasuk citra mammografi, cenderung memiliki distribusi kelas yang tidak seimbang, misalnya jumlah kasus normal yang jauh lebih banyak dibandingkan kasus kanker (Müller dkk., 2022). Proporsi kategori tersebut dijaga tetap sama dalam data latih, validasi, dan uji, model dapat mempelajari pola pada kelas minoritas secara lebih efektif dan mengurangi risiko bias terhadap kelas mayoritas (Alzubaidi dkk., 2021). Oleh karena itu, penggunaan *stratified split* dalam penelitian ini menjadi langkah esensial untuk memastikan bahwa model mampu menghasilkan prediksi yang lebih adil, representatif, dan akurat dalam konteks analisis citra medis yang sensitif.

2.7.3 Hyperparameter Tuning

Hyperparameter tuning merupakan proses penyesuaian parameter eksternal yang tidak dipelajari secara langsung selama pelatihan model, tetapi harus ditentukan sebelumnya untuk memperoleh performa yang optimal (Ilemoobayo dkk., 2024). Parameter tersebut mencakup berbagai aspek seperti *activation function*, *loss function*, *optimization function*, *epoch*, *early stoping patience*, *dropout*, *weight decay*, *learning rate*, *batch size* dan *dense units* (El Ghazi & Akinin, 2023). Pada konteks TL, penyesuaian hyperparameter menjadi krusial karena model *pre-trained* perlu diadaptasikan kembali terhadap karakteristik tugas dan distribusi data yang baru agar generalisasinya tetap kuat. Oleh karena itu, proses *hyperparameter tuning* dalam penelitian ini tidak hanya difokuskan pada pencarian nilai terbaik, tetapi juga pada pemilahan parameter mana yang ditetapkan secara tetap dan mana yang perlu dioptimalkan lebih lanjut.

Selama pengaturan *hyperparameter*, beberapa parameter memiliki sifat dasar yang menentukan perilaku fundamental model sehingga sering kali ditetapkan secara tetap pada awal eksperimen (Müller dkk., 2022). Parameter seperti *activation function*, *loss function*, dan *optimization function* termasuk dalam kategori ini karena masing-masing memiliki peran inti dalam mengontrol bagaimana jaringan memproses informasi dan memperbarui bobotnya (Alzubaidi dkk., 2021). *Activation function* berfungsi mengubah output linear menjadi representasi non-linear sehingga jaringan dapat mempelajari pola kompleks, sedangkan *loss function* digunakan untuk

mengukur seberapa jauh prediksi jaringan dibandingkan dengan nilai kebenaran (Wang dkk., 2023). Sementara itu, *optimization function* menentukan bagaimana bobot jaringan diperbarui berdasarkan gradien yang dihasilkan selama pelatihan (Wang dkk., 2023). Ketiga parameter ini menjadi dasar dalam desain arsitektur model, sehingga pemilihannya secara tepat penting untuk membentuk fondasi pelatihan yang stabil sebelum masuk ke tahap penyesuaian lebih lanjut.

Selain parameter fungsional, hyperparameter lain yang memiliki pengaruh besar terhadap dinamika pelatihan adalah jumlah *epoch* dan tingkat *early stopping patience* (Müller dkk., 2022). Jumlah *epoch* mengacu pada berapa kali seluruh dataset pelatihan diproses oleh model dalam satu siklus pembelajaran. Sehingga semakin tinggi nilai *epoch*, semakin banyak kesempatan model untuk menyesuaikan bobotnya (Wang dkk., 2023). Namun, pelatihan yang terlalu lama dapat menyebabkan *overfitting*, yaitu ketika model menghafal data pelatihan dan gagal beradaptasi dengan data baru. Mekanisme *early stopping* digunakan untuk mengatasi hal tersebut dengan memberikan toleransi tertentu (*patience*) sebelum pelatihan dihentikan ketika performa validasi tidak lagi menunjukkan peningkatan (Alzubaidi dkk., 2021). Pendekatan ini membantu memastikan bahwa proses pelatihan berhenti pada titik optimal tanpa membuang sumber daya komputasi secara berlebihan.

Hyperparameter lain yang biasanya dimasukkan ke dalam proses *tuning* adalah *dropout*, *weight decay*, *learning rate*, *batch size*, dan jumlah *dense units*. *Dropout* adalah teknik regularisasi yang secara acak menonaktifkan sejumlah *neuron* selama pelatihan untuk mengurangi ketergantungan berlebih pada fitur tertentu dan menekan risiko *overfitting* (Alzubaidi dkk., 2021). *Weight decay* berperan sebagai regularisasi tambahan dengan menurunkan nilai bobot secara bertahap agar model tidak mempelajari pola yang terlalu kompleks. Sementara itu, *learning rate* mengatur seberapa besar langkah pembaruan bobot setiap kali gradien dihitung, yang menentukan kecepatan dan stabilitas proses konvergensi (Wang dkk., 2023). *Batch size* mengontrol jumlah sampel yang diproses setiap iterasi, sehingga memengaruhi efisiensi komputasi dan stabilitas gradien (Alzubaidi dkk., 2021). Adapun jumlah *dense units* menentukan kapasitas representasi pada lapisan penuh terhubung, yang berpengaruh pada kedalaman pemahaman fitur oleh model (Müller dkk., 2022). Karena nilai optimal dari parameter-parameter ini sangat bergantung pada karakteristik dataset dan arsitektur model, maka diperlukan mekanisme pencarian yang sistematis untuk menemukan kombinasi terbaik yang kemudian dilakukan melalui berbagai metode *hyperparameter tuning*.

Metode yang biasa digunakan untuk *hyperparameter tuning* mencakup *Grid Search* yang mengeksplorasi kombinasi parameter secara sistematis, *Random Search* yang memilih sampling acak dari ruang parameter, serta teknik yang lebih canggih seperti *Bayesian Optimization* atau menggunakan pustaka modern seperti *Keras Tuner/Hyperband/Optuna* untuk efisiensi pencarian yang lebih tinggi (Liyew dkk., 2025). Pada penelitian TL terkini, *Bayesian Optimization* telah terbukti lebih efisien dibanding *Grid Search* atau *Random Search* dalam menemukan *hyperparameter* optimal dengan evaluasi yang lebih sedikit (Raiaan dkk., 2024). Kelebihan dari pendekatan ini adalah pengurangan beban komputasi dan lebih cepat konvergen pada model *pre-trained* yang kompleks, terutama ketika data terbatas atau domain spesifik seperti citra medis. Oleh karena itu, dalam *pipeline* klasifikasi berbasis TL, penerapan *hyperparameter tuning* yang sistematis menjadi bagian kunci untuk memastikan performa model yang stabil dan andal.

2.7.4 Metrik Evaluasi Klasifikasi

Metrik evaluasi dalam pemodelan klasifikasi berperan penting untuk menilai sejauh mana model mampu melakukan prediksi secara benar terhadap data yang belum pernah dilihat sebelumnya (Li dkk., 2023). Penggunaan satu metrik saja, seperti *accuracy*, sering kali tidak cukup untuk memberikan gambaran yang komprehensif mengenai performa model, terutama pada dataset dengan distribusi kelas yang tidak seimbang (*imbalanced data*) (Liao dkk., 2023). Oleh karena itu, diperlukan kombinasi beberapa metrik evaluasi untuk menilai kinerja model dari berbagai sudut pandang, seperti ketepatan prediksi, kemampuan mendeteksi kelas tertentu, serta keseimbangan antara keduanya (Salloum, 2025).

Secara teoritis, evaluasi model klasifikasi berkaitan erat dengan konsep peluang bersyarat dalam teori probabilitas. Misalkan Y menyatakan label aktual dan $\hat{Y}$ menyatakan label hasil prediksi model, maka hubungan antara keduanya dapat direpresentasikan melalui peluang bersyarat $P(\hat{Y} | Y)$ atau $P(Y | \hat{Y})$. Pendekatan probabilistik ini menjadi dasar dalam analisis performa model klasifikasi pada bidang *pattern recognition* sebagaimana dibahas oleh Bishop (Bishop, 2006). Pada konteks klasifikasi multi-kelas, evaluasi performa model umumnya dilakukan menggunakan *confusion matrix*. Melalui pendekatan *one-vs-rest*, setiap kelas k diperlakukan sebagai kelas positif secara bergantian, sementara kelas lainnya dianggap sebagai kelas negatif. Komponen evaluasi klasifikasi untuk setiap kelas k dapat didefinisikan

sebagai berikut:

$$\begin{aligned}
 TP_k &= P(\hat{Y} = k \mid Y = k), \\
 FP_k &= P(\hat{Y} = k \mid Y \neq k), \\
 FN_k &= P(\hat{Y} \neq k \mid Y = k), \\
 TN_k &= P(\hat{Y} \neq k \mid Y \neq k).
 \end{aligned} \tag{32}$$

Keempat komponen tersebut merupakan estimasi empiris dari peluang bersyarat yang diperoleh berdasarkan hasil prediksi model. Oleh karena itu, metrik evaluasi klasifikasi dapat dirumuskan baik secara konvensional menggunakan *confusion matrix* maupun secara probabilistik menggunakan konsep peluang bersyarat. Secara umum, peluang bersyarat antara dua kejadian acak A dan B didefinisikan sebagai:

$$P(A \mid B) = \frac{P(A \cap B)}{P(B)}, \quad P(B) \neq 0. \tag{33}$$

Metrik evaluasi yang digunakan dalam penelitian ini meliputi *accuracy*, *precision*, *sensitivity (recall)*, *specificity*, dan *F1-score* (Taghipour-Gorjikolaie dkk., 2025). *Accuracy* merupakan metrik evaluasi yang mengukur proporsi prediksi yang benar dari keseluruhan prediksi yang dilakukan oleh model. Metrik ini menunjukkan seberapa tepat model dalam memprediksi seluruh sampel data, baik yang positif maupun negatif (Liao dkk., 2023). Secara konvensional, *accuracy* dirumuskan sebagai:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}. \tag{34}$$

Accuracy dalam perspektif probabilitas empiris dapat dipandang sebagai estimasi peluang bahwa label hasil prediksi model sesuai dengan label sebenarnya. Peluang tersebut dinyatakan sebagai:

$$Accuracy = P(\hat{Y} = Y), \tag{35}$$

Parameter Y menyatakan label aktual dan $\hat{Y}$ menyatakan label hasil prediksi model, karena prediksi yang benar terjadi ketika model menghasilkan *true positive* atau *true negative*, maka peluang $P(\hat{Y} = Y)$ dapat diestimasi secara empiris menggunakan perbandingan jumlah prediksi yang benar terhadap keseluruhan data uji, sehingga konsisten dengan Persamaan (34).

Precision atau *Positive Predictive Value* mengukur tingkat ketepatan prediksi model

terhadap suatu kelas tertentu dan dirumuskan sebagai:

$$Precision_k = \frac{TP_k}{TP_k + FP_k}. \quad (36)$$

Precision dalam kerangka probabilistik merepresentasikan peluang bahwa data benar-benar berasal dari kelas k ketika model memprediksi kelas tersebut, yang dinyatakan sebagai:

$$Precision_k = P(Y = k \mid \hat{Y} = k) = \frac{P(Y = k \cap \hat{Y} = k)}{P(\hat{Y} = k)}. \quad (37)$$

$$Precision_{macro} = \frac{1}{K} \sum_{k=1}^K Precision_k. \quad (38)$$

Sensitivity atau *Recall* mengukur kemampuan model dalam mendeteksi seluruh sampel yang benar-benar berasal dari kelas tertentu dan dirumuskan sebagai:

$$Sensitivity_k = \frac{TP_k}{TP_k + FN_k}. \quad (39)$$

Secara probabilistik, *sensitivity* merepresentasikan peluang bahwa model memprediksi kelas k ketika data tersebut memang berasal dari kelas k , yaitu:

$$Sensitivity_k = P(\hat{Y} = k \mid Y = k) = \frac{P(Y = k \cap \hat{Y} = k)}{P(Y = k)}. \quad (40)$$

$$Sensitivity_{macro} = \frac{1}{K} \sum_{k=1}^K Sensitivity_k. \quad (41)$$

Specificity mengukur kemampuan model dalam mengidentifikasi sampel yang tidak berasal dari suatu kelas tertentu dan dirumuskan sebagai:

$$Specificity_k = \frac{TN_k}{TN_k + FP_k}. \quad (42)$$

specificity dalam pendekatan probabilistik dinyatakan sebagai peluang bahwa model tidak memprediksi kelas k ketika data tersebut memang bukan berasal dari kelas k ,

yaitu:

$$Specificity_k = P(\hat{Y} \neq k \mid Y \neq k) = \frac{P(Y \neq k \cap \hat{Y} \neq k)}{P(Y \neq k)}. \quad (43)$$

$$Specificity_{macro} = \frac{1}{K} \sum_{k=1}^K Specificity_k. \quad (44)$$

F1-Score merupakan rata-rata harmonik antara *precision* dan *sensitivity* yang digunakan untuk menyeimbangkan ketepatan prediksi dan kemampuan deteksi model, terutama pada data dengan distribusi kelas tidak seimbang (Oza dkk., 2024). Metrik ini dirumuskan sebagai:

$$F1-Score_k = 2 \cdot \frac{Precision_k \cdot Sensitivity_k}{Precision_k + Sensitivity_k}. \quad (45)$$

$$F1-Score_{macro} = \frac{1}{K} \sum_{k=1}^K F1-Score_k. \quad (46)$$

F1-Score juga dapat dituliskan dalam kerangka probabilistik sebagai kombinasi dari dua peluang bersyarat, yaitu *precision* dan *sensitivity* dengan menggunakan definisi peluang bersyarat, *F1-Score* untuk kelas k dapat dinyatakan sebagai:

$$F1-Score_k = 2 \times \frac{P(Y = k \mid \hat{Y} = k) \times P(\hat{Y} = k \mid Y = k)}{P(Y = k \mid \hat{Y} = k) + P(\hat{Y} = k \mid Y = k)} \quad (47)$$

Receiver Operating Characteristic (ROC) merupakan kurva yang menggambarkan hubungan antara TPR dan FPR pada berbagai nilai *threshold*, sehingga mampu menunjukkan kemampuan model dalam membedakan kelas positif dan negatif secara menyeluruh (Liao dkk., 2023). AUC kemudian digunakan sebagai ukuran kuantitatif dari performa tersebut, di mana nilai AUC yang semakin mendekati satu menunjukkan bahwa model memiliki kapabilitas diskriminatif yang tinggi terhadap pola data (Arulanathan dkk., 2024). ROC–AUC dipilih karena metrik ini tidak bergantung pada satu *threshold* tertentu, lebih tahan terhadap ketidakseimbangan kelas, serta mampu mengevaluasi kualitas *ranking* probabilitas yang dihasilkan model sehingga cocok digunakan pada tugas klasifikasi medis yang membutuhkan sensitivitas tinggi dalam membedakan karakteristik citra (Ali dkk., 2022). Dua

teknik yang umum digunakan dalam kasus *multiclass* adalah *One-vs-Rest* (OvR) dan *One-vs-One* (OvO), yang memungkinkan kurva ROC dan nilai AUC dihitung secara sistematis untuk setiap kelas atau setiap pasangan kelas. Pendekatan ini membuat ROC–AUC tetap relevan dan informatif dalam penilaian performa model *multiclass* karena metrik tersebut tetap mampu menggambarkan kemampuan diskriminasi model terhadap lebih dari dua kelas (Giudici dkk., 2025).

Pada penelitian ini, pendekatan OvR digunakan karena bekerja dengan membentuk satu model biner untuk setiap kelas dengan menganggap kelas tersebut sebagai positif dan seluruh kelas lainnya sebagai negatif, sehingga menghasilkan kurva ROC dan nilai AUC yang merepresentasikan performa identifikasi setiap kelas secara individual. Teknik ini unggul dalam interpretasi makro karena memberikan gambaran menyeluruh tentang sejauh mana masing-masing kelas dapat dipisahkan dari kumpulan kelas lain (Giudici dkk., 2025). Sebaliknya, OvO membangun model biner untuk setiap pasangan kelas, sehingga menghasilkan evaluasi berbasis hubungan *pairwise* yang lebih sensitif terhadap perbedaan antar kelas yang memiliki kemiripan visual atau distribusi fitur yang berdekatan.

Confusion Matrix merupakan representasi tabular dari hasil klasifikasi yang menunjukkan jumlah prediksi benar dan salah pada masing-masing kelas (Aguilar-Ruiz & Michalak, 2024). Pada kasus biner, matriks ini terdiri dari empat komponen utama yaitu TP, TN, FP, dan FN yang disusun dalam format dua kali dua sebagaimana ditunjukkan pada Gambar 21 (a). Lalu pada Gambar 21 (b) merupakan skenario *confusion matrix multiclass*, dimana *confusion matrix* diperluas menjadi matriks berukuran $C \times C$, dengan C adalah jumlah kelas, dan setiap baris merepresentasikan kelas aktual sedangkan setiap kolom merepresentasikan kelas prediksi (Markoulidakis dkk., 2021).

		Predicted Class			
		C_1	C_2	...	C_N
Actual Class	C_1	$C_{1,1}$	FP	...	$C_{1,N}$
	C_2	FN	TP	...	FN
	...	...	...	...	...
	C_N	$C_{N,1}$	FP	...	$C_{N,N}$

		Predicted Class	
		Positive	Negative
Actual Class	Positive	TP	FN
	Negative	FP	TN

Gambar 21. *Confusion Matrix*: (a) Biner; (b) *Multiclass* (Markoulidakis dkk., 2021)

BAB III

METODOLOGI PENELITIAN

3.1 Tempat dan Waktu Penelitian

3.1.1 Tempat Penelitian

Penelitian ini dilaksanakan secara studi literatur di jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Lokasi bertempat di Jalan Prof. Dr. Soemantri Brojonegoro No.1, Gedong Meneng, Bandar Lampung.

3.1.2 Waktu Penelitian


Penelitian ini dilakukan pada semester ganjil tahun akademik 2025/2026 tepatnya bulan Agustus 2025. Proses pengerjaan terbagi menjadi tiga tahap. Tahap pertama melakukan pengumpulan, pemahaman terhadap literatur dan menentukan tema penelitian. Setelah menentukan tema penelitian, akan dilakukan pengumpulan data terkait. Tahap kedua merupakan tahap pengerjaan program yang dimulai dari *preprocessing data*, segmentasi citra melalui pemanfaatan PFCM, penentuan ROI, perolehan *pseudo-stadium labeling*, augmentasi data dan pemodelan klasifikasi menggunakan model TL. Tahap ketiga adalah penyusunan hasil penelitian dan kesimpulan penelitian.

3.2 Data dan Alat

3.2.1 Data

Data yang digunakan dalam penelitian ini berasal dari dataset *Mammographic Image Analysis Society* (MIAS) yang tersedia melalui *platform Kaggle* pada proyek

“*Mammography CNN Pytorch*” pada tautan <https://www.kaggle.com/code/nhanvi/mias-mammography-cnn-pytorch/input>. Dataset ini terdiri atas citra mammogram dan berkas anotasi yang memberikan informasi terkait karakteristik jaringan payudara serta jenis kelainan yang terdeteksi. Setiap citra memiliki resolusi 1024×1024 piksel dan disajikan dalam format PGM. Informasi tambahan terdapat pada berkas *Info.txt* yang berisi tujuh kolom deskriptif, mencakup nomor referensi citra, tipe jaringan latar belakang (*Fatty*, *Fatty-glandular*, atau *Dense-glandular*), kelas abnormalitas (seperti *Calcification*, *Circumscribed masses*, *Spiculated masses*, *Asymmetry*, hingga *Normal*), tingkat keparahan (*Benign* atau *Malignant*), serta koordinat pusat dan radius area kelainan dalam satuan piksel.



Gambar 22. Distribusi Data

Dataset MIAS diorganisir dalam pasangan citra yang merepresentasikan mammogram sisi kiri dan kanan dari setiap pasien, sehingga memungkinkan analisis komparatif antara kedua sisi payudara. Adapun beberapa citra menampilkan distribusi kalsifikasi yang tersebar luas sehingga tidak disertai dengan koordinat pusat atau radius yang pasti. Dataset ini bersifat publik dan hanya dapat digunakan untuk kepentingan penelitian sesuai dengan lisensi resmi dari MIAS. Hak cipta dataset sepenuhnya dimiliki oleh MIAS dan penggunaannya wajib disertai dengan sitasi yang tepat pada publikasi ilmiah. Tujuan utama penyediaan dataset ini

adalah untuk mendukung pengembangan metode otomatis dalam mendeteksi lesi pada mammogram serta membantu prediksi tingkat keganasan secara akurat guna menunjang diagnosis klinis. Pada penelitian ini hanya memanfaatkan 115 data yang merupakan data kelas abnormalitas/*cancer* seperti pada Gambar.

3.2.2 Alat

Adapun peralatan yang digunakan dalam penelitian ini adalah:

a. Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan dalam penelitian ini adalah laptop dengan merk *Vivobook ASUSLaptop X415EA A1400EA*. Spesifikasi *hardware* perangkat tersebut adalah sebagai berikut:

- *Processor* 11th Gen Intel® Core™ i3-1115G4 @3.00GHz, 3.00GHz
- Installed RAM 8 GB

b. Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan pada penelitian ini untuk mendukung dan menunjang penelitian ini, yaitu:

1. Sistem Operasi

Windows 10 Pro 64-bit, digunakan sebagai sistem operasi utama untuk menjalankan seluruh proses penelitian, mulai dari pengolahan data citra hingga pelatihan model klasifikasi.

2. *Overleaf* (LaTeX - TeX Live 2024)

Penulisan laporan penelitian ini dilakukan menggunakan LaTeX pada *platform Overleaf* yang mendukung penyusunan dokumen ilmiah secara terstruktur, konsisten, dan sesuai dengan kaidah penulisan akademik.

3. *Python* 3.10

Bahasa pemrograman utama yang digunakan dalam penelitian ini karena memiliki banyak pustaka (*library*) yang mendukung pengolahan citra, analisis data, dan pembelajaran mesin.

4. *Library NumPy* 1.26.4

NumPy digunakan untuk komputasi numerik dan manipulasi *array* multidimensi yang digunakan dalam representasi data citra serta perhitungan fungsi matematis pada algoritma PFCM.

5. *Library Pandas 2.2.2*

Pandas digunakan untuk pengolahan data tabular, seperti pengelolaan dataset hasil ekstraksi fitur dan penyimpanan hasil evaluasi model.

6. *Library Matplotlib 3.7.5 dan Seaborn 0.12.2*

Kedua pustaka ini digunakan untuk memvisualisasikan hasil penelitian, seperti proses konvergensi algoritma PFCM, distribusi cluster, serta grafik hasil akurasi klasifikasi.

7. *Library OpenCV 4.9.0*

OpenCV digunakan dalam tahap pra-pemrosesan citra, meliputi perubahan ukuran (*resizing*), konversi ke *grayscale*, normalisasi, augmentasi data, dan segmentasi awal citra.

8. *Library Scikit-learn 1.2.2*

Scikit-learn digunakan untuk membantu proses evaluasi hasil *clustering* dan klasifikasi, seperti penghitungan metrik *silhouette coefficient*, *davies-bouldin index*, *calinski-harabasz index*, *accuracy*, *precision*, *specificity*, *recall/sensitivity*, *f1-score* dan *confusion matrix*.

9. *Library TensorFlow 2.17.0 / PyTorch 2.4.0*

Salah satu dari kedua *framework* DL ini digunakan untuk membangun dan melatih model TL pada tahap klasifikasi citra.

10. *Library Fuzzy Clustering (custom implementation)*

Algoritma *Possibilistic Fuzzy C-Means (PFCM)* diimplementasikan secara manual menggunakan kombinasi *NumPy* dan *SciPy*, untuk menghasilkan pembobotan ganda antara keanggotaan (*membership*) dan derajat kemungkinan (*possibilistic degree*) dalam proses clustering citra.

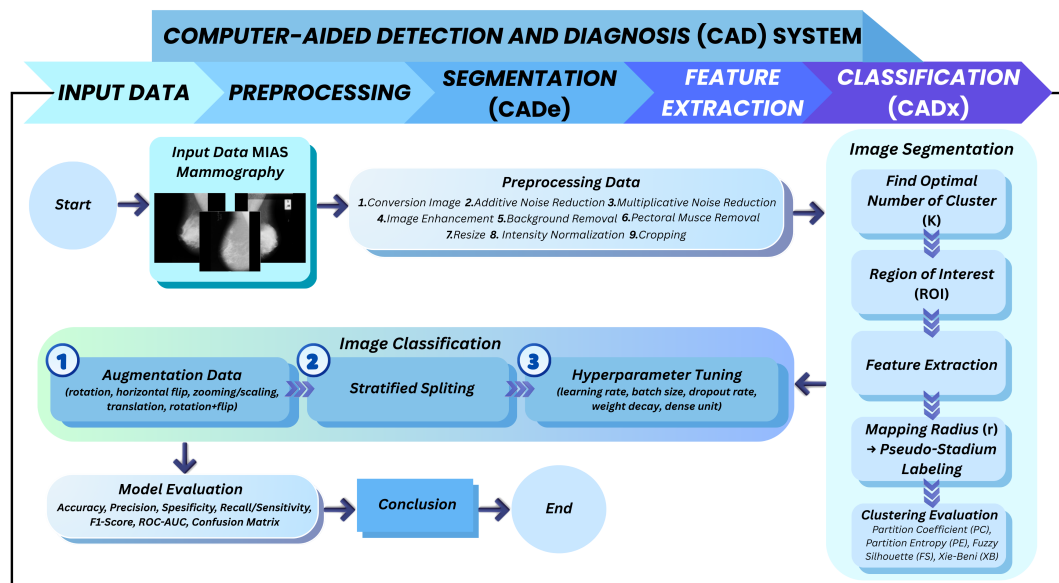
11. *Jupyter Notebook / Google Colab*

Lingkungan kerja interaktif yang digunakan untuk menjalankan kode, menampilkan hasil visualisasi, dan melakukan eksperimen secara bertahap pada dataset citra.

3.2.3 Metode Penelitian

Penelitian ini melakukan pengembangan sistem CAD dalam melakukan deteksi dan diagnosis dari data MIAS *Mammography*. Pada tahap awal dilakukan terlebih dahulu *preprocessing* data citra, agar data yang digunakan siap diolah pada tahap berikutnya. Deteksi kanker payudara ini dilakukan menggunakan algoritma PFCM

dalam mengidentifikasi ROI dan memperoleh *pseudo-stadium labeling*. Terakhir, pemanfaat label tersebut dalam tugas klasifikasi menggunakan model-model TL. Langkah lengkapnya yang dilakukan pada penelitian dapat diilustrasikan pada Gambar 23 sebagai berikut:



Gambar 23. Alur Penelitian

Berdasarkan alur penelitian pada Gambar 23, berikut penjelasan setiap tahapannya:

1. Melakukan penginputan data pada *software Python* melalui *Google Colab* sebagai tempat untuk menulis *code Python*.
2. Melakukan *preprocessing data* yang telah diinput. Proses *preprocessing data* meliputi *conversion image*, *additive noise reduction*, *multiplicative noise reduction*, *image enhancement*, *background removal*, *pectoral muscle removal*, *resize*, *intensity normalization*, *cropping*. Proses ini dilakukan agar dapat meningkatkan kualitas citra.
3. Melakukan *image segmentation* menggunakan PFCM untuk menguji K kluster terbaik yang ditentukan.
4. Melakukan ekstraksi ROI, yaitu pemisahan jaringan non-tumor dan tumor berdasarkan K kluster terbaik yang sudah diperoleh.

5. Melakukan *feature extraction* berdasarkan ROI pada tahapan sebelumnya. Proses ini dilakukan untuk memperoleh informasi *Centeroid* (x, y) dan *Radius* (r).
6. Melakukan *mapping* nilai r yang diperoleh sebelumnya untuk mendapatkan label baru berupa *pseudo-stadium labeling* berdasarkan AJCC-TNM menggunakan informasi Stadium T (T1, T2, T3, dan T4). Dasar *mapping* ini adalah melalui perhitungan dari *membership matrix*, *typicality matrix*, dan *combined matrix* hasil penerapan PFCM.
7. Melakukan *image classification* menggunakan model-model *pre-trained* TL.
8. Melakukan augmentasi terhadap data citra dari label *pseudo-stadium* menggunakan teknik *rotation*, *horizontal flip*, *zooming/scaling*, *translation* dan *rotation+flip*.
9. Melakukan *hyperparameter tuning* dengan menguji beberapa hyperparameter yang berpengaruh seperti *learning rate*, *batch size*, *dropout rate*, *weight decay*, dan *dense unit*. Serta menggunakan *hyperparameter* yang sudah ditetapkan dari awal seperti *epoch*, *early stoping patience*, *activation function*, *loss function* dan *optimization function*.
10. Melakukan evaluasi model klasifikasi dengan melihat nilai *accuracy*, *precision*, *spesificity*, *recall/sensitivity*, ROC-AUC, dan melalui visualisasi dari *confusion matrix*.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi sistem CAD berbasis citra mammogram yang terintegrasi, mulai dari tahap *preprocessing data*, segmentasi area tumor atau CADe, hingga klasifikasi tingkat keparahan kanker payudara atau CADx. Berdasarkan hasil eksperimen dan analisis yang telah dipaparkan pada Bab IV, diperoleh beberapa kesimpulan utama sebagai berikut.

1. Sistem CAD berhasil dikembangkan secara terintegrasi dengan mengombinasikan tahapan *preprocessing*, segmentasi CADe, pembentukan *pseudo-stadium labeling*, serta klasifikasi CADx berbasis TL. Integrasi antar tahapan ini memungkinkan alur analisis citra mammogram yang sistematis dan berkesinambungan, sehingga hasil dari setiap tahap dapat dimanfaatkan secara langsung pada tahap berikutnya tanpa kehilangan konteks informasi klinis.
2. Tahapan *preprocessing* terbukti berperan penting dalam meningkatkan kualitas citra mammogram sebelum dilakukan segmentasi dan klasifikasi. Proses peningkatan kontras, reduksi noise, serta penyeragaman ukuran citra mampu memperjelas karakteristik area lesi dan struktur jaringan payudara, sehingga mendukung performa algoritma segmentasi dan meningkatkan stabilitas proses ekstraksi fitur pada tahap klasifikasi. Dengan demikian, *preprocessing* menjadi fondasi penting dalam memastikan kualitas input sistem CAD.
3. Metode PFCM berhasil diterapkan pada tahap CADe untuk melakukan segmentasi area tumor pada citra mammogram. Pendekatan ini mampu mengakomodasi ketidakpastian dan variasi intensitas piksel yang umum ditemukan pada citra medis, sehingga menghasilkan segmentasi area tumor yang lebih adaptif terhadap noise dan variasi lokal dibandingkan metode klusterisasi konvensional.

4. Hasil segmentasi CADe dimanfaatkan untuk membentuk *pseudo-stadium labeling* melalui pendekatan yang bersifat kuantitatif dan otomatis berdasarkan ukuran tumor hasil segmentasi, yang dipetakan ke dalam kategori stadium T1–T4 sesuai dengan kriteria sistem AJCC–TNM. Pembentukan *pseudo-stadium labeling* ini merupakan kontribusi utama penelitian, karena memungkinkan proses pelabelan stadium dilakukan tanpa bergantung pada anotasi stadium klinis secara langsung. Pendekatan ini berperan sebagai jembatan konseptual antara tahap CADe dan CADx, di mana informasi spasial hasil segmentasi tidak hanya digunakan untuk deteksi, tetapi ditransformasikan menjadi representasi diagnosis terstruktur. Dengan demikian, *pseudo-stadium labeling* yang diusulkan menyediakan alternatif pelabelan yang reproduktibel dan dapat diskalakan, serta membuka peluang pengembangan sistem CAD yang lebih mandiri dan adaptif pada keterbatasan data berlabel klinis.
5. Model klasifikasi berbasis TL berhasil diterapkan pada tahap CADx untuk menilai tingkat keparahan kanker payudara secara otomatis menggunakan *pseudo-stadium labeling*. Berdasarkan hasil evaluasi pada skema augmentasi data, model DenseNet121 menunjukkan performa terbaik dibandingkan arsitektur lainnya, dengan nilai *accuracy* sebesar 0.9000, *precision* 0.9019, *sensitivity* 0.9000, *specificity* 0.9667, dan *F1-score* 0.8996. Selain itu, kemampuan diskriminasi model ini juga tercermin dari nilai *micro-average* AUC sebesar 0.9804 dan *macro-average* AUC sebesar 0.9783, yang mengindikasikan performa klasifikasi yang sangat baik dan konsisten pada seluruh kelas *pseudo-stadium*. Hasil ini menunjukkan bahwa DenseNet121 paling efektif dalam memanfaatkan informasi fitur hasil segmentasi CADe untuk mendukung proses diagnosis otomatis pada sistem CADx.
6. Strategi evaluasi sistem CAD dirancang secara objektif dan komprehensif dengan mencakup evaluasi pada tahap CADe dan CADx. Pada tahap CADe, kinerja segmentasi area tumor hasil penerapan metode PFCM dievaluasi menggunakan metrik validasi clustering, yaitu *Partition Coefficient* (PC), *Partition Entropy* (PE), *Fuzzy Silhouette* (FS), dan indeks *Xie–Beni* (XB), untuk menilai kualitas pemisahan kluster, tingkat keanggotaan *fuzzy*, serta kekompakan dan keterpisahan antar kluster. Sementara itu, pada tahap CADx, evaluasi performa klasifikasi dilakukan berdasarkan *confusion matrix*, perhitungan metrik *accuracy*, *precision*, *sensitivity*, *specificity*, dan *F1-score*, serta analisis kurva ROC-AUC. Penggunaan nilai *micro* dan *macro-average* AUC memberikan gambaran menyeluruh terhadap kemampuan diskriminasi

model pada masing-masing kelas *pseudo-stadium*, sehingga performa sistem CAD dapat dinilai secara adil, konsisten, dan representatif.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa sistem CAD yang dikembangkan mampu melakukan analisis citra mammogram secara terstruktur dan otomatis, mulai dari deteksi hingga penilaian tingkat keparahan kanker payudara. Integrasi metode segmentasi PFCM, *pseudo-stadium labeling*, dan klasifikasi berbasis TL memberikan kontribusi metodologis yang relevan dalam pengembangan sistem CAD yang adaptif dan berpotensi mendukung proses diagnosis klinis.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dijadikan acuan untuk pengembangan dan penyempurnaan sistem CAD pada penelitian selanjutnya, baik dari sisi metodologi maupun implementasi sistem.

1. Penelitian selanjutnya disarankan untuk mengeksplorasi dataset mammogram dengan jumlah sampel yang lebih besar dan berasal dari berbagai sumber, sehingga variasi karakteristik citra dan distribusi *pseudo-stadium* dapat direpresentasikan secara lebih komprehensif. Hal ini diharapkan dapat meningkatkan kemampuan generalisasi sistem CAD terhadap data klinis nyata.
2. Pada tahap CADe, pengembangan metode segmentasi dapat diarahkan pada pemanfaatan pendekatan *deep learning* berbasis segmentasi semantik, seperti U-Net atau arsitektur turunannya, sebagai pembanding terhadap metode *fuzzy clustering*. Perbandingan ini berpotensi memberikan wawasan lebih lanjut mengenai efektivitas segmentasi berbasis pembelajaran mendalam dibandingkan metode berbasis optimasi *fuzzy*.
3. Proses pembentukan *pseudo-stadium labeling* pada penelitian ini masih mengandalkan pendekatan berbasis ukuran tumor hasil segmentasi. Penelitian lanjutan dapat mempertimbangkan integrasi fitur tambahan, seperti bentuk, tekstur, atau informasi klinis pendukung, guna mendekati representasi stadium kanker payudara yang lebih komprehensif sesuai praktik klinis.
4. Pada tahap CADx, meskipun model DenseNet121 dan InceptionV3 menunjukkan performa yang sangat baik pada skema augmentasi, eksplorasi lebih lanjut terhadap arsitektur *transfer learning* yang lebih ringan atau model

vision transformer (ViT) dapat dilakukan untuk menilai *trade-off* antara kompleksitas model, akurasi, dan efisiensi komputasi.

5. Strategi evaluasi sistem CAD pada penelitian selanjutnya dapat diperluas dengan melibatkan metrik evaluasi klinis tambahan, seperti *cost-sensitive analysis* atau simulasi skenario kesalahan diagnosis, guna mengkaji dampak kesalahan klasifikasi terhadap pengambilan keputusan medis secara lebih realistis.
6. Implementasi sistem CAD dalam bentuk aplikasi atau prototipe berbasis antarmuka pengguna juga disarankan sebagai langkah lanjutan, sehingga sistem yang dikembangkan tidak hanya bersifat konseptual, tetapi dapat diuji secara langsung dalam lingkungan simulasi klinis.

DAFTAR PUSTAKA

- Abdulameer, G., & Ali, Y. H. (2025). *Enhanced clustering techniques for marine ad-hoc networks using dynamic PFCM*. *Fusion: Practice and Applications*, 18(1), 261–268. ASPG. doi: 10.54216/FPA.180118
- Aguilar-Ruiz, J. S., & Michalak, M. (2024). *Classification performance assessment for imbalanced multiclass data*. *Scientific Reports*, 14, 19759. Nature Publishing Group. doi: 10.1038/s41598-024-61365-7
- Alhichri, H. S., Alsuwayed, A., Bazi, Y., & Ammour, N. (2021). *Classification of remote sensing images using EfficientNet-B3 CNN model with attention*. *IEEE Access*, 9, 140214–140226. IEEE. doi: 10.1109/ACCESS.2021.3051085
- Ali, K., Shaikh, Z. A., Khan, A. A., & Laghari, A. A. (2022). *Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer*. *Neuroscience Informatics*, 2(4), 100034. Elsevier. doi: 10.1016/j.neuri.2021.100034
- Alshdaifat, E. H., Amin, M., Abu Mhanna, H. Y., Malkawi, M., Al-Mnayys, A. M., Gharaibeh, H., Akhdar, H. F., Madain, R., Alhatamleh, S., Al-Qbain, T. A., Asalmanc, N., Alomar, A., Mohammad, Q., & Sindiani, M. A. (2025). *(KAUH-BCUSD): Computer-aided breast cancer diagnosis using transformer and CNN using ultrasound dataset*. *Intelligence-Based Medicine*, 12, 100270. Elsevier. doi: 10.1016/j.ibmed.2025.100270
- Alwateer, M., Bamaq, A., Farsi, M., Aljohani, M., Shehata, M., & Elhosseini, M. A. (2025). *Transformative approaches in breast cancer detection: Integrating transformers into computer-aided diagnosis for histopathological classification*. *Bioengineering*, 12(2), 179. MDPI. doi: 10.3390/bioengineering12020179
- Al-Wesabi, F. N., Albarrak, A. A., Hilal, A. M., Al-Sharqabi, A. A., Alhabezi, S., & Al Duhayyim, M. (2021). *Design of optimal deep learning based human activity*

- recognition on sensor enabled Internet of Things environment. IEEE Access*, 9, 143988–143996. IEEE. doi: 10.1109/ACCESS.2021.3112973
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. Journal of Big Data*, 8(1), 53. SpringerOpen. doi: 10.1186/s40537-021-00444-8
- American Association for Cancer Research. (2025). *Breast cancer mortality in women ages 20–49 significantly dropped between 2010 and 2020*. News Release, AACR Annual Meeting 2025. American Association for Cancer Research.
- An, Q., Rahman, S., Zhou, J., & Kang, J. J. (2023). *A comprehensive review on machine learning in healthcare industry: Classification, restrictions, opportunities and challenges. Sensors*, 23(2), 4178. MDPI. doi: 10.3390/s23094178
- Arfi, M., Yadav, S. C., & Tripathi, S. L. (2024). *An integrated computer-aided diagnosis BCaND model for detection, segmentation and classification of breast cancer. Engineering Research Express*. IOP Publishing. doi: 10.1088/2631-8695/ad780e
- Arnold, M., Morgan, E., Rumgay, H., Mafra, A., Singh, D., Laversanne, M., Vignat, J., Gralow, J. R., Cardoso, F., Siesling, S., & Soerjomataram, I. (2022). *Current and future burden of breast cancer: Global statistics for 2020 and 2040. The Breast*, 66, 15–23. Elsevier. doi: 10.1016/j.breast.2022.08.010
- Arulanathan, S., Prakash, S. W., Ayyasamy, R. K., Kavitha, V. P., Kuppusamy, P. G., & Chinnasamy, P. (2024). *Classification of Paediatric Pneumonia Using Modified DenseNet-121 Deep-Learning Model. IEEE Access*, 12, 35716–35727. IEEE. doi: 10.1109/ACCESS.2024.3371151
- Ayeni, J. A. (2022). *Convolutional neural network (CNN): The architecture and applications. Applied Journal of Physical Science*, 4(4), 42–50. Integrity Research Journals. doi: 10.31248/AJPS2022.085
- Bang, C. S., Lee, J. J., & Baik, G. H. (2021). *Computer-aided diagnosis of esophageal cancer and neoplasms in endoscopic images: a systematic review and meta-analysis of diagnostic test accuracy. Gastrointestinal Endoscopy*, 93(5), 1006–1015. doi: 10.1016/j.gie.2020.11.025
- Bezdek, J. C. (1973). *Cluster validity with fuzzy sets. Journal of Cybernetics*, 3(3), 58–73. Taylor & Francis. doi: 10.1080/01969727308546047

- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., & Ghayvat, H. (2021). *CNN variants for computer vision: history, architecture, application, challenges and future scope*. *Electronics*, 10(20), 2470. MDPI. doi: 10.3390/electronics10202470
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer Science+Business Media.
- Chen, Y., Mancini, M., Zhu, X., & Akata, Z. (2024). *Semi-supervised and unsupervised deep visual learning: A survey*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 46(3), 1327–1347. IEEE. doi: 10.1109/TPAMI.2022.3201576
- Chen, Y., & Zhou, S. (2024). *Revisiting Possibilistic Fuzzy C-Means Clustering Using the Majorization–Minimization Method*. *Entropy*, 26(7), 670. MDPI. doi: 10.3390/e26070670
- Dada, E. G., Oyewola, D. O., & Misra, S. (2024). *Computer-aided diagnosis of breast cancer from mammogram images using deep learning algorithms*. *Journal of Electrical Systems and Information Technology*, 11(38). SpringerOpen. doi: 10.1186/s43067-024-00164-y
- Dihmani, H., Bousselham, A., & Boutaane, O. (2024). *A new computer-aided diagnosis system for breast cancer detection from thermograms using metaheuristic algorithms and explainable AI*. *Algorithms*, 17(10), 462. MDPI. doi: 10.3390/a17100462
- Eckardt, J.-N., Bornhäuser, M., Wendt, K., & Middeke, J. M. (2022). *Semi-supervised learning in cancer diagnostics*. *Frontiers in Oncology*, 12, 960984. Frontiers Media SA. doi: 10.3389/fonc.2022.960984
- El Ghazi, M., & Aknin, N. (2023). *Optimizing Deep LSTM Model through Hyperparameter Tuning for Sensor-Based Human Activity Recognition in Smart Home*. *Informatica*, 47, 109–122. doi: 10.31449/inf.v47i10.5268
- Fasterholdt, I., Naghavi-Behzad, M., Rasmussen, B. S. B., Kjælhede, T., Skjøth, M. M., Hildebrandt, M. G., & Kidholm, K. (2022). *Value assessment of artificial intelligence in medical imaging: a scoping review*. *BMC Medical Imaging*, 22(1), 187. Springer Nature. doi: 10.1186/s12880-022-00918-y

- Fico, N., Di Grezia, G., Cuccurullo, V., Salvia, A. A. H., Iacomino, A., Sciarra, A., & Gatta, G. (2023). *Breast imaging physics in mammography (Part I). Diagnostics*, 13(22), 3577. MDPI. doi: 10.3390/diagnostics13223577
- Firmino, M., Angelo, G., Morais, H., Dantas, M. R., & Valentim, R. (2016). *Computer-aided detection (CADe) and diagnosis (CADx) system for lung cancer with likelihood of malignancy. BioMedical Engineering OnLine*, 15(2), 152. BioMed Central. doi: 10.1186/s12938-015-0102-7
- Gandomkar, Z., Svingengphanom, S., Suleiman, M., Wong, D., Reed, W., Ekpo, E., Xu, D., Lewis, S., Evans, K., Wolfe, J. M., & Brennan, P. C. (2023). *Reliability of radiologists' first impression when interpreting a screening mammogram. PLOS ONE*, 18(4), e0284605. doi: 10.1371/journal.pone.0284605
- Garrucho, L., Kushibar, K., Osuala, R., Diaz, O., Catanese, A., del Riego, J., Bobowicz, M., Strand, F., Igual, L., & Lekadir, K. (2023). *High-resolution synthesis of high-density breast mammograms: Application to improved fairness in deep learning based mass detection. Frontiers in Oncology*, 13, 1044496. doi: 10.3389/fonc.2022.1044496
- Gao, Y., Lin, J., Zhou, Y., & Lin, R. (2023). *The application of traditional machine learning and deep learning techniques in mammography: a review. Frontiers in Oncology*, 13, 1213045. doi: 10.3389/fonc.2023.1213045
- Ghozia, A., Attiya, G., Adly, E., & El-Fishawy, N. (2020). *Intelligence is beyond learning: A context-aware artificial intelligent system for video understanding. Computational Intelligence and Neuroscience*, 2020, Article ID 8813089. doi: 10.1155/2020/8813089
- Giudici, P., Schrader, J., Rosciano, R. C., & Kummerfeld, D.-M. (2025). *A Multiclass ROC Curve*. arXiv:2510.15670v1 [stat.ME]. doi: 10.48550/arXiv.2510.15670
- Gulati, S., Dhamija, E., & Anand, R. (2022). *Imaging artifacts on synthesized mammogram: What a radiologist should know!. Indian Journal of Radiology and Imaging*, 32(4), 555–561. doi: 10.1055/s-0042-1753644
- Gürler, O., & Nasibov, E. (2024). *Comprehensive analysis of fuzzy C-means clustering and its variants. Journal of Modern Technology and Engineering*, 9(2), 69–93. doi: 10.62476/jmte9269
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition*. arXiv:1512.03385 [cs.CV]. doi: 10.48550/arXiv.1512.03385

- Hemali, S., Agrawal, S., Oza, P., Tanwar, S., & Alkhayat, A. (2023). *Mammogram Pre-processing Using Filtering Methods for Breast Cancer Diagnosis. I.J. Image, Graphics and Signal Processing*, 4, 44–58. doi: 10.5815/ijigsp.2023.04.04
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. arXiv:1704.04861 [cs.CV]. doi: 10.48550/arXiv.1704.04861
- Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2017). *Densely Connected Convolutional Networks*. arXiv:1608.06993 [cs.CV]. doi: 10.48550/arXiv.1608.06993
- Huynh, T. T. M., Le, T. M., That, L. T., Tran, L. V., & Dao, S. V. T. (2022). *A two-stage feature selection approach for fruit recognition using camera images with various machine learning classifiers. IEEE Access*, 10, 132260. IEEE. doi: 10.1109/ACCESS.2022.3237212
- Ikechukwu, A. V., Murali, S., Deepu, R., & Shivamurthy, R. C. (2021). *ResNet-50 vs VGG-19 vs training from scratch: A comparative analysis of the segmentation and classification of Pneumonia from chest X-ray images. Global Transitions Proceedings*, 2, 375–381. Elsevier. doi: 10.1016/j.gltp.2021.08.027
- Ilemoobayo, J., Durodola, O., Alade, O., Awotunde, O. J., Olanrewaju, A. T., Falana, O., Ogungbire, A., Osinuga, A., Ogunbiyi, D., Ifeanyi, A., Odezuluigbo, I. E., & Edu, O. E. (2024). *Hyperparameter tuning in machine learning: A comprehensive review. Journal of Engineering Research and Reports*, 26(6), 388–395. doi: 10.9734/jerr/2024/v26i618312
- International Agency for Research on Cancer (IARC). (2024). *Cancer Today — Fact Sheets by Country*. Global Cancer Observatory, World Health Organization. Tidak memiliki doi.
- Jiang, Z., Wang, L., Wu, Q., Shao, Y., Shen, M., Jiang, W., & Dai, C. (2022). *Computer-aided diagnosis of retinopathy based on vision transformer. Journal of Innovative Optical Health Sciences*, 15(2), 2250009. doi: 10.1142/S1793545822500092
- Kaur, N., & Hans, R. (2025). *Transfer learning for cancer diagnosis in medical images: A compendious study. International Journal of Computer and Intelligent Systems*, 2025(18:62). doi: 10.1007/s44196-025-00772-0

- Kementerian Kesehatan Republik Indonesia. (2023). *Pelaksanaan skrining kanker payudara dan kanker leher rahim melalui Sister Klinik UPK Kemenkes RI*. Kementerian Kesehatan RI. Tidak memiliki doi.
- Kim, C.-I., Hwang, S.-M., Park, E.-B., Won, C.-H., & Lee, J.-H. (2021). *Computer-Aided Diagnosis Algorithm for Classification of Malignant Melanoma Using Deep Neural Networks*. *Sensors*, 21(21), 6851. doi: 10.3390/s21216851
- Kim, H. E., Cosa-Linan, A., Santhanam, N., Jannesari, M., Maros, M. E., & Ganslandt, T. (2022). *Transfer learning for medical image classification: A literature review*. *BMC Medical Imaging*, 22(69). doi: 10.1186/s12880-022-00793-7
- Larroza, A., Pérez-Benito, F. J., Tendero, R., Perez-Cortes, J. C., Román, M., & Llobet, R. (2024). *Breast delineation in full-field digital mammography using the Segment Anything Model*. *Diagnostics*, 14(10), 1015. doi: 10.3390/diagnostics14101015
- Latha, M., Kumar, P. S., Chandrika, R. R., Mahesh, T. R., Kumar, V., & Guluwadi, S. (2024). *Revolutionizing breast ultrasound diagnostics with EfficientNet-B7 and explainable AI*. *BMC Medical Imaging*, 24, 230. doi: 10.1186/s12880-024-01404-3
- Liyew, C. M., Di Nardo, E., Ferraris, S., & Meo, R. (2025). *Hyperparameter optimization of machine learning models for predicting actual evapotranspiration*. *Machine Learning with Applications*, 20, 100661. doi: 10.1016/j.mlwa.2025.100661
- Krishnapuram, R., & Keller, J. M. (1993). *A possibilistic approach to clustering*. *IEEE Transactions on Fuzzy Systems*, 1(2), 98–110. doi: 10.1109/91.227387
- Kurniasari, D., Kurniawati, V., Nuryaman, A., Usman, M., & Nisa, R. K. (2024). *Implementation of fuzzy C-means and fuzzy possibilistic C-means algorithms on poverty data in Indonesia*. *BAREKENG: Journal of Mathematics and Its Applications*, 18(3), 1919–1930. doi: 10.30598/barekengvol18iss3pp1919-1930
- Lei, S., Zheng, R., Zhang, S., Wang, S., Chen, R., Sun, K., Zeng, H., Zhou, J., & Wei, W. (2021). *Global patterns of breast cancer incidence and mortality*. *Cancer Communications*, 41(11), 1183–1194. doi: 10.1002/cac2.12207

- Li, M., Jiang, Y., Zhang, Y., & Zhu, H. (2023). *Medical image analysis using deep learning algorithms*. *Frontiers in Public Health*, 11, 1273253. doi: 10.3389/fpubh.2023.1273253
- Liao, J., Lam, H.-K., Gulati, S., & Hayee, B. (2023). *Improved Computer-Aided Diagnosis System using Contrastive Self-Supervised Learning*. *International Journal of Network Dynamics and Intelligence*, 2(3). doi: 10.53941/ijnidi.2023.100010
- Liu, L., Wang, Y., Liu, X., Han, S., Jia, L., Meng, L., Yang, Z., Chen, W., Zhang, Y., & Qiao, X. (2021). *Computer-aided diagnostic system for colposcopy images*. *Annals of Translational Medicine*, 9(13), 1045. doi: 10.21037/atm-21-885
- Living Beyond Breast Cancer (LBBC). (2023). *How breast cancer is staged*. Tidak memiliki doi.
- Maqsood, S., Damaševičius, R., & Maskeliūnas, R. (2022). *TTCNN: A Breast Cancer Detection and Classification*. *Applied Sciences*, 12(7), 3273. doi: 10.3390/app12073273
- Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). *Multiclass Confusion Matrix Reduction Method*. *Technologies*, 9(4), 81. doi: 10.3390/technologies9040081
- Masoud, R. M., Bakir, R. M. A., Saraya, M. S., & Ayyad, S. M. (2025). *BREAST-CAD*. *Technologies*, 13(3), 286. doi: 10.3390/technologies13030286
- Mujahid, M., Rustam, F., Álvarez, R., Vidal Mazón, J. L., de la Torre Díez, I., & Ashraf, I. (2022). *Pneumonia classification from X-ray images*. *Diagnostics*, 12(6), 13380. doi: 10.3390/diagnostics120613380
- Müller, D., Soto-Rey, I., & Kramer, F. (2022). *Ensemble learning optimized medical image classification*. *IEEE Access*, 10, 68487–68480. doi: 10.1109/ACCESS.2022.3182399
- Nisa, R. K., Kurniasari, D., Lumbaraja, F. R., & Warsono, W. (2025). *Breast cancer area identification in mammograms*. *Karbala International Journal of Modern Science*, 11(1), Article 5. doi: 10.33640/2405-609X.3385
- Nissan, N., Ochoa Albiztegui, R. E., Fruchtman-Brot, H., Gluskin, J., Arita, Y., Amir, T., Reiner, J. S., Feigin, K., Mango, V. L., Johnson, M. S., & Sung, J. S.

- (2025). *Extremely dense breasts*. *European Journal of Radiology*, 182, 111837. doi: 10.1016/j.ejrad.2024.111837
- Oza, U., Gohel, B., Kumar, P., & Oza, P. (2024). *Presegmenter cascaded framework for mammogram mass segmentation*. *International Journal of Biomedical Imaging*, 2024, Article ID 9422083. doi: 10.1155/2024/9422083
- Pal, N. R., Pal, K., & Bezdek, J. C. (1997). *A mixed c-means clustering model*. In *Proceedings of the 6th International Fuzzy Systems Conference* (pp. 11–21). IEEE. doi: 10.1109/FUZZY.1997.616338
- Pal, N. R., Pal, K., Keller, J. M., & Bezdek, J. C. (2005). *A possibilistic fuzzy c-means clustering algorithm*. *IEEE Transactions on Fuzzy Systems*, 13(4), 517–530. doi: 10.1109/TFUZZ.2004.840099
- Rahman, T., Chowdhury, M. E. H., Khandakar, A., Islam, K. R., Mahbub, Z. B., Kadir, M. A., & Kashem, S. (2020). *Transfer learning with deep convolutional neural network (CNN) for pneumonia detection using chest X-ray*. *Applied Sciences*, 10(9), 3233. doi: 10.3390/app10093233
- Raiaan, M. A. K., Sakib, S., Fahad, N. M., Al Mamun, A., Rahman, M. A., Shatabda, S., & Mukta, M. S. H. (2024). *A systematic review of hyperparameter optimization techniques in Convolutional Neural Networks*. *Decision Analytics Journal*, 11, 100470. doi: 10.1016/j.dajour.2024.100470
- Ram, S., Vinoth, S., Gopalakrishnan, R. N., Balakumar, A. A., Kalinathan, L., Joseph Velankanni, T. A., & Bo, J. A. (2024). *Leveraging diverse CNN architectures for medical image captioning*. In *Working Notes of CLEF 2024*. CEUR-WS.org. Tidak memiliki doi.
- Rojas-Hernández, R., Díaz-de-León-Santiago, J. L., Barceló-Alonso, G., Bautista-López, J., Trujillo-Mora, V., & Salgado-Ramírez, J. C. (2022). *Lossless Medical Image Compression by Using Difference Transform*. *Entropy*, 24(7), 951. doi: 10.3390/e24070951
- Rose, J. D., Vijayakumar, K., Singh, L., & Sharma, S. K. (2022). *Computer-aided diagnosis for breast cancer detection*. *Concurrent Engineering Research and Applications*, 30(4), 393–403. doi: 10.1177/1063293X211058158
- Saber, A., Hussein, A. G., Awad, W. A., Mahmoud, A., & Allakany, A. (2023). *Adapting pre-trained CNNs for mammographic images*. *Scientific Reports*, 13, 46163. doi: 10.1038/s41598-023-46163-0

- Salloum, S. (2025). *K-Means clustering and classification of breast cancer images. JMIR Formative Research*, 9(e71974). doi: 10.2196/71974
- Satriyanto, E., Wardhani, N. W. S., Anam, S., & Mahmud, W. F. (2024). *Improved Fuzzy Possibilistic C-Means using Artificial Bee Colony. International Journal on Informatics Visualization*, 8(4), 2066–2074. doi: 10.30630/joiv.8.4.2066
- Sharma, R., & Kamra, A. (2023). *Enhancing diagnosis of breast cancer through mammographic image segmentation. International Journal of Sustainable Building Technology and Urban Development*, 14(4), 488–499. doi: 10.22712/susb.20230038
- Simonyan, K., & Zisserman, A. (2015). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. arXiv:1409.1556. doi: 10.48550/arXiv.1409.1556
- Simović, A., Lutovac-Banduk, M., Lekić, S., & Kuletó, V. (2022). *Smart Visualization of Medical Images. Diagnostics*, 12(12), 3208. doi: 10.3390/diagnostics12123208
- Sims, Z., Strgar, L., Thirumalaisamy, D., Heussner, R., Thibault, G., & Chang, Y. H. (2023). *SEG: Segmentation evaluation in absence of ground truth labels. bioRxiv*. doi: 10.1101/2023.02.23.529890
- Soomro, S., Niaz, A., Soomro, T. A., Kim, J., Manzoor, A., & Choi, K. N. (2023). *Selective image segmentation. PLOS ONE*, 18(12), e0294789. doi: 10.1371/journal.pone.0294789
- Suganyadevi, S., Seethalakshmi, V., & Balasamy, K. (2022). *A review on deep learning in medical image analysis. International Journal of Multimedia Information Retrieval*, 11(1), 19–38. doi: 10.1007/s13735-021-00218-1
- Szegedy, C., Liu, W., Jia, Y., et al. (2014). *Going deeper with convolutions. arXiv:1409.4842*. doi: 10.48550/arXiv.1409.4842
- Taghipour-Gorjikolaie, M., et al. (2025). *AI-based hierarchical approach for optimizing breast cancer detection. Biomedical Signal Processing and Control*, 100, 107143. doi: 10.1016/j.bspc.2024.107143
- Tan, M., & Le, Q. V. (2019). *EfficientNet. arXiv:1905.11946*. doi: 10.48550/arXiv.1905.11946
- Tao, W., et al. (2020). *Real-time assembly operation recognition. Procedia Manufacturing*, 48, 926–931. doi: 10.1016/j.promfg.2020.05.130

- Teichgraber, D. C., Guirguis, M. Y., & Whitman, G. J. (2021). *Breast cancer staging updates. American Journal of Roentgenology*, 217(2), 278–290. doi: 10.2214/AJR.20.25233
- Vijayargahavan, G. R., et al. (2023). *Audit of prior screening mammograms. Seminars in Ultrasound, CT and MRI*, 44(1), 62–69. doi: 10.1053/j.sult.2022.12.003
- Wang, J., Wang, S., & Zhang, Y. (2023). *Deep learning on medical image analysis. CAAI Transactions on Intelligence Technology*. doi: 10.1049/cit2.12356
- Welzl, E. (1991). *Smallest enclosing disks (balls and ellipsoids)*. *Computational Geometry*, 1(4), 195–202.
- Wenderott, K., et al. (2024). *Effects of AI implementation on efficiency in medical imaging. NPJ Digital Medicine*, 7(1), 265. doi: 10.1038/s41746-024-01248-9
- Wilk, A. M., et al. (2025). *Radiomics-based survival modelling. Computer Methods and Programs in Biomedicine*, 269, 108640. doi: 10.1016/j.cmpb.2025.108640
- World Health Organization (WHO). (2025). *Breast cancer: Fact sheet*. Tidak memiliki doi.
- Yang, Y., et al. (2021). *Comparative analysis of neural networks for COVID-19 lung images. Computers in Biology and Medicine*, 139, 104887. doi: 10.1016/j.combiomed.2021.104887
- Yilmaz, E., & Trocan, M. (2021). *Modified GoogLeNet for melanoma diagnosis. Journal of Information and Telecommunication*, 5(2), 123–138. doi: 10.1080/24751839.2021.1893495
- Yu, S. M., et al. (2024). *AI-based CAD for breast cancer detection. Hong Kong Medical Journal*, 29(6), 486–494. doi: 10.12809/hkmj2191020
- Zebari, D. A., et al. (2021). *Systematic review of CAD approaches for breast cancer. Applied Artificial Intelligence*, 35(15), 1217–1259. doi: 10.1080/08839514.2021.2001177
- Zhang, H., & Qie, Y. (2023). *Applying deep learning to medical imaging. Applied Sciences*, 13(19), 10221. doi: 10.3390/app13198221
- Zhang, Y., et al. (2025). *Global burden of female breast cancer. Journal of the National Cancer Center*, 5, 287–296. doi: 10.1016/j.jncc.2025.02.002

Zhang, Y.-D., Wang, S.-H., Liu, G., & Yang, J. (2016). *Computer-aided diagnosis of abnormal breasts*. *Advances in Mechanical Engineering*, 8(2), 1–11. doi: 10.1177/1687814016632413