

**IDENTIFIKASI CITRA X-RAY JANTUNG NORMAL DAN
PEMBESARAN JANTUNG (*CARDIOMEGALY*) BERDASARKAN
EKSTRAKSI CIRI TEKSTUR MENGGUNAKAN METODE
*RANDOM FOREST***

SKRIPSI

Disusun untuk Memenuhi Tugas dan Melengkapi Syarat Guna
Memperoleh Gelar Srata Satu (S1) dalam Ilmu Fisika



Oleh :

HESTI WINDYASARI

2108026001

**PROGRAM STUDI FISIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI WALISONGO SEMARANG
2025**

PERNYATAAN KEASLIAN

Yang bertanda tangan di bawah ini :

Nama : Hesti Windyasari

NIM : 2108026001

Jurusan : Fisika

Menyatakan bahwa skripsi saya yang berjudul:

**IDENTIFIKASI CITRA X-RAY JANTUNG NORMAL DAN
PEMBESARAN JANTUNG (CARDIOMEGALY)
BERDASARKAN EKSTRAKSI CIRI TEKSTUR
MENGUNAKAN METODE RANDOM FOREST**

Secara keseluruhan adalah hasil penelitian/karya saya sendiri,
kecuali bagian tertentu yang dirujuk sumbernya.

Semarang, 24 Juni 2025

Pembuat Pernyataan,



hesti Windyasari
NIM. 2108026001



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI WALISONGO
FAKULTAS SAINS DAN TEKNOLOGI
Jl. Prof. Dr. Hamka Ngaliyan Semarang
Telp. 024-7601295 Fax. 7615387

LEMBAR PENGESAHAN

Naskah skripsi berikut ini:

Judul : **IDENTIFIKASI CITRA X-RAY JANTUNG NORMAL
DAN PEMBESARAN JANTUNG (CARDIOMEGALY)
BERDASARKAN EKSTRAKSI CIRI TEKSTUR
MENGGUNAKAN METODE RANDOM FOREST**

Penulis : **Hesti Windyasari**
NIM : **2108026001**
Jurusan : **Fisika**

Telah diujikan dalam sidang *tugas akhir* oleh Dewan Penguji Fakultas Sains dan Teknologi UIN Walisongo dan dapat diterima sebagai salah satu syarat memperoleh gelar sarjana dalam Ilmu Fisika.

Semarang, 7 Juli 2025

DEWAN PENGUJI

Penguji I,

Alwiyah Nurhayati, Ph.D.
NIP. 198112112011012006

Penguji II,

Agus Sudarmanto, M.Si.
NIP. 197708232009121001

Penguji III,

Sheilla Rully Anggita, M.Si.
NIP. 199005052019032017

Penguji IV,

Istikomah, M.Sc.
NIP. 199011262019032021

Pembimbing I,

Muhammad Ardhi Khalif, M.Sc.
NIP. 198210092011011010

Pembimbing II,

Irman Said Prastyo, M.Sc.
NIP. 199112282019031009



NOTA DINAS

Semarang, 24 Juni 2025

Yth. Ketua Program Studi Fisika
Fakultas Sains dan Teknologi
UIN Walisongo Semarang

Assalamu'alaikum, wr.wb.

Dengan ini diberitahukan bahwa saya telah melakukan bimbingan, arahan dan koreksi naskah skripsi dengan:

Judul : **Identifikasi Citra X-Ray Jantung Normal Dan Pembesaran Jantung (Cardiomegaly) Berdasarkan Ekstraksi Ciri Tekstur Menggunakan Metode Random Forest**

Nama : Hesti Windyasari

NIM : 2108026001

Jurusan : Fisika

Saya memandang bahwa naskah skripsi tersebut sudah dapat diajukan kepada Fakultas Sains dan Teknologi UIN Walisongo untuk diujikan dalam Sidang Munaqosah.

Wassalamu'alaikum, wr.wb.

Pembimbing I



Muhammad Ardhi Khalif, M.Sc.

NIP. 198210092011011010

NOTA DINAS

Semarang, 24 Juni 2025

Yth. Ketua Program Studi Fisika
Fakultas Sains dan Teknologi
UIN Walisongo Semarang

Assalamu'alaikum warahmatullahi wabarakatuh

Dengan ini diberitahukan bahwa saya telah melakukan bimbingan, arahan dan koreksi naskah skripsi dengan:

Judul : IDENTIFIKASI CITRA X-RAY JANTUNG NORMAL
DAN PEMBESARAN JANTUNG (CARDIOMEGALY)
BERDASARKAN EKSTRAKSI CIRI TEKSTUR
MENGUNAKAN METODE RANDOM FOREST

Nama : Hesti Windyasari


NIM : 2108026001

Jurusan : Fisika

Saya memandang bahwa naskah skripsi tersebut sudah dapat diajukan kepada Fakultas Sains dan Teknologi UIN Walisongo untuk diujikan dalam Sidang Munaqasyah.

Wassalamu'alaikum warahmatullahi wabarakatuh

Pembimbing II,



Irman Said Prastyo, M.Sc.

NIP. 199112282019031009

ABSTRAK

Cardiomegaly adalah pembesaran jantung yang dapat menjadi tanda awal penyakit jantung serius. Penelitian ini bertujuan mengidentifikasi *cardiomegaly* pada citra X-ray menggunakan ekstraksi ciri tekstur dan klasifikasi dengan metode *Random Forest*. Fitur tekstur histogram yang digunakan mencakup (*mean, variance, skewness, kurtosis, entropy, standar deviasi*) dan GLCM (*homogeneity, contrast, entropy, correlation*), yang merepresentasikan distribusi intensitas dan pola spasial citra. Hasil ekstraksi histogram menunjukkan citra jantung normal memiliki nilai mean dan entropy lebih tinggi, sedangkan citra *cardiomegaly* lebih tinggi pada variance, skewness, standar deviasi, dan kurtosis. Pada fitur GLCM, citra normal memiliki contrast dan energy lebih tinggi, sementara *cardiomegaly* unggul pada homogeneity dan correlation. Pengujian dengan metode percentage split menunjukkan performa terbaik pada split 70%, 80%, dan 90%, dengan akurasi, presisi, dan recall masing-masing sebesar 100%. Hasil ini membuktikan bahwa kombinasi ekstraksi tekstur dan *Random Forest* efektif membedakan kondisi jantung normal dan *cardiomegaly*.

Kata Kunci: *Cardiomegaly, Citra X-ray, Histogram, GLCM, Random Forest.*

KATA PENGANTAR

Assalamualaikum Wr.Wb.

Puji syukur penulis panjatkan ke hadirat Allah SWT atas limpahan rahmat, karunia, serta kesehatan yang senantiasa diberikan, sehingga penulis dapat menyelesaikan penyusunan skripsi ini yang berjudul "Identifikasi Citra X-Ray Jantung Normal Dan Pembesaran Jantung (*Cardiomegaly*) Berdasarkan Ekstraksi Ciri Tekstur Menggunakan Metode *Random Forest*". Sholawat dan salam tak lupa penulis haturkan kepada junjungan Nabi Besar Muhammad SAW, sosok panutan umat yang telah membawa manusia keluar dari zaman kegelapan menuju cahaya ilmu pengetahuan. Semoga kita semua termasuk golongan umat beliau yang mendapatkan syafa'at di hari akhir kelak. Aamiin.

Penyusunan skripsi ini tidak terlepas dari doa, dukungan, bimbingan, semangat, serta kontribusi dari berbagai pihak. Oleh karena itu, penulis menyampaikan rasa terima kasih yang tidak terhingga kepada:

1. Allah SWT yang selalu mencurahkan kasih sayang, memberikan perlindungan, pertolongan, petunjuk, kesehatan, serta limpahan rahmat kepada penulis dalam setiap situasi.
2. Bapak Prof. Dr. H. Nizar, M.Ag., selaku Rektor Universitas Islam Negeri Walisongo Semarang.

3. Bapak Prof. Dr. Musahadi, M.Ag., selaku Dekan Fakultas Sains dan Teknologi di Universitas Islam Negeri Walisongo Semarang.
4. Ibu Alwiyah Nurhayati M.Si., Ph.D., selaku Ketua Program Studi Fisika.
5. Bapak Muhammad Ardhi Khalif, M.Sc., dan Bapak Irman Said Prastyo, M.Sc., selaku dosen pembimbing yang selalu membimbing dengan sabar, memberi masukan, dan koreksi pada skripsi ini.
6. Ibu Heni Sumarti, M.Si., selaku dosen peminatan Fisika Medis yang juga selalu membimbing dengan sabar, tulus, dan memberikan masukan serta koreksi pada skripsi ini.
7. Segenap Dosen serta pegawai dan seluruh Civitas akademik di lingkungan Fakultas Sains dan Teknologi UIN Walisongo terkhusus program studi Fisika.
8. Kedua orang tua tercinta, Bapak Hartoyo dan Ibu Purwanti, yang selalu memberikan semangat, dukungan secara moral maupun materi, serta tak henti mendoakan dan mencurahkan kasih sayang kepada penulis.
9. Adik tercinta Destyana Widya Iswary, serta segenap keluarga besar yang selalu memberi dukungan, nasehat dan do'a kepada penulis.

10. Ahmad Rafi yang senantiasa memberikan semangat, bantuan, motivasi, serta dukungan penuh kepada penulis.
11. Sahabat Ze Zahra Bilah, Aida Rahmawati , Manzila Putri Inaayah, Tara Elsa Shofiyana, yang selalu memberikan semangat dan dukungan.
12. Teman-teman Fisika angkatan 2021 yang selalu memberi dukungan.
13. Seluruh pihak yang telah berperan dan membantu dalam penyusunan skripsi ini, namun tidak dapat disebutkan satu per satu, yang kontribusinya sangat berarti hingga skripsi ini dapat diselesaikan dengan baik.

Dalam proses pelaksanaan dan penyusunan skripsi ini, penulis menyadari bahwa masih terdapat berbagai kekurangan dan belum mencapai kesempurnaan. Oleh karena itu, penulis sangat mengharapkan adanya kritik dan saran yang bersifat membangun guna memperbaiki dan menyempurnakan penulisan ini. Semoga skripsi ini dapat memberikan manfaat untuk semua pihak.

Wassalamualaikum Wr.Wb.

Semarang, 24 Juni 2025

Penulis,

Hesti Windyasari

NIM. 2108026001

DAFTAR ISI

PERNYATAAN KEASLIAN	iii
LEMBAR PERSETUJUAN	iii
NOTA DINAS	vii
NOTA DINAS	ix
ABSTRAK	xi
KATA PENGANTAR.....	xiii
DAFTAR ISI	xvii
DAFTAR GAMBAR.....	xxi
DAFTAR TABEL	xxiii
DAFTAR LAMPIRAN.....	xxv
BAB I PENDAHULUAN	1
A. Latar Belakang.....	1
B. Rumusan Masalah.....	10
C. Tujuan Penelitian	10
D. Manfaat Penelitian	11
E. Batasan Masalah.....	12
BAB II LANDASAN TEORI.....	14
A. Deskripsi Teori.....	14
1. Anatomi Jantung	15
2. Penyakit Jantung.....	20
3. Jantung Normal dan Pembesaran jantung.....	23

4. Sinar-X	26
5. Aplikasi Sinar-X.....	36
6. <i>Computer Aided Diagnosis</i> (CAD).....	40
7. Dasar Pengolahan Citra Digital	42
8. Ekstraksi Ciri Tekstur.....	48
9. <i>Random Forest</i>	55
10. Python.....	57
B. Kajian Pustaka	58
BAB III METODE PENELITIAN	62
A. Waktu dan Tempat Penelitian	62
B. Alat Penelitian.....	62
C. Bahan Penelitian	62
D. Pengolahan Data	63
1. Preprocessing	65
2. Ekstraksi Ciri Tekstur.....	65
3. Histogram	66
4. <i>Gray Level Co-occurrence Matrix</i> (GLCM).....	66
5. Klasifikasi Citra	67
6. Analisis Data.....	69
BAB IV HASIL DAN PEMBAHASAN	74
A. Pre-processing.....	74
1. Cropping	75
2. Resize	76

3. Rescale kerentang 0-1 (float32)	77
4. Clahe	78
5. Gaussian Blur	79
6. Rescale kembali ke 0-255.....	79
B. Ekstraksi Ciri Tekstur	80
C. Klasifikasi	81
1. Hasil klasifikasi metode Random Forest.....	82
2. Hasil Klasifikasi 10% percentage split.	83
3. Hasil Klasifikasi 20% percentage split.	84
4. Hasil Klasifikasi 30% percentage split.	85
5. Hasil Klasifikasi 40% percentage split.	86
6. Hasil Klasifikasi 50% percentage split.	87
7. Hasil Klasifikasi 60% percentage split.	88
8. Hasil Klasifikasi 70% Percentage Split.....	89
9. Hasil Klasifikasi 80% Percentage Split.....	90
10. Hasil Klasifikasi 90% Percentage Split.....	91
BAB V KESIMPULAN DAN SARAN.....	106
DAFTAR PUSTAKA	108
LAMPIRAN.....	122

DAFTAR GAMBAR

Gambar 2.1 Letak Jantung.....	16
Gambar 2.2 Citra Jantung.....	24
Gambar 2.3 Diagram tabung sinar-X.....	28
Gambar 2.4 Radiasi Bremsstrahlung.....	29
Gambar 2.5 Transisi elektron antar kulit	31
Gambar 2.6 Koefisien atenuasi linier ..Error! Bookmark not defined.	35
Gambar 2.7 Pesawat Sinar-X.....	37
Gambar 2.8 Representasi citra digital.....	44
Gambar 2.9 Citra Black and White(grayscale)	47
Gambar 2.10 Binary Image.....	48
Gambar 2.11 Prinsip fitur analisis tekstur	50
Gambar 3.1 Flowchard Pengolahan Data.....	64
Gambar 4.1 Citra X-ray.....	76
Gambar 4.2 Citra setelah di-Resize 500x500.....	77
Gambar 4.3 Citra Setelah di-Rescale ke rentang 0-1.....	78
Gambar 4.4 Citra Setelah dilakukan CLAHE.....	78
Gambar 4.5 Citra Setelah dilakukan Gaussian Blur.....	79
Gambar 4.6 Citra Setelah kembali ke rentang 0-255.....	80
Gambar 4.7 Klasifikasi menggunakan data training.....	82
Gambar 4.8 Klasifikasi 10% percentage split.	83
Gambar 4.9 Klasifikasi 20% percentage split.	85

Gambar 4.10 Klasifikasi 30% percentage split.....	86
Gambar 4.11 Klasifikasi 40% percentage split.....	87
Gambar 4.12 Klasifikasi 50% percentage split.....	88
Gambar 4.13 Klasifikasi 60% percentage split.....	89
Gambar 4.14 Klasifikasi 70% percentage split.....	90
Gambar 4.15 Klasifikasi 80% percentage split.....	91
Gambar 4.16 Klasifikasi 90% percentage split.....	92
Gambar 4.17 Sampel citra a) TP, b) FN, c) FP, d) TN.....	95

DAFTAR TABEL

Tabel 2.1 Karakteristik Fisik dan Atenuasi Linier (50 keV) Berbagai Material	35
Tabel 4.1 Hasil Klasifikasi Random Forest	93
Tabel 4.2 Rata-Rata Ciri Tekstur	97

DAFTAR LAMPIRAN

Lampiran 1. Code Program Pre-Processing	122
Lampiran 2. Hasil Ekstraksi Ciri Tekstur	125
Lampiran 3. Code Program Python Histogram_GLCM ..	130
Lampiran 4. Hasil Klasifikasi Ciri Tekstur.....	135
Lampiran 5. Hasil Trainingset dan Testingset	137
Lampiran 6. Tabel Hasil Klasifikasi	147
Lampiran 7. Daftar Riwayat Hidup.....	150
Lampiran 8. Persetujuan Pembimbing	151
Lampiran 9. Lembar Pengesahan.....	152

BAB I

PENDAHULUAN

A. Latar Belakang

Kesehatan tubuh merupakan kebutuhan primer bagi manusia, namun terkadang sebagian orang kurang memperhatikannya, didalam tubuh manusia mempunyai berbagai penyakit yang merupakan penyebab gangguan kesehatan pada tubuh manusia dan semua itu tidak asing bagi masyarakat, ini semua merupakan kendala yang sering dihadapi oleh masyarakat, semua manusia menyadari bahwa tubuhnya mengalami gangguan kesehatan, tetapi sebagian besar masyarakat tidak tahu penyakit yang sedang diderita tubuhnya serta pengobatannya (Nurkholis et al., 2017).

Pemahaman yang lebih mendalam mengenai gangguan kesehatan memerlukan pengetahuan tentang komponen utama tubuh yang berperan penting dalam kelangsungan hidup, salah satunya yaitu sistem kardiovaskular. Di dalam tubuh manusia, terdapat beberapa komponen penting, dan sistem kardiovaskular menjadi salah satu di antaranya. Sistem ini tersusun atas jantung dan pembuluh darah yang membentuk jaringan

organ yang kompleks. Fungsinya meliputi pemompaan darah ke seluruh tubuh, penyaluran oksigen dan nutrisi ke sel-sel, serta pengangkutan limbah metabolisme untuk dibuang. Kesehatan memiliki peranan yang sangat penting bagi manusia, sebab tubuh yang sehat memungkinkan kita menjalani aktivitas sehari-hari dengan lancar dan berpikir dengan jernih. Dari sekian banyak organ tubuh, jantung termasuk yang harus dijaga kesehatannya. Peran vital yang dimilikinya membuat gangguan sekecil apa pun dapat memengaruhi kinerja tubuh secara keseluruhan(Basuki, 2020). Penyakit jantung adalah penyebab utama kematian di seluruh dunia(Dian et al., 2021). seiring bertambahnya usia, fungsi jantung seseorang akan terpengaruh. Jantung yang terus-menerus bekerja akan memengaruhi kemampuannya, yang pada akhirnya dapat mengalami penurunan. Proses kerja jantung yang berlangsung secara berulang dan terus-menerus ini dikenal sebagai denyut jantung(Wahidah & Harahap, 2021).

Salah satu bentuk gangguan pada sistem kardiovaskular yang perlu mendapatkan perhatian khusus adalah pembesaran jantung atau yang dikenal dengan istilah *cardiomegaly*. *Cardiomegaly* adalah kondisi pembesaran jantung, di mana jantung memiliki berat yang

lebih tinggi dibandingkan jantung normal. Deteksi dini terhadap *cardiomegaly* sangat penting, karena kondisi ini berperan sebagai faktor utama dalam penyakit jantung yang serius. Selain itu, deteksi dini juga dapat membantu mengurangi risiko komplikasi yang disebabkan oleh *cardiomegaly*. Penggunaan teknologi kecerdasan buatan dalam sistem pendukung keputusan medis berbasis data medis memberikan kontribusi signifikan dalam bidang kedokteran. Oleh karena itu, teknik analisis yang dihasilkan oleh sistem medis menjadi faktor kunci dalam pengembangan dan penerapan solusi yang efektif(Azizah et al., 2024).

Dalam upaya menangani *cardiomegaly* secara lebih efisien, perkembangan teknologi medis telah memainkan peran yang sangat penting, khususnya dalam hal deteksi dini dan diagnosis. Teknologi pencitraan medis seperti X-ray, CT Scan, dan MRI telah lama digunakan untuk melihat struktur dan ukuran jantung secara visual, memungkinkan dokter untuk mengidentifikasi adanya *cardiomegaly*(Islam et al., 2017). Namun, kemajuan terbaru dalam bidang kecerdasan buatan (*Artificial Intelligence/AI*) telah membawa solusi yang lebih canggih dan akurat. Dengan menggunakan metode ekstraksi ciri tekstur dari citra X-ray dan pengolahan citra digital,

sistem berbasis AI kini dapat digunakan untuk mendeteksi cardiomegaly secara otomatis dan lebih cepat(Rajpurkar et al., 2017). Teknik seperti *machine learning* dan *deep learning* memungkinkan komputer untuk mempelajari pola-pola kelainan pada citra medis, sehingga membantu dokter dalam pengambilan keputusan klinis secara lebih objektif(Kermany et al., 2018). Selain itu, teknologi ini juga berpotensi digunakan dalam sistem pendukung keputusan medis (*clinical decision support systems*), yang dapat meningkatkan efisiensi dan akurasi diagnosis penyakit jantung, terutama di wilayah dengan keterbatasan tenaga medis spesialis(Y. Tang et al., n.d.). Peran teknologi ini tidak hanya membantu dalam proses diagnosis, tetapi juga menjadi bagian penting dari upaya preventif terhadap penyakit jantung. Dengan memahami pentingnya deteksi dini terhadap gangguan jantung seperti *cardiomegaly*.

Berbagai metode telah dikembangkan untuk mengklasifikasikan citra X-ray, seperti *Random Forest*, *Naïve Bayes*, *Convolutional Neural Network (CNN)*, dan arsitektur *VGG19*. *Naïve Bayes* adalah metode klasifikasi yang menggunakan probabilitas berdasarkan teorema Bayes dengan asumsi bahwa fitur-fitur dalam data saling independen. Meskipun sederhana, metode ini sering

digunakan untuk klasifikasi teks dan citra karena kecepatan dan efisiensinya. Dalam studi oleh Khan et al., (2023) *Naïve Bayes* digunakan sebagai meta-pelajar dalam ensemble yang terdiri dari empat classifier CNN untuk mendeteksi pneumonia dari citra X-ray dada. Model ini mencapai skor F1 sebesar 98% untuk kelas pneumonia. Namun, kelemahan utama dari metode ini adalah asumsi independensi antar fitur, yang jarang terpenuhi dalam data citra medis. Ketergantungan antar fitur tekstur dapat menyebabkan penurunan akurasi klasifikasi. Selain itu, *Naïve Bayes* cenderung kurang efektif dalam menangani data kontinu dan kompleksitas tinggi, seperti yang sering ditemukan dalam citra X-ray.

Convolutional Neural Network (CNN) adalah arsitektur *deep learning* yang dirancang khusus untuk memproses data berbentuk grid, seperti gambar. CNN menggunakan lapisan konvolusi untuk mengekstraksi fitur otomatis dari citra, yang memungkinkan model untuk mengenali pola dan struktur kompleks dalam gambar tanpa perlu ekstraksi fitur manual. Penelitian oleh Kailasam & Balasubramanian, (2025) mengembangkan model *deep learning* untuk klasifikasi citra X-ray dada dalam mendeteksi pneumonia. Model ini mencapai akurasi yang tinggi dalam klasifikasi biner *COVID-19* dan

Tidak Ada Temuan dan multi-kelas *COVID-19* dan Tidak Ada Temuan vs. *Pneumonia*. Namun, kelemahan dari metode ini adalah kebutuhan akan data pelatihan dalam jumlah besar dan sumber daya komputasi yang signifikan. Selain itu, CNN rentan terhadap overfitting jika tidak dilengkapi dengan teknik regularisasi yang tepat.

VGG19 adalah metode *deep learning* berbasis *Convolutional Neural Network* (CNN) yang memiliki arsitektur dalam berupa 19 lapisan, terdiri dari lapisan konvolusi dan lapisan fully connected. Metode ini dikenal karena kesederhanaan struktur dan kemampuannya dalam menangkap fitur visual yang kompleks dari citra melalui filter berukuran kecil (3x3). Studi oleh Bougias et al., (2021) menggunakan 2000 citra X-ray dada yang dibagi secara seimbang antara citra normal dan yang mengindikasikan cardiomegaly. Meskipun metode *VGG19* menghasilkan akurasi tertinggi sebesar 84,5%, kesalahan klasifikasi masih terjadi, terutama pada citra dengan batas jantung yang tidak jelas. Hal ini disebabkan karena pendekatan klasifikasi yang digunakan hanya menganalisis citra secara keseluruhan tanpa memperhatikan informasi spasial atau bentuk organ secara rinci.

Dalam studi oleh Z. Tang et al., (2020) *Random Forest* digunakan untuk menilai tingkat keparahan *COVID-19* berdasarkan fitur kuantitatif dari citra CT dada, seperti volume dan rasio area *ground-glass opacity* (GGO). Model ini mencapai akurasi 87,5% dan area di bawah kurva ROC sebesar 0,91. Namun, pendekatan ini memiliki beberapa kelemahan. Tanpa ekstraksi ciri tekstur yang mendalam, model mungkin kehilangan informasi spasial penting yang dapat mempengaruhi akurasi klasifikasi. Selain itu, model ini hanya mengklasifikasikan kasus menjadi dua kategori kasus ringan dan kasus berat, sehingga tidak dapat memberikan penilaian yang lebih rinci mengenai tingkat keparahan penyakit. Pendekatan ini juga tidak mempertimbangkan fitur klinis lainnya yang dapat berkontribusi pada penilaian keparahan *COVID-19* secara lebih komprehensif.

Salah satu metode klasifikasi yang dapat dimanfaatkan untuk mengolah hasil ekstraksi ciri tekstur tersebut adalah metode *Random Forest*, yang telah terbukti efektif dalam berbagai studi analisis citra medis, termasuk dalam mendeteksi kelainan pada citra X-ray dada. Analisis citra X-ray menggunakan metode *Random Forest* merupakan salah satu metode pembelajaran mesin berbasis ensemble yang terdiri dari kumpulan pohon

keputusan (*decision trees*). Metode ini bekerja dengan membangun banyak pohon selama proses pelatihan, kemudian menggabungkan hasil prediksi dari masing-masing pohon untuk menentukan hasil akhir berdasarkan suara terbanyak. *Random Forest* dikenal handal dalam menangani data berukuran besar dan kompleks, serta memiliki ketahanan terhadap *overfitting*. Metode ini juga cocok diterapkan pada permasalahan klasifikasi citra, termasuk citra medis seperti X-ray dada. Salah satu penelitian yang mengimplementasikan metode *Random Forest* untuk menganalisis citra X-ray adalah studi oleh Hidayat et al., (2023), Penelitian ini menggunakan metode *Random Forest* untuk klasifikasi penyakit jantung dengan penerapan teknik pre-processing seperti penanganan missing value dan normalisasi data. Pengujian dilakukan dengan dua skenario pembagian data, dan hasil terbaik diperoleh pada split data 80% dengan akurasi sebesar 94%. Dalam penelitian yang telah dilakukan sebelumnya menunjukkan bahwa penggunaan ekstraksi ciri tekstur dapat meningkatkan akurasi, sensitivitas model terhadap pola spasial, dan interpretabilitas hasil klasifikasi, dibandingkan dengan pendekatan yang hanya mengandalkan fitur kuantitatif dasar dari citra tanpa

mempertimbangkan informasi tekstural secara mendalam.

Menanggapi berbagai keterbatasan yang ditemukan dalam studi sebelumnya, pendekatan ekstraksi ciri tekstur mulai mendapat perhatian sebagai solusi potensial untuk meningkatkan interpretabilitas serta akurasi dalam analisis citra medis. Dalam penelitian analisis citra medis, ekstraksi ciri tekstur memainkan peran penting dalam mengidentifikasi pola radiologis yang tidak mudah dikenali oleh pengamatan visual langsung, , hal ini menjadi dasar munculnya pendekatan baru.

Sebagai bentuk pembaruan dalam penelitian ini, pendekatan yang digunakan yaitu ekstraksi ciri tekstur dengan metode klasifikasi *Random Forest*. Kombinasi ini dipilih sebagai alternatif yang lebih efisien karena memiliki sejumlah keunggulan, seperti kemampuan beroperasi secara optimal pada dataset yang terbatas, memberikan interpretasi hasil yang lebih mudah dipahami dibandingkan dengan model *deep learning*, serta efisiensi komputasi yang lebih tinggi. *Random Forest* juga dikenal memiliki ketahanan terhadap overfitting dan mampu menangani data berdimensi tinggi secara efektif. Dengan mengadopsi teknik ekstraksi ciri tekstur dari citra

X-ray sebagai input ke dalam model *Random Forest*, penelitian ini diharapkan dapat meningkatkan akurasi dalam proses identifikasi cardiomegaly, sekaligus memberikan kontribusi terhadap pengembangan sistem pendukung keputusan (*decision support system*) yang dapat membantu tenaga medis dalam melakukan diagnosis secara lebih cepat, tepat, dan andal.

B. Rumusan Masalah

1. Bagaimana perbandingan nilai citra X-ray jantung normal dan cardiomegaly menggunakan ekstraksi ciri tekstur pada citra X-ray yang diklasifikasikan dengan metode *Random Forest*?
2. Bagaimana hasil klasifikasi identifikasi cardiomegaly dan normal pada citra X-ray, dengan akurasi, presisi, dan recall yang dihitung berdasarkan ekstraksi tekstur citra?

C. Tujuan Penelitian

1. Untuk mengetahui perbandingan citra X-ray jantung normal dan cardiomegaly menggunakan metode ekstraksi ciri tekstur pada citra X-ray yang diklasifikasikan dengan metode *Random Forest*.
2. Untuk mengetahui hasil klasifikasi identifikasi cardiomegaly dan normal pada citra X-ray, dengan

akurasi, presisi, dan recall yang dihitung berdasarkan ekstraksi tekstur citra.

D. Manfaat Penelitian

1. Bagi Peneliti dan Pembaca

Penelitian ini memberikan wawasan mengenai identifikasi penyakit di toraks menggunakan citra X-ray melalui pendekatan ekstraksi ciri tekstur. Studi ini bertujuan untuk memperkenalkan metode diagnostik non-invasif yang bermanfaat bagi praktisi kesehatan serta memberikan kontribusi bagi pengembangan keahlian peneliti dalam analisis citra medis.

2. Bagi Tenaga Kesehatan

Berguna untuk meningkatkan kemampuan dalam mendeteksi pembesaran jantung (*cardiomegaly*) dengan menggunakan citra X-ray. Tenaga kesehatan dapat melakukan diagnosis yang lebih cepat dan non-invasif tanpa prosedur seperti kateterisasi atau pemeriksaan invasif lainnya dengan menggunakan ekstraksi ciri tekstur pada gambar X-ray. Hasil penelitian ini juga dapat membantu tenaga kesehatan memahami pola perubahan tekstur yang terjadi pada jantung akibat pembengkakan, sehingga

mereka dapat memberikan perawatan yang lebih tepat dan spesifik untuk setiap pasien. Selain itu, penelitian ini dapat menjadi dasar untuk pengembangan metode diagnostik berbasis gambar yang lebih baik di masa depan, yang akan membantu tenaga kesehatan dalam memberikan perawatan yang lebih efektif dan cepat dalam mendeteksi penyakit jantung.

3. Bagi Institusi

Penelitian ini meningkatkan reputasi akademik dan ilmiah institusi yang menaungi penelitian ini. Institusi tersebut dikenal sebagai pelopor dalam penelitian inovatif yang menggabungkan teknologi X-ray dengan studi mengenai pembesaran jantung (*cardiomegaly*), khususnya dalam mengembangkan metode diagnostik berbasis ekstraksi ciri tekstur untuk mendeteksi penyakit jantung.

E. Batasan Masalah

1. Data citra X-ray jantung diambil di website kaggle.com.
2. Studi ini akan mengklasifikasikan gambar X-ray jantung berdasarkan karakteristik tekstur. Tujuan dari klasifikasi ini adalah untuk melihat

bagaimana kondisi jantung dan adanya pembesaran jantung (*cardiomegaly*) dapat terdeteksi melalui perubahan tekstur pada citra X-ray.

3. Penelitian ini akan menggunakan Python untuk melakukan tahap pra-pengolahan hingga ekstraksi ciri tekstur. Python akan digunakan untuk menganalisis gambar X-ray jantung, memungkinkan pengolahan data yang akurat tentang bagaimana *cardiomegaly* dapat teridentifikasi melalui analisis tekstur gambar. Dengan menggunakan Python, diharapkan analisis gambar dapat dilakukan dengan metode yang lebih canggih dan menghasilkan hasil yang lebih tepat.

BAB II

LANDASAN TEORI

A. Deskripsi Teori

Dalam Al-Qur'an, seperti dalam surah Fussilat (QS. Fussilat: 53), terdapat penekanan pada tanda-tanda kebesaran Allah dalam penciptaan manusia dan dorongan untuk memahami keajaiban yang ada di dalam diri kita:

سَنُرِيهِمْ آيَاتِنَا فِي الْأَفَاقِ وَفِي أَنْفُسِهِمْ حَتَّىٰ يَتَبَيَّنَ لَهُمْ أَنَّهُ الْحَقُّ ۖ أَوَلَمْ يَكْفِ بِرَبِّكَ أَنَّهُ عَلَىٰ كُلِّ شَيْءٍ شَهِيدٌ ﴿٥٣﴾

“Kami akan memperlihatkan kepada mereka tanda-tanda (kebesaran) Kami di segenap penjuru dan pada diri mereka sendiri, hingga jelaslah bagi mereka bahwa Al-Qur'an itu benar. Dan apakah Tuhanmu tidak cukup (bagi kamu), bahwa Dia menyaksikan segala sesuatu?”

Tafsir dari Al-Muyassar menyebutkan bahwa ayat ini menyinggung segala sesuatu yang ada dalam diri manusia, termasuk proses tubuh yang menunjukkan kebesaran Allah, seperti penyembuhan luka, regenerasi sel, dan respons tubuh terhadap penyakit. Melalui

penelitian ilmiah dan teknologi, manusia dapat memahami lebih dalam tanda-tanda kebesaran-Nya sekaligus menjalankan tanggung jawab untuk menjaga tubuh sebagai bentuk ibadah. Pemanfaatan teknologi untuk deteksi dini penyakit, seperti pembesaran jantung, mencerminkan usaha manusia untuk mengoptimalkan ilmu pengetahuan dalam rangka memelihara kesehatan yang telah Allah karuniakan(quranhadits.com).


Surah Fussilat (QS. Fussilat: 53) menunjukkan bahwa tanda-tanda kebesaran Allah dapat ditemukan baik di alam semesta maupun dalam tubuh manusia. Hal ini relevan dengan penelitian dalam bidang medis, termasuk identifikasi pembesaran jantung (*cardiomegaly*) menggunakan teknologi seperti X-ray. Teknologi ini membantu manusia memahami kondisi tubuh mereka dan mendeteksi kelainan dengan lebih akurat, sebagai bentuk eksplorasi dari tanda-tanda kebesaran Allah yang tersembunyi dalam tubuh.

1. Anatomi Jantung

Jantung adalah organ tubuh manusia yang berfungsi untuk memompa darah ke seluruh tubuh. Jantung terletak di dalam rongga dada dan terdiri dari empat ruang, yaitu dua serambi (*atrium*) dan dua bilik

(*ventrikel*). Darah yang dipompa oleh jantung membawa oksigen dan nutrisi ke seluruh tubuh serta mengangkut sisa metabolisme untuk dikeluarkan. Jantung berperan sangat penting dalam sistem sirkulasi darah, yang mendukung fungsi organ dan jaringan tubuh agar tetap berfungsi dengan baik.

a. Letak Jantung



Gambar 2.1 Letak

Jantung(openstax.org/books/anatomy-and-physiology).

Berdasarkan gambar 2.1 jantung manusia terletak di dalam rongga toraks, tepat di antara kedua paru-paru pada area yang dikenal sebagai mediastinum. Posisi jantung dalam rongga *toraks*

berada di dalam mediastinum, jantung terpisah dari struktur mediastinal lainnya oleh membran kuat yang disebut perikardium atau kantung perikardial, dan menempati ruang khusus yang disebut rongga perikardial. Permukaan dorsal jantung berada dekat dengan badan vertebra, sedangkan permukaan anteriornya terletak di belakang sternum dan tulang-tulang rawan iga. Pembuluh darah besar, yaitu vena kava superior dan inferior, serta aorta dan batang pulmonalis, berhubungan dengan permukaan superior jantung yang disebut dasar jantung. Dasar jantung ini sejajar dengan tulang rawan iga ketiga. Ujung inferior jantung, yang disebut apeks, terletak sedikit ke kiri sternum, di antara pertemuan tulang iga keempat dan kelima dengan tulang rawannya. Bagian kanan jantung cenderung terdorong ke anterior, sedangkan bagian kirinya terdorong ke posterior. Pemahaman mengenai posisi dan orientasi jantung ini penting, terutama saat melakukan auskultasi menggunakan stetoskop ataupun saat menginterpretasikan citra dari bidang midsagital. Penyimpangan ringan apeks ke arah kiri ini membentuk lekukan pada

permukaan medial lobus inferior paru-paru kiri, yang disebut *cardiac notch* (openstax.org/books/anatomy-and-physiology).

Selain basis dan apeks, jantung memiliki beberapa bagian penting lainnya. Permukaan anterior, yang menghadap paru-paru kanan dan membentang dari permukaan inferior hingga basis jantung, terletak di belakang sternum dan tulang rusuk. Permukaan ini didominasi oleh ventrikel kanan. Permukaan inferior, yang terletak di antara apeks dan sisi kanan jantung, sebagian besar berada di atas diafragma. Bagian ini terutama dibentuk oleh ventrikel kanan, serta bagian bawah atrium kanan dan apeks ventrikel kiri. Permukaan kanan jantung sepenuhnya terdiri dari atrium kanan. Sementara itu, permukaan kiri, yang menghadap paru-paru kiri dan membentang dari basis hingga apeks jantung, sebagian dibentuk oleh aurikula atrium kiri dan ventrikel kiri (Lestari & Setiawan, 2021).

Jantung merupakan organ vital yang memiliki peran sentral dalam sistem kardiovaskular, dengan fungsi utamanya sebagai pompa yang mengedarkan darah ke seluruh

tubuh. Darah yang kaya oksigen dipompa dari ventrikel kiri ke seluruh jaringan tubuh, sementara darah terdeoksigenasi dipompa dari ventrikel kanan menuju paru-paru untuk pertukaran gas. Fungsi jantung ini memungkinkan tubuh memperoleh oksigen dan nutrisi yang dibutuhkan serta mengeluarkan karbon dioksida dan produk limbah metabolik (Tsuroyya et al., 2025). Selain itu, jantung juga berperan dalam menjaga tekanan darah melalui pengaturan volume darah yang dipompa, serta beradaptasi terhadap kebutuhan metabolik tubuh yang berubah-ubah, seperti saat berolahraga atau dalam kondisi stres (Indawati & Dewi, 2020). Jantung memiliki empat ruang utama, yaitu atrium kanan dan kiri serta ventrikel kanan dan kiri, yang bekerja secara sinkron dalam siklus sistol (kontraksi) dan diastol (relaksasi) untuk memastikan aliran darah yang efisien. Selain fungsi mekanisnya, sistem konduksi listrik jantung seperti SA node dan AV node memainkan peran penting dalam pengaturan irama jantung yang stabil (Hendrawan & Setiyawati, 2021). Gangguan pada salah satu fungsi tersebut dapat

menyebabkan penyakit kardiovaskular seperti gagal jantung atau aritmia, yang secara signifikan memengaruhi kualitas hidup pasien. Oleh karena itu, pemahaman mendalam mengenai fisiologi jantung sangat penting dalam deteksi dini dan penanganan penyakit jantung.

2. Penyakit Jantung

Jantung memiliki fungsi utama untuk mengalirkan darah ke seluruh tubuh. Darah yang kaya akan oksigen disalurkan dari jantung ke berbagai bagian tubuh melalui aorta, sedangkan darah yang kekurangan oksigen dikembalikan dari tubuh ke jantung melalui vena. Berikut merupakan beberapa penyakit jantung:

- a. *Penyakit Jantung Koroner (PJK)* adalah salah satu penyakit tidak menular yang menjadi penyebab utama kematian di seluruh dunia. Menurut laporan *World Health Organization (WHO)* tahun 2016, terdapat 7,4 juta kematian akibat *Penyakit Jantung Koroner (PJK)* dan 6,7 juta kematian yang disebabkan oleh stroke. Sementara itu, hasil Riset Kesehatan Dasar (Riskesdas) tahun 2013 mengungkapkan bahwa PJK memiliki prevalensi

tertinggi di Indonesia untuk penyakit kardiovaskular, dengan jumlah penderita mencapai 2.650.340 orang (0,5%). *Penyakit Jantung Koroner* (PJK) dipengaruhi oleh faktor risiko yang tidak bisa diubah, seperti usia, jenis kelamin, dan faktor genetik. Selain itu, PJK juga dapat dipicu oleh faktor risiko yang dapat dikendalikan, seperti kebiasaan merokok, kadar lemak darah yang abnormal (*dislipidemia*), tekanan darah tinggi (*hipertensi*), kurangnya aktivitas fisik, obesitas, diabetes mellitus, stres, konsumsi alkohol, dan pola makan yang tidak sehat (Naomi et al., 2021).

- b. Gagal jantung kongestif (*Congestive Heart Failure/CHF*) merupakan kumpulan gejala yang kompleks, yang muncul akibat terganggunya fungsi kerja jantung, baik karena masalah struktural maupun fungsional Metra et al., (2019). Gagal jantung kongestif pada awalnya disebabkan oleh gangguan pada otot-otot dinding jantung yang melemah, sehingga jantung tidak mampu memompa darah secara optimal untuk memenuhi kebutuhan tubuh (Lilik & Budiono, 2021). Berdasarkan data dari Kementerian Kesehatan

RI Tahun 2020, Gagal jantung kongestif adalah penyakit dengan angka kematian tertinggi kedua di Indonesia, setelah stroke. Di Indonesia, prevalensi gagal jantung kongestif yang telah terdiagnosis oleh dokter mencapai 1,5% atau sekitar 1.017.290 orang. Sedangkan berdasarkan data dari Provinsi Jawa Tengah, menunjukkan adanya penurunan angka insidensi kumulatif atau proporsi kasus baru gagal jantung kongestif ketika dibandingkan antara tahun 2018 dan 2019. Pada tahun 2018, angka tersebut tercatat sebesar 9,82%, sementara pada tahun 2019 turun menjadi 1,90%.


- c. Pembesaran jantung merupakan kondisi medis yang ditandai dengan pembesaran jantung, sering dikenal sebagai jantung membesar. Kondisi ini umumnya disebabkan oleh *hypertensive heart disease* (HHD), yaitu komplikasi yang timbul akibat tekanan darah tinggi atau hipertensi. Pembesaran jantung adalah faktor prognostik independen yang berhubungan dengan risiko kematian. Kondisi ini berperan sebagai prediktor kematian yang dapat meningkatkan risiko mortalitas melalui berbagai mekanisme, seperti

meningkatnya kebutuhan oksigen akibat pembesaran massa ventrikel, terjadinya aritmia ventrikel yang fatal, serta gangguan fungsi endotel(A. Ogungbe et al., 2022).

3. Jantung Normal dan Pembesaran jantung

Jantung normal adalah organ berotot yang berfungsi memompa darah ke seluruh tubuh melalui pembuluh darah. Ukuran jantung yang normal proporsional dengan tubuh seseorang, dengan Indeks Kardioraksik (*Cardiothoracic Ratio/CTR*) pada gambaran X-ray dada sebesar $\leq 50\%$. Dalam kondisi normal, jantung dapat memompa darah beroksigen ke seluruh tubuh dan darah terdeoksigenasi ke paru-paru dengan efisien. Sebaliknya, pembesaran jantung atau *cardiomegaly* adalah kondisi di mana ukuran jantung lebih besar dari normal, biasanya ditandai dengan $CTR > 50\%$. Pembesaran ini dapat disebabkan oleh berbagai faktor seperti hipertensi, penyakit katup jantung, gagal jantung, atau kardiomiopati. Cardiomegaly sering kali menurunkan kemampuan jantung untuk memompa darah dengan baik, sehingga memicu gejala seperti sesak napas, mudah lelah, pembengkakan pada kaki, dan detak jantung tidak teratur. Untuk mendiagnosis kondisi ini, dapat

dilakukan pemeriksaan seperti X-ray dada, ekokardiografi, atau MRI jantung. Penanganan pembesaran jantung tergantung pada penyebabnya, mulai dari perubahan gaya hidup, pemberian obat-obatan, hingga intervensi medis atau bedah.



Gambar 2.2 (a) Citra Jantung Normal, (b) Citra Pembesaran jantung(Radiologi RSUD Dr. R. Soeprapto Cepu).

Berdasarkan Gambar 2.2(a) terlihat gambaran jantung yang proporsional dengan rongga dada, di mana CTR berada dalam batas normal, yaitu $\leq 50\%$. Ukuran dan posisi jantung tampak sesuai tanpa adanya tanda-tanda pembesaran atau kelainan struktur lainnya. Hal ini menunjukkan bahwa jantung

pada citra kedua berada dalam kondisi normal. Perbandingan ini menegaskan perbedaan mencolok antara kondisi jantung normal dengan pembesaran jantung yang tampak pada hasil radiologi. Sebaliknya dengan Gambar 2.2(b) terlihat adanya pembesaran ukuran jantung dibandingkan dengan rongga dada. Hal ini ditunjukkan oleh Indeks Kardioraksik (*Cardiothoracic Ratio/CTR*) yang melebihi 50%, sehingga mengindikasikan adanya kondisi cardiomegaly. Cardiomegaly ini dapat disebabkan oleh berbagai faktor seperti hipertensi, gagal jantung, atau gangguan katup jantung. Bayangan jantung yang mendominasi area mediastinum pada citra ini menjadi salah satu ciri khas dari cardiomegaly.

Penelitian terbaru yang menunjukkan bahwa meskipun batas konvensional untuk diagnosis pembesaran jantung menggunakan rasio kardioraks (CTR) adalah >50%, nilai CTR yang mendekati ambang ini, seperti >48%, juga dapat menunjukkan peningkatan risiko kardiovaskular. Sebuah studi oleh Zaman et al., (2007) menemukan bahwa pasien dengan CTR antara 0,42 dan 0,49 memiliki risiko kematian yang lebih tinggi dibandingkan dengan mereka yang memiliki CTR <0,42, bahkan setelah

disesuaikan dengan faktor risiko lainnya. Hal ini menunjukkan bahwa risiko meningkat secara linear seiring dengan peningkatan CTR, tanpa adanya ambang batas yang jelas.

Selain itu, penelitian oleh Lin et al., (2022) mengklasifikasikan kondisi jantung berdasarkan nilai CTR, dengan kategori normal ($0,42 < \text{CTR} \leq 0,50$), pembesaran jantung ringan hingga sedang ($0,50 < \text{CTR} \leq 0,60$), dan pembesaran jantung berat ($\text{CTR} > 0,60$). Dalam klasifikasi ini, nilai $\text{CTR} > 48\%$ sudah termasuk dalam kisaran atas dari kategori normal, yang dapat mengindikasikan potensi perkembangan menuju cardiomegaly. Oleh karena itu, nilai $\text{CTR} > 48\%$ meskipun masih dalam batas normal, dapat dianggap sebagai indikasi awal risiko cardiomegaly dan memerlukan pemantauan lebih lanjut serta evaluasi klinis yang komprehensif.

4. Sinar-X


Sinar-X merupakan radiasi elektromagnetik yang memiliki panjang gelombang sekitar 0,01 hingga 10 nanometer, dengan energi antara 100 hingga 100.000 elektronvolt (eV). Sinar ini dapat muncul dalam bentuk spektrum kontinu maupun diskret. Spektrum kontinu dihasilkan dari percepatan atau

perlambatan elektron, sedangkan spektrum diskret berasal dari transisi elektron antar tingkat energi dalam atom(Krane, 1992).

Pemancaran sinar-X diskret terjadi saat elektron dalam kulit bagian dalam atom berpindah untuk mengisi kekosongan yang ditinggalkan oleh elektron lain yang telah terlepas. Elektron dalam kulit terdalam memiliki ikatan energi yang besar, sehingga transisinya menghasilkan foton dengan energi sinar-X. Berbeda dengan elektron di kulit terluar yang transisinya hanya memancarkan cahaya tampak. Agar proses transisi sinar-X dapat terjadi, elektron di kulit dalam harus dikeluarkan terlebih dahulu. Hal ini bisa dilakukan dengan menembakkan partikel berenergi tinggi, seperti elektron yang dipercepat menggunakan tegangan sekitar 10.000 volt. Setelah elektron tersebut terlepas, elektron dari tingkat energi yang lebih tinggi segera turun untuk mengisi kekosongan, sambil memancarkan foton sinar-X yang energinya setara dengan perbedaan antara tingkat energi awal dan akhirnya(Krane, 1992).


Sinar-X dihasilkan melalui suatu proses di dalam tabung sinar-X dapat dilihat pada Gambar 2.3 diagram tabung sinar-X menunjukkan komponen-

komponen utama yang berfungsi menghasilkan sinar-X. Dalam tabung ini, elektron dipercepat oleh tegangan tinggi menuju target yang umumnya terbuat dari bahan logam seperti tungsten. Ketika elektron ini menghantam target, sebagian energi kinetiknya dikonversikan menjadi sinar-X. Tabung ini dilengkapi dengan katoda dan anoda, di mana katoda menghasilkan elektron, sementara anoda bertindak sebagai target untuk menghasilkan sinar-X. Teknologi desain tabung sinar-X telah mengalami kemajuan pesat, memungkinkan voltase dan arus yang lebih tinggi untuk menghasilkan intensitas sinar-X yang lebih besar, meskipun elemen dasar dari tabung ini tetap tidak berubah(Tipler, Paul A.; Llewellyn, 2008).



Gambar 2.3 Diagram tabung sinar-X(Tipler, Paul A.; Llewellyn, 2008).


Secara umum, pembentukan sinar-X dibagi menjadi dua jenis, yaitu sinar-X karakteristik dan sinar-X *bremsstrahlung*:



Gambar 2.4 Radiasi Bremsstrahlung(Dr. Muslimin, 2011).

- a. Bremsstrahlung, adalah radiasi pengereman, proses ini terjadi ketika elektron bermuatan yang bergerak dengan kecepatan tinggi melewati dekat inti atom. Tarikan elektrostatis yang kuat dari inti atom menyebabkan lintasan elektron berbelok tajam. Akibat perubahan arah ini, elektron kehilangan sebagian energinya yang kemudian dipancarkan dalam bentuk radiasi elektromagnetik. Radiasi inilah yang dikenal sebagai sinar-X bremsstrahlung yang dapat dilihat pada Gambar 2.4.

- b. Sinar-X Karakteristik dihasilkan melalui proses perpindahan elektron dalam atom, yaitu ketika elektron dari tingkat energi yang lebih tinggi berpindah ke tingkat energi yang lebih rendah. Perbedaan energi antara orbit-orbit dalam atom target ini cukup besar, sehingga radiasi yang dipancarkan memiliki frekuensi tinggi dan termasuk dalam wilayah sinar-X(Dr. Muslimin, 2011). Fenomena interaksi antara radiasi sinar-X dan materi ini juga berkaitan erat dengan efek fotolistrik, yang menjadi dasar penting dalam memahami proses pelepasan elektron dari permukaan logam akibat penyinaran. Efek fotolistrik terjadi ketika cahaya jatuh pada permukaan logam (katoda) dan menyebabkan elektron terpancar keluar. Proses pelepasan elektron akibat efek fotolistrik ini berperan penting dalam menciptakan kekosongan pada kulit elektron atom, yang kemudian memicu terjadinya transisi elektron antar kulit.



Gambar 2.5 Transisi elektron antar kulit(<https://en.wikipedia.org>).

Transisi electron pada Gambar 2.5 yang menghasilkan garis emisi sinar-X $K\alpha$ terjadi saat sebuah elektron dari orbital kulit L ($n = 2$) berpindah untuk mengisi kekosongan pada kulit K ($n = 1$), yang sebelumnya kehilangan satu elektronnya. Proses ini melepaskan energi dalam bentuk foton sinar-X dengan karakteristik tertentu, yang disebut $K\alpha$. Agar transisi ini bisa terjadi, atom minimal harus memiliki tiga elektron—dua di kulit K (satu yang keluar, satu yang tetap), dan minimal satu di kulit L sebagai pengganti. Karena itu, atom seperti litium atau ion mirip litium adalah yang paling sederhana yang bisa menunjukkan emisi $K\alpha$.

Namun dalam praktik spektroskopi, elemen yang umum digunakan adalah tembaga (Cu), besi (Fe), atau neon (Ne), karena memiliki tingkat energi transisi dalam kisaran sinar-X. Selain $K\alpha$, terdapat pula transisi $K\beta$, yaitu ketika elektron dari kulit M ($n = 3$) mengisi kekosongan di kulit K ($n = 1$). Energi yang dihasilkan lebih tinggi dari $K\alpha$ karena selisih energi antar kulit lebih besar(<https://en.wikipedia.org>).

Prinsip-prinsip dasar ini juga dapat dibuktikan melalui percobaan fotolistrik, yang memungkinkan pengamatan langsung terhadap perilaku elektron saat berinteraksi dengan cahaya. Dalam eksperimen, mengamati bagaimana jumlah dan energi elektron yang terpancar bergantung pada intensitas serta panjang gelombang cahaya. Agar elektron tidak kehilangan energi akibat tumbukan dengan molekul udara, percobaan ini dilakukan dalam ruang hampa. Arus listrik yang muncul akibat gerakan elektron diukur dengan ammeter, sedangkan energi kinetik maksimum elektron ditentukan dengan menaikkan tegangan perlambat (potensial henti) hingga arus menjadi nol (Krane, 1992).

Dari berbagai eksperimen ditemukan bahwa:

1. Jumlah elektron yang dipancarkan bertambah dengan naiknya intensitas cahaya.
2. Namun, energi kinetik maksimum elektron hanya bergantung pada panjang gelombang, bukan intensitas.
3. Hanya cahaya dengan panjang gelombang di bawah nilai tertentu (*cutoff*) yang bisa menyebabkan emisi elektron.
4. Elektron keluar hampir seketika setelah cahaya menyinari logam dalam waktu sekitar 10^{-9} detik.

Teori gelombang klasik gagal menjelaskan fakta ini, karena menurutnya semua panjang gelombang seharusnya mampu melepaskan elektron jika intensitas cukup tinggi, dan prosesnya akan memerlukan waktu lebih lama. Einstein, pada tahun 1905, mengusulkan bahwa cahaya terdiri dari partikel kecil foton yang energinya bergantung pada frekuensi cahaya $E = h\nu$. Jika energi foton melebihi energi minimum yang dibutuhkan untuk melepaskan elektron (fungsi kerja, W), maka kelebihanannya menjadi energi kinetik elektron

$K = h\nu - W$. Penelitian lanjutan oleh Millikan pada 1915 membuktikan teori Einstein secara eksperimen dan memungkinkan penentuan nilai tetapan Planck secara akurat. Ini membuktikan bahwa cahaya memiliki sifat partikel sekaligus gelombang, sesuai dengan teori kuantum(Krane, 1992).

Konsep dualitas partikel-gelombang ini selanjutnya diterapkan dalam memahami proses penyerapan dan atenuasi sinar-X saat melewati suatu material. Intensitas cahaya yang melewati suatu benda akan makin lemah seiring bertambahnya ketebalan benda tersebut. Hal ini terjadi karena cahaya mengalami hamburan dan diserap oleh benda tersebut, seberapa besar cahaya berkurang tergantung pada jenis benda dan energi cahaya yang masuk, peristiwa berkurangnya kekuatan cahaya saat melewati suatu benda ini disebut sebagai pelemahan atau atenuasi. Atenuasi akan menimbulkan perbedaan tingkat kehitaman pada gambar radiografi, yang dikenal sebagai kontras(BUSHBERG et al., 1994) hal ini dijelaskan dalam persamaan (2.1).

$$I = I_0 e^{-\mu x} \quad (2.1)$$

Di mana I_0 adalah intensitas awal sinar-X sebelum mengenai suatu benda. I adalah intensitas sinar-X setelah melewati benda tersebut. Sedangkan μ adalah nilai yang menunjukkan seberapa besar sinar-X dilemahkan oleh material yang dilewatinya (Gabriel, 1996).

Tabel 2.1 Karakteristik Fisik dan Koefisien Atenuasi Linier (50 keV) Berbagai Material

MATERIAL	DENSITY (g/cm³)	ELECTRONS PER MASS (e/g)×10²³	ELECTRON DENSITY (e/cm³)×10²³	μ @50 keV (cm⁻¹)
Hydrogen gas	0.000084	5.97	0.0005	0.000028
Water vapor	0.000598	3.34	0.002	0.000128
Air	0.00129	3.006	0.0038	0.00029
Fat	0.91	3.34	3.04	0.193
Ice	0.917	3.34	3.06	0.196
Water	1	3.34	3.34	0.214
Compact bone	1.85	3.192	5.91	0.573

Tabel 2.1 memperlihatkan hubungan antara kerapatan material, kerapatan elektron, elektron per massa, dan koefisien atenuasi linier (pada 50 keV) untuk beberapa material (BUSHBERG et al., 1994).

5. Aplikasi Sinar-X

Aplikasi Sinar-X adalah teknologi yang memberikan informasi rinci tentang struktur internal suatu material secara non-destruktif, dengan cakupan mulai dari skala meter hingga nanometer. Dalam dunia medis, sinar-X digunakan secara luas untuk tujuan diagnostik dan terapeutik. Teknik radiografi sinar-X memungkinkan visualisasi struktur internal tubuh, seperti tulang, paru-paru, dan organ lainnya, yang membantu dokter dalam mendiagnosis berbagai kondisi medis, termasuk patah tulang, infeksi, dan tumor (Fuadi et al., 2022).

Dapat dilihat pada Gambar 2.7 Proses ini menggunakan sinar-X untuk mengambil serangkaian citra dua dimensi (2D) dari objek dari berbagai sudut. Pengambilan citra ini dikenal sebagai pemindaian CT. Selanjutnya, metode rekonstruksi digunakan untuk mengubah citra 2D tersebut menjadi irisan penampang objek dalam bentuk 2D. Hasil akhirnya berupa representasi digital dalam skala abu-abu, yang sering disebut citra potongan atau hasil rekonstruksi, menggambarkan struktur internal objek secara dua dimensi. Citra potongan ini dapat dianalisis lebih lanjut, dipotong secara virtual dari berbagai arah, atau

bagian-bagian tertentu dapat diberi warna atau dibuat transparan untuk memvisualisasikan morfologi objek dalam bentuk 2D.



Gambar 2.7 Pesawat Sinar-X (Radiologi RSUD Dr. R. Soeprapto Cepu).

X-ray umumnya digunakan sebagai langkah awal dalam proses diagnostik. Pengembangan alat deteksi berbantuan komputer (CAD) untuk analisis X-ray menawarkan banyak keuntungan. Salah satunya adalah membantu ahli radiologi dalam mengambil keputusan yang lebih kuantitatif dan berbasis informasi. Dengan meningkatnya volume data yang harus dianalisis, ahli radiologi menghadapi tantangan untuk memeriksa semua hasil X-ray secara efisien. Oleh karena itu, otomatisasi dan augmentasi menjadi sangat penting untuk mendukung ahli radiologi dalam

mempertahankan kualitas diagnosis (Islam et al., 2017).

Pemahaman mengenai proses dasar pembentukan citra radiografi menjadi penting dalam mendukung pengembangan sistem otomatisasi tersebut. Radiografi dilakukan dengan menempatkan sumber sinar-X di satu sisi tubuh pasien dan detektor sinar-X (biasanya datar) di sisi yang berlawanan. Tabung sinar-X akan memancarkan sinar dalam bentuk pulsa berdurasi singkat (biasanya kurang dari setengah detik). Saat sinar-X melewati tubuh pasien, sebagian besar sinarnya akan berinteraksi dengan jaringan tubuh, dan sebagian lainnya akan menembus tubuh lalu mencapai detektor, di mana citra radiografi terbentuk.

Sinar-X yang memasuki tubuh pasien awalnya terdistribusi secara merata, tetapi seiring perjalanannya melalui jaringan, sinar ini akan berkurang intensitasnya akibat proses hamburan dan penyerapan oleh jaringan tubuh. Inilah yang disebut dengan atenuasi. Setiap jenis jaringan memiliki tingkat atenuasi yang berbeda misalnya, tulang, jaringan lunak, dan rongga udara memiliki karakteristik fisik yang berbeda, sehingga menyerap

sinar-X dalam tingkat yang berbeda pula. Perbedaan tingkat penyerapan ini menghasilkan variasi distribusi sinar-X yang keluar dari tubuh pasien. Citra radiografi yang terbentuk merupakan gambaran dari distribusi sinar-X yang telah dimodifikasi oleh karakteristik masing-masing jaringan tersebut. Detektor yang digunakan untuk menangkap citra ini dapat berupa film fotografi (seperti pada sistem film-layar) atau sistem detektor elektronik (seperti pada radiografi digital).

Selanjutnya, perlu dipahami bahwa kualitas visual dari citra radiografi sangat bergantung pada tingkat kontras yang dihasilkan. Kontras dalam gambar medis muncul sebagai variasi tingkat keabuan pada citra tersebut. Jika suatu gambar memiliki warna abu-abu yang seragam, maka gambar tersebut tidak menunjukkan kontras. Sebaliknya, jika terdapat perbedaan yang jelas antara bagian yang gelap dan terang, maka gambar tersebut memiliki kontras yang tinggi. Beragam teknik pencitraan medis menghasilkan kontras dengan memanfaatkan berbagai jenis energi, yang berinteraksi dengan jaringan tubuh berdasarkan sifat fisik yang berbeda-beda.

Dalam pencitraan sinar-X transmisi seperti radiografi, fluoroskopi, mamografi, dan CT scan, kontras dihasilkan dari perbedaan komposisi jaringan, yang memengaruhi tingkat penyerapan lokal sinar-X. Tingkat penyerapan ini ditentukan oleh kepadatan massa (g/cm^3) dan angka atom efektif dari jaringan. Selain itu, energi foton sinar-X yang digunakan yang dapat diatur oleh operator juga turut memengaruhi tingkat kontras citra. Karena tulang memiliki angka atom efektif yang jauh lebih tinggi dibanding jaringan lunak, akibat kandungan kalsium dan fosfor yang tinggi, maka tulang akan tampak sangat kontras dalam gambar sinar-X. Salah satu contoh paling umum dari penerapan ini adalah radiografi dada, yang mampu memperlihatkan struktur paru-paru dengan kontras tinggi antara jaringan paru dan saluran udaranya, menjadikannya sebagai prosedur radiografi yang paling sering digunakan di seluruh dunia (JERROLD T. BUSHBERG, PhD et al., 1994).

6. *Computer Aided Diagnosis (CAD)*

Computer-Aided Diagnosis (CAD) adalah teknologi yang menggabungkan metode komputer dan kecerdasan buatan dengan pencitraan medis

untuk membantu profesional kesehatan dalam mendiagnosis berbagai penyakit secara akurat dan tepat waktu. Sistem CAD menganalisis data medis, baik berupa gambar maupun non-gambar, menggunakan metode pembelajaran mesin untuk menilai kondisi pasien. Informasi ini kemudian digunakan untuk mendukung proses pengambilan keputusan klinis oleh dokter (Gloria Kang GJ et al., (2018). Dalam praktiknya, CAD berfungsi sebagai "pendapat kedua" bagi radiolog, memberikan informasi tambahan yang dapat meningkatkan akurasi diagnosis. Meskipun keputusan akhir tetap berada di tangan profesional medis, CAD membantu dalam mendeteksi kelainan yang mungkin terlewatkan, terutama dalam kasus yang kompleks atau ketika beban kerja tinggi.

Cara kerja CAD didasarkan pada prinsip-prinsip pengolahan citra dan pengenalan pola, yang meliputi peningkatan kualitas gambar, penyaringan citra, ekstraksi serta pemilihan fitur citra, dan dilanjutkan dengan proses klasifikasi (Yusufiyah, 2015). Proses klasifikasi dilakukan menggunakan bantuan Machine Learning melalui WEKA. WEKA adalah perangkat lunak open-source yang

menggunakan bahasa pemrograman Java API. WEKA dapat digunakan untuk pembelajaran dan pelatihan data dengan mengimpor file dalam format ARFF, CSV, C4.5, dan binary sebagai input. WEKA dapat langsung digunakan tanpa perlu menulis kode karena telah dilengkapi dengan fasilitas analisis data, seperti perangkat untuk pra-pemrosesan data, metode pembelajaran, dan metode evaluasi. Selain itu, WEKA juga memiliki antarmuka grafis dan kemampuan untuk membandingkan berbagai metode pembelajaran(Ermawati, 2020).

7. Dasar Pengolahan Citra Digital

Pengolahan citra digital adalah bidang ilmu yang mempelajari berbagai metode untuk memproses citra, termasuk gambar diam (seperti foto) dan gambar bergerak (seperti dari webcam). Istilah "digital" mengacu pada proses pengolahan citra yang dilakukan secara digital menggunakan komputer(Shpakov & Bogomolov, 1981).

Secara matematis, citra adalah fungsi kontinu dengan intensitas cahaya yang terdistribusi pada bidang dua dimensi, untuk dapat diproses oleh komputer digital, citra tersebut harus diubah menjadi representasi numerik dengan nilai diskrit. Proses

mengubah fungsi kontinu menjadi nilai diskrit ini disebut digitalisasi citra. Citra digital dapat direpresentasikan sebagai matriks dua dimensi $f(x, y)$ yang terdiri dari M kolom dan N baris, di mana titik perpotongan antara kolom dan baris disebut piksel (pixel = picture element), yang merupakan elemen terkecil dari citra (Shpakov & Bogomolov, 1981), Matrix $f(x,y)$ ditunjukkan oleh persamaan (2.2).

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0, M-1) \\ f(1,0) & f(1,1) & \cdots & f(1, M-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(N-1,0) & f(N-1,1) & \cdots & f(N-1, M-1) \end{bmatrix} \quad (2.2)$$

Citra $f(x,y)$ dalam bentuk fungsi matematis dapat dituliskan sebagai berikut: $0 \leq x \leq M-1$ dan $0 \leq y \leq N-1$.

Dimana:

M = jumlah piksel pada baris (row) dalam array citra,


N = jumlah piksel pada kolom (column) dalam array citra,

G = nilai skala keabuan (gray level).

Nilai M , N , dan G biasanya berupa perpangkatan dua.

$$M = 2^m ; N = 2^n ; G = 2^k \quad (2.3)$$

Nilai m , n , dan k merupakan bilangan bulat positif. Interval antara 0 dan G disebut skala keabuan (*grayscale*), dan besarnya G bergantung pada proses digitalisasi. Biasanya, nilai keabuan 0 mewakili intensitas hitam, sedangkan nilai 1 mewakili intensitas putih. Untuk citra 8-bit, nilai G adalah $2^8 = 256$ tingkat keabuan, dapat dilihat pada representasi citra digital Gambar 2.8 (Shpakov & Bogomolov, 1981).



Gambar 2.8 Representasi citra digital dalam 2 dimensi (Systems, 2000).

Objek tertentu dapat terdeteksi melalui pengolahan citra digital ini. Salah satu metode yang digunakan adalah segmentasi warna. Normalisasi RGB merupakan salah satu metode segmentasi warna yang memiliki keunggulan karena mudah diterapkan, prosesnya cepat, dan efektif untuk objek seperti rambu lalu lintas(Aryuanto et al., 2009), serta aplikasi untuk deteksi wajah(Kong & Zhu, 2007). Dalam aplikasi pengolahan citra digital secara umum, jenis citra digital dapat dikelompokkan menjadi tiga kategori, yaitu citra berwarna (*color image*), citra hitam putih (*black and white image*), dan citra biner (*binary image*)(Shpakov & Bogomolov, 1981).


- a. Color Image atau citra RGB (*Red, Green, Blue*) adalah jenis citra di mana setiap piksel memiliki warna spesifik yang terdiri dari tiga komponen utama: merah (*Red*), hijau (*Green*), dan biru (*Blue*). Masing-masing komponen warna memiliki rentang nilai antara 0 hingga 255. Dengan rentang ini, terdapat $255^3 = 16.581.375$ (16 juta) variasi warna berbeda, yang dianggap cukup untuk merepresentasikan gambar apapun. Karena jumlah bit yang dibutuhkan untuk setiap piksel, gambar ini juga dikenal sebagai gambar bit warna.

Citra berwarna terdiri dari tiga matriks yang merepresentasikan nilai merah, hijau, dan biru untuk setiap piksel(Whittaker et al., 1984).

- b. Citra Black and White (*grayscale*) pada Gambar 2.9 adalah citra digital di mana setiap piksel memiliki gradasi warna dari putih hingga hitam. Gradasi ini berarti setiap piksel dapat diwakili oleh 8 bit atau 1 byte. Rentang warna pada citra black and white sangat ideal untuk digunakan dalam pengolahan gambar, seperti pada aplikasi medis, misalnya dalam citra X-ray. Citra black and white pada dasarnya merupakan hasil rata-rata dari citra berwarna (*color image*), sehingga dapat dituliskan pada persamaan (2.4).

$$I_{BW}(x,y) = \frac{I_R(x,y)+I_G(x,y)+I_B(x,y)}{3} \quad (2.4)$$

Di mana $I_R(x,y)$ adalah nilai piksel merah (Red), pada titik (x,y) , $I_G(x,y)$ adalah nilai piksel hijau (Green), pada titik (x,y) , $I_B(x,y)$ adalah nilai piksel biru (Blue), pada titik (x,y) dan $I_{BW}(x,y)$ adalah nilai piksel hitam putih (black and white) pada titik (x,y) (Whittaker et al., 1984).



Gambar 2.9 Citra Black and White(grayscale)(Whittaker et al., 1984).


- c. Binary Image adalah citra di mana setiap piksel hanya memiliki dua pilihan warna, yaitu pada Gambar 2.10 yang mempunyai warna hitam atau putih. Karena hanya ada dua kemungkinan warna untuk setiap piksel, hanya diperlukan 1 bit per piksel (0 untuk hitam dan 1 untuk putih), atau dalam format 8-bit, nilai 0 dan 255. Hal ini menjadikan binary image sangat efisien dalam penggunaan ruang penyimpanan. Citra biner sangat cocok untuk merepresentasikan teks (baik cetakan maupun tulisan tangan), sidik jari, atau gambar arsitektur. Binary image dihasilkan dari pemrosesan citra hitam putih (grayscale) menggunakan fungsi tertentu, seperti berikut:

$$I_{\text{Bin}}(x, y) = \begin{cases} 0 & I_{\text{BW}}(x, y) < T \\ 255 & I_{\text{BW}}(x, y) \geq T \end{cases} \quad (2.5)$$

Sedangkan dalam bentuk floating point

$$I_{\text{Bin}}(x, y) = \begin{cases} 0 & I_{\text{BW}}(x, y) < T \\ 1 & I_{\text{BW}}(x, y) \geq T \end{cases} \quad (2.6)$$

dimana $I_{\text{BW}}(x, y)$ merupakan nilai piksel grayscale pada titik (x, y) , $I_{\text{Bin}}(x, y)$ adalah nilai piksel biner pada titik (x, y) sedangkan T adalah nilai threshold (Whittaker et al., 1984).



Gambar 2.10 Binary Image (Whittaker et al., 1984).

8. Ekstraksi Ciri Tekstur


Tekstur dapat diartikan sebagai pola pengelompokan kesamaan dalam suatu citra. Sifat-sifat subpola lokal ini mencakup penerimaan cahaya, keseragaman, kerapatan, kekasaran, keteraturan, kelinieran, frekuensi, fase, keterarahan, ketidakteraturan, kehalusan, dan sebagainya. Karena komputer tidak memiliki kemampuan visual seperti

manusia, komputer hanya dapat mengenali pola citra digital melalui ciri atau karakteristik teksturnya. Karakteristik ini diperoleh melalui proses ekstraksi ciri menggunakan berbagai metode, seperti *co-occurrence*, *autokorelasi*, *wavelet*, frekuensi tepi, *run length*, dan metode lainnya (Kitaguchi et al., 2005).

Aplikasi tekstur dapat dikelompokkan menjadi dua jenis, yaitu untuk keperluan segmentasi dan klasifikasi tekstur. Dari sudut pandang matematis, tekstur terbagi dalam dua spektrum: stokastik dan reguler. Tekstur stokastik, atau tekstur statistis, memiliki karakteristik yang menyerupai derau, sementara tekstur reguler, atau tekstur struktural, terdiri dari pola-pola yang teratur dan berulang. Metode statistik yang digunakan untuk mendapatkan fitur tekstur meliputi *histogram*, dan *Gray Level Co-occurrence Matrix (GLCM)* (Ermawati, 2020).

Prinsip pembuatan fitur analisis tekstur pada Gambar 2.11 melibatkan pembuatan histogram dan gray-level co-occurrence matrix (GLCM) dari area tertentu (ROI). Dalam pembuatan GLCM, setiap piksel pada ROI dibandingkan satu kali dengan piksel lain dalam jarak dan arah tertentu (0° , 45° , 90° , atau 135°). Untuk setiap pasangan nilai piksel, GLCM ditambah 1

pada baris dan kolom yang sesuai (seperti pada contoh dengan jarak 1 dan arah 90°; satu pasangan 2-1 ditemukan dan 1 ditambahkan pada matriks yang relevan)(Hinzpeter et al., 2017).



Gambar 2.11 Prinsip menghasilkan fitur analisis tekstur(Hinzpeter et al., 2017).

a. Histogram

Histogram citra merupakan grafik yang menggambarkan frekuensi kemunculan nilai-nilai warna atau intensitas piksel pada sebuah citra. Untuk citra berwarna, histogram menunjukkan distribusi nilai warna atau frekuensi intensitas piksel pada setiap komponen RGB yang menyusunnya. Namun, informasi mengenai susunan posisi warna piksel di dalam citra tidak tercakup dalam histogram, sehingga histogram

tidak dapat digunakan untuk memprediksi bentuk objek yang ada di dalam citra(Marlina et al., 2020).

Selain itu, histogram juga dapat memberikan informasi tentang kecerahan dan kontras sebuah citra. Puncak histogram menunjukkan intensitas piksel yang paling sering muncul atau dominan dalam citra tersebut. Proses analisis histogram meliputi beberapa pola, yaitu:

- a. Citra gelap: histogram cenderung terkumpul di sisi kiri.
- b. Citra terang: histogram cenderung terkumpul di sisi kanan.
- c. Citra dengan kontras rendah: histogram terkonsentrasi di satu area.
- d. Citra dengan kontras tinggi: histogram tersebar merata di seluruh area(Marlina et al., 2020).

Penelitian yang dilakukan oleh Zaheeruddin et al., (2012), menjelaskan bahwa salah satu metode paling sederhana untuk mendeskripsikan tekstur dengan menggunakan pendekatan statistik yang berkaitan dengan histogram intensitas gambar. Beberapa parameter statistik yang dimanfaatkan meliputi mean, variance, skewness, entropy,

standar deviasi dan kurtosis (Agussationo et al., 2018):

- 1) Mean merupakan nilai rata-rata dari tingkat kecerahan pada suatu objek dalam citra.

$$m = \sum_{i=0}^L i \cdot p(i) \quad (2.7)$$

- 2) Varian menunjukkan variasi pada elemen-elemen dalam f_n merepresentasikan intensitas abu-abu, sedangkan $p(f_n)$ merupakan nilai histogram.

$$\sigma^2 = \sum_n (f_n - \mu)^2 p(f_n) \quad (2.8)$$

- 3) Skewness menunjukkan tingkat kemiringan relatif atau asimetri dari kurva histogram.

$$\alpha_3 = \frac{1}{\sigma^3} \sum_n (f_n - \mu)^3 p(f_n) \quad (2.9)$$

- 4) Entropi adalah ukuran yang menunjukkan tingkat kompleksitas pada sebuah gambar.

$$H = -\sum_{i=0}^{L-1} p(i) \log_2(p(i)) \quad (2.10)$$

- 5) Standar deviasi menunjukkan akar kuadrat dari variasi elemen gambar.

$$\sigma = \sqrt{\sum_n (f_n - \mu)^2 p(f_n)} \quad (2.11)$$

- 6) Kurtosis adalah ukuran yang menggambarkan ketajaman kurva histogram.

$$\alpha_4 = \frac{1}{\alpha^4} \sum_n (F_n - \pi)^4 p(f_n) \quad (2.12)$$

b. Teknik Gray Level Co-occurrence Matrix (GLCM)

Matriks Kemunculan Skala Abu-abu (GLCM) digunakan untuk menganalisis tekstur atau mengekstraksi fitur. GLCM adalah representasi matriks yang menggambarkan seberapa sering pasangan dua piksel dengan tingkat keabuan tertentu muncul dalam jarak dan arah yang ditentukan pada sebuah gambar. GLCM menghitung nilai homogeneity, contrast, entropy, correlation (Zhou et al., 2017).

Setelah memperoleh matriks co-occurrence pada modul, penelitian ini menggunakan fitur Gray Level Co-occurrence Matrix (GLCM) dengan menghitung ciri statistik orde kedua, yaitu:

- 1) Homogeneity digunakan untuk menganalisis distribusi intensitas piksel dalam sebuah citra.

$$\sum_{i,j=0}^{N-1} i \frac{P_{i,j}}{1 + (i - j)^2} \quad (2.13)$$

- 2) Contrast mengukur sejauh mana intensitas piksel berbeda dalam matriks *ko-occurrence*.

$$\sum_{i,j=0}^{N-1} i P_{i,j} (i - j)^2 \quad (2.14)$$

- 3) Energy mengukur tingkat kekacauan atau ketidakpastian dalam distribusi intensitas piksel pada citra.

$$Energy = \sum_i \sum_j p^2(i, j) \quad (2.15)$$

- 4) Correlation merupakan ukuran sejauh mana hubungan linier antara nilai keabuan piksel-piksel dalam sebuah citra.

$$IDM = \frac{1}{\sigma_x \sigma_y} \sum_i = 1 \sum_j = 1(1 - \mu_x)(1 - \mu_y)p(i, j)$$

(2.16)

9. *Random Forest*

Metode *Random Forest* adalah metode ensemble pembelajaran mesin yang digunakan untuk meningkatkan akurasi metode klasifikasi dengan mengombinasikan beberapa pohon keputusan. *Random Forest* merupakan pengembangan dari metode decision tree yang memanfaatkan banyak pohon keputusan, di mana masing-masing pohon dilatih menggunakan sampel individu, dan setiap set fitur dibagi menjadi pohon yang dipilih dari subset fitur yang dipilih secara acak.

Metode Random Forest adalah teknik seleksi fitur yang menetapkan skor pada fitur input berdasarkan seberapa berguna dan pentingnya fitur tersebut untuk memprediksi fitur target pada dataset. Metode ini merupakan teknik nonparametrik yang membangun pohon keputusan dari subset fitur acak yang digunakan untuk klasifikasi dan regresi. Dua metode seleksi fitur yang paling umum digunakan dalam metode Random Forest adalah impurity importance dan permutation importance. Impurity

importance, yang juga dikenal sebagai penurunan rata-rata impuritas, sering disebut sebagai metode Gini Index. Metode Gini Index memberikan skor pentingnya fitur secara multivariat dengan biaya yang relatif murah, dan teknik ini telah berhasil diterapkan pada dataset berdimensi tinggi, seperti data microarray(Algehyne et al., 2022).

Metode Gini Index didasarkan pada teori Gini. Gagasan dasarnya adalah, misalkan S adalah kumpulan sampel s , dan sampel ini memiliki k kelas $(C_i, i = 1, \dots, k)$. Oleh karena itu, S dapat dibagi menjadi k subset berdasarkan perbedaan antar kelas. Misalkan S_i adalah kumpulan sampel yang termasuk dalam kelas C_i dan s_i adalah jumlah sampel dalam S_i . Maka, Gini Index dari kumpulan S dapat dihitung menggunakan persamaan berikut:

$$Gini(S) = 1 - \sum_{i=1}^m P_i^2 \quad (2.21)$$

Di mana P_i adalah probabilitas yang diperkirakan menggunakan $\frac{s_i}{s}$ untuk sampel yang termasuk dalam C_i . Nilai minimum $Gini(S)$ adalah 0,

menunjukkan bahwa semua anggota dalam set berasal dari kelas yang sama, sehingga informasi yang paling berguna dapat diperoleh. Sebaliknya, nilai maksimum Gini(S) menunjukkan informasi yang paling sedikit dapat diperoleh (Algehyne et al., 2022).

Metode Gini Index baru untuk seleksi fitur teks, berdasarkan teori Gini, telah diusulkan oleh Shang et al., (2007) dengan persamaan:

$$Gini(W) = P(W)(1 - \sum_{i=1}^m P(C_i | W)^2) + P(\bar{W})(1 - \sum_{i=1}^m P(C_i | \bar{W})^2) \quad (2.22)$$

10. Python

Python adalah bahasa pemrograman interpretatif yang serbaguna, dirancang dengan penekanan pada keterbacaan kode. Bahasa ini dikenal karena mampu menggabungkan fungsionalitas yang kuat dengan sintaksis yang sederhana dan jelas. Python juga dilengkapi dengan pustaka standar yang luas dan lengkap, serta didukung oleh komunitas yang besar (Syahrudin & Kurniawan, 2018).

Python mendukung berbagai paradigma pemrograman, termasuk pemrograman berorientasi objek, imperatif, dan fungsional, meskipun tidak terbatas pada itu. Salah satu fitur utama Python adalah kemampuannya sebagai bahasa pemrograman dinamis yang dilengkapi dengan manajemen memori otomatis. Meskipun sering digunakan sebagai bahasa scripting, Python memiliki penggunaan yang lebih luas dan dapat diterapkan dalam berbagai konteks yang biasanya tidak dilakukan dengan bahasa script. Python cocok untuk pengembangan perangkat lunak di berbagai platform sistem operasi (Syahrudin & Kurniawan, 2018).

B. Kajian Pustaka

1. Penelitian oleh Jawahar et al., (2022) mengembangkan teknik klasifikasi citra X-ray COVID-19 menggunakan fitur Histogram of Oriented Gradients (HOG) yang kemudian diklasifikasikan dengan Random Forest. Proses penelitian meliputi ekstraksi fitur HOG dari citra X-ray, diikuti dengan pelatihan dan pengujian menggunakan metode Random Forest. Hasil penelitian menunjukkan akurasi klasifikasi hingga 99,73%, menunjukkan efektivitas kombinasi

kedua metode tersebut dalam diagnosis COVID-19 berbasis citra X-ray.

2. Penelitian oleh Ariansyah et al., (2024) mengkaji klasifikasi pneumonia pada citra X-ray paru-paru menggunakan metode Naïve Bayes. Tahapan penelitian meliputi ekstraksi fitur menggunakan metode Local Binary Pattern (LBP) dan Gray Level Co-occurrence Matrix (GLCM), kemudian dilanjutkan dengan klasifikasi menggunakan Naïve Bayes. Hasil penelitian menunjukkan akurasi klasifikasi mencapai 93% pada dataset yang diuji, menunjukkan bahwa kombinasi metode ekstraksi fitur LBP-GLCM dengan metode Naïve Bayes efektif dalam mendeteksi pneumonia dari citra X-ray.
3. Penelitian oleh Breve, (2022) melakukan perbandingan terhadap 21 arsitektur CNN yang berbeda untuk mendeteksi COVID-19 pada citra X-ray dada. Dalam penelitian ini, digunakan dataset COVIDx8B yang terdiri dari 16.352 citra X-ray dari pasien di lebih dari 51 negara. Hasil penelitian menunjukkan bahwa arsitektur DenseNet169 mencapai akurasi tertinggi sebesar 98,15% dan skor F1 sebesar 98,12%. Lebih lanjut, dengan

menggunakan ensemble dari lima instance DenseNet169, akurasi meningkat menjadi 99,25% dan skor F1 menjadi 99,24%, menunjukkan bahwa pendekatan ensemble dapat meningkatkan performa deteksi COVID-19 pada citra X-ray.

4. Dalam penelitian oleh Gour & Jain, (2020) dikembangkan model Stacked Convolutional Neural Network untuk diagnosis COVID-19 dari citra X-ray dada. Model ini menggabungkan beberapa sub-model yang berasal dari arsitektur VGG19 dan membentuk jaringan CNN berlapis 30 (disebut CovNet30). Model ini dilatih menggunakan dataset COVID19CXr yang mencakup 2.764 citra X-ray dari 1.768 pasien. Hasil penelitian menunjukkan bahwa model ini mencapai akurasi sebesar 92,74%, sensitivitas 93,33%, nilai prediksi positif (PPV) 92,13%, dan skor F1 sebesar 0,93 dalam mengklasifikasikan citra X-ray menjadi tiga kelas: COVID-19, Normal, dan Pneumonia. Penelitian ini menunjukkan potensi penggunaan arsitektur VGG19 dalam pengembangan sistem diagnosis otomatis untuk COVID-19 berbasis citra X-ray.

5. Pada penelitian yang dilakukan oleh Panwar et al., (2020) tentang deteksi COVID-19 dari citra X-ray dan CT scan menggunakan pendekatan transfer learning berbasis VGG19 dan visualisasi Grad-CAM, dilakukan tahapan ekstraksi fitur dari citra medis menggunakan VGG19 yang sudah dilatih sebelumnya, kemudian dilakukan fine-tuning untuk menyesuaikan dengan dataset COVID-19. Selanjutnya, digunakan metode Grad-CAM untuk menyoroti area penting yang mempengaruhi klasifikasi citra. Hasil penelitian menunjukkan bahwa model yang diusulkan mampu mencapai akurasi sebesar 95,5% dalam mendeteksi COVID-19 dari citra X-ray dan CT scan, serta menghasilkan interpretasi visual yang dapat membantu ahli radiologi dalam memahami keputusan model.

BAB III

METODE PENELITIAN

A. Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada bulan Mei 2025, dengan proses pengambilan data melalui website Kaggle.

B. Alat Penelitian

Alat yang digunakan dalam penelitian ini antara lain:

1. Laptop dengan spesifikasi *processor* Intel(R) Core(TM) i3-4005U CPU @ 1.70GHz 1.70 GHz, RAM 4,00 GB, Disk: 512 GB dengan sistem operasi Windows 10 Pro.
2. *Software Python 3*
3. *Machine Learning WEKA* versi 3.8.4
4. Microsoft word untuk membuat laporan penelitian.

C. Bahan Penelitian


Dalam penelitian ini, bahan yang digunakan adalah gambar X-ray jantung dua dimensi yang dihasilkan dari mesin X-ray berdasarkan ciri tekstur.

Gambar tersebut diambil dari hasil pemeriksaan medis yang telah dilakukan. Data yang digunakan adalah gambar *grayscale* dan disimpan dalam format jpeg. Jumlah keseluruhan data yang diambil ada 100 dengan 50 citra X-ray pembesaran jantung dan 50 citra X-ray jantung normal.

D. Pengolahan Data

Penelitian ini menggunakan citra X-ray jantung yang diperoleh dari database terpercaya, mencakup dua kategori utama, yaitu citra dengan kondisi pembesaran jantung (*cardiomegaly*) dan citra jantung normal. Proses ekstraksi citra dilakukan dengan menggunakan bahasa pemrograman Python yang dijalankan di platform Google Colab, memanfaatkan berbagai pustaka pengolahan citra digital untuk mempersiapkan data sebelum tahap analisis lebih lanjut. Setelah proses ekstraksi, klasifikasi citra dilakukan dengan menggunakan metode pembelajaran mesin berbasis WEKA, sebuah perangkat lunak yang banyak digunakan untuk keperluan data mining dan machine learning. Secara garis besar, tahapan penelitian ini dapat dilihat pada Gambar 3.1, yang terdiri atas tiga tahap utama: pra-pemrosesan citra untuk meningkatkan kualitas

gambar dan mengurangi noise, ekstraksi fitur tekstur untuk mengambil informasi penting dari citra menggunakan metode statistik, serta tahap klasifikasi menggunakan metode Random Forest. Dengan pendekatan ini, penelitian bertujuan mengidentifikasi adanya indikasi pembesaran jantung secara otomatis dan akurat berdasarkan karakteristik tekstur pada citra X-ray. Proses pengolahan data meliputi tahapan-tahapan yang dilakukan sebagai berikut:



Gambar 3.1 Flowchard Pengolahan Data.

1. Preprocessing

Dalam penelitian ini, preprocessing dimulai dengan pengumpulan citra X-ray dada dari rumah sakit, yang mencakup pengambilan gambar pasien dalam kondisi tertentu, seperti kelainan jantung. Citra yang diperoleh kemudian diolah dengan teknik cropping untuk memfokuskan analisis pada area jantung yang relevan, sehingga menghilangkan bagian citra yang tidak diperlukan dan mengurangi noise. Langkah ini membantu meningkatkan akurasi ekstraksi fitur dengan memastikan bahwa hanya area yang mengandung informasi penting yang dianalisis.

2. Ekstraksi Ciri Tekstur

Ekstraksi Fitur Tekstur Proses ekstraksi ini menghasilkan data penting yang dapat digunakan untuk memperoleh informasi yang berharga. Informasi tersebut pada akhirnya dapat memberikan deskripsi dan interpretasi yang mendalam mengenai suatu objek (Purwaningsih et al., 2015). Ekstraksi fitur tekstur dalam penelitian

ini mencakup Histogram dan GLCM (Gray Level Co-Occurrence Matrix)(Rizal et al., 2019).

3. Histogram

Histogram gambar adalah grafik yang menunjukkan frekuensi kemunculan nilai intensitas piksel dalam gambar dan menggambarkan sebaran warna atau kecerahan. Histogram gambar berwarna mencakup distribusi intensitas untuk setiap komponen RGB (merah, hijau, dan biru), tetapi tidak menunjukkan posisi piksel, sehingga tidak dapat digunakan untuk memprediksi bentuk atau struktur(Marlina et al., 2020).

4. *Gray Level Co-occurrence Matrix (GLCM)*

Metode statistik yang digunakan untuk menganalisis tekstur dalam citra adalah *Gray Level Co-occurrence Matrix* (GLCM), yang berfokus pada hubungan spasial antara pasangan piksel dengan intensitas abu-abu yang berbeda. GLCM mempelajari distribusi frekuensi pasangan nilai intensitas tersebut melalui berbagai transformasi geometris untuk mendapatkan informasi tentang

pola tekstur. Selama proses ini, empat parameter tekstur utama dihitung: *energi*, *entropi*, *kontras*, dan *homogenitas*. Parameter ini kemudian digambarkan dalam empat representasi citra yang berbeda. Setelah parameter ini ditentukan, teknik segmentasi berbasis derivatif digunakan, yang menggunakan perhitungan jarak Euclidian untuk menemukan dan memisahkan bagian-bagian gambar yang menunjukkan perbedaan fitur tekstur. Tujuan dari teknik ini adalah untuk menemukan area yang memiliki atribut tekstur yang berbeda, yang akan memungkinkan analisis lebih mendalam terhadap struktur gambar(Aouat et al., 2021).

5. Klasifikasi Citra

Klasifikasi merupakan metode yang digunakan untuk menentukan teknik pengelompokan data berdasarkan atribut atau target tertentu, sehingga seluruh data dapat dikelompokkan ke dalam kelas atau kategori yang sesuai. Teknik ini memungkinkan identifikasi pola dan perilaku yang terdapat dalam data, sehingga dapat berfungsi sebagai alat untuk membedakan

berbagai jenis data. Pada klasifikasi menggunakan metode random forest, proses ini dilakukan dengan membangun sejumlah pohon keputusan (tree) yang dilatih menggunakan sampel data yang tersedia. Dalam menentukan hasil klasifikasi, random forest menggabungkan keputusan dari semua pohon dengan cara melakukan voting mayoritas, di mana kelas yang mendapatkan suara terbanyak dari seluruh pohon akan dipilih sebagai hasil akhir klasifikasi (Rosyani et al., 2021).

Studi ini dimulai dengan prosedur biopsi dan pengumpulan data. Kemudian, untuk meningkatkan akurasi klasifikasi, digunakan metode Random Forest, sebuah metode pembelajaran mesin kelompok. Random Forest adalah evolusi dari metode pohon keputusan di mana beberapa pohon dibangun dan masing-masing dilatih pada sampel data yang berbeda. Setiap pohon dibentuk menggunakan subset fitur keputusan yang dipilih secara acak. Beberapa keunggulan metode ini termasuk peningkatan akurasi meskipun ada data yang hilang, ketahanan terhadap outlier, dan efisiensi dalam penyimpanan data. Selain itu, Random Forest

memiliki mekanisme pemilihan fitur, yang memungkinkan penggunaan fitur terbaik untuk meningkatkan performa model klasifikasi, dan juga dapat menangani secara efektif dataset yang besar dan parameter yang kompleks(Givari et al., 2022).

6. Analisis Data

Indeks pengukuran dapat didefinisikan sebagai informasi mengenai sejumlah nilai yang menggambarkan tingkat kegagalan atau keberhasilan dalam suatu proses(Ermawati 2020). Perhitungan confusion matrix dapat digunakan sebagai indeks untuk menilai kualitas suatu metode klasifikasi. Confusion matrix adalah matriks yang menunjukkan perbandingan jumlah antara data uji yang diklasifikasikan dengan benar dan data uji yang diklasifikasikan secara salah(Nuryani Siska 2021).

Akurasi nilai diagnostik dalam klasifikasi dapat diilustrasikan melalui nilai indeks evaluasi yang diperoleh dari hasil klasifikasi data menggunakan metode machine learning WEKA. Dalam analisis penelitian ini, akurasi, sensitivitas, dan spesifisitas akan dijelaskan dan diukur

dengan cara sebagai berikut(Saifullah & Suryotomo, 2021):

a. Accuracy

Rasio ini menggambarkan perbandingan antara jumlah prediksi yang benar secara keseluruhan dengan total data yang ada.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.23)$$

b. Precision

Jumlah prediksi positif yang benar dibagi dengan total prediksi positif. Ini menunjukkan berapa banyak dari kelas yang diprediksi sebagai positif yang sebenarnya adalah positif. Ukuran ini mencerminkan seberapa akurat model dalam mendeteksi penyakit.

$$Presisi = \frac{TP}{TP+FP} \quad (3.24)$$

c. Recall

Jumlah prediksi positif yang benar dibagi dengan total kejadian positif yang

sebenarnya. Ini menunjukkan berapa banyak kejadian positif yang sebenarnya berhasil diprediksi sebagai positif. Ukuran ini menilai seberapa baik model mengidentifikasi semua kasus penyakit yang sebenarnya.

$$Recall = \frac{TP}{TP+FN} \quad (3.25)$$

Dalam penelitian ini, Positif Benar (TP) menunjukkan kasus yang benar sebagai jantung yang terpengaruh oleh makanan pedas, sementara Positif Benar (FP) menunjukkan kasus yang salah sebagai jantung yang terpengaruh. Negatif Benar (TN) menunjukkan kasus yang benar sebagai jantung normal, dan Negatif Benar (FN) menunjukkan kasus yang salah sebagai jantung normal(Windyasari et al., 2024).

Dalam evaluasi model klasifikasi, confusion matrix digunakan untuk merangkum kinerja model dengan membandingkan prediksi terhadap label sebenarnya. Empat komponen utama dalam confusion matrix adalah:

- 1) *True Positive* (TP): Kasus di mana citra jantung positif (cardiomegaly) menurut diagnosis dokter, dan model juga memprediksi positif.
- 2) *False Positive* (FP): Kasus di mana citra jantung sebenarnya negatif (normal) menurut dokter, tetapi model salah memprediksi sebagai positif (Cardiomegaly).
- 3) *True Negative* (TN): Kasus di mana citra jantung negatif (Normal) menurut dokter, dan model juga memprediksi negatif.
- 4) *False Negative* (FN): Kasus di mana citra jantung sebenarnya positif (Cardiomegaly) menurut dokter, tetapi model salah memprediksi sebagai negatif (Normal).

BAB IV

HASIL DAN PEMBAHASAN

Berdasarkan metode penelitian yang telah diuraikan pada bab tiga, bab ini menyajikan hasil dari proses klasifikasi citra X-ray jantung yang dilakukan melalui ekstraksi ciri tekstur dengan menggunakan metode *Random Forest*. Proses pengolahan data tersebut akan dijabarkan secara lebih detail melalui beberapa tahapan penelitian berikut ini:

A. Pre-processing

Data yang digunakan dalam penelitian ini diperoleh dari situs web (www.kaggle.com/datasets), khususnya dari dataset NIH CLAHE Enhanced Chest X-rays. Kaggle merupakan platform yang menyediakan berbagai kumpulan data citra medis, termasuk citra X-ray dada. Dalam penelitian ini, dipilih citra X-ray jantung yang diklasifikasikan ke dalam dua kategori, yaitu kondisi jantung normal dan cardiomegaly. Untuk menjamin kualitas data yang digunakan dalam proses ekstraksi ciri tekstur, dilakukan tahap seleksi guna memastikan bahwa setiap citra benar-benar merepresentasikan kondisi yang dimaksud dan memiliki kualitas visual yang memadai. Dari hasil seleksi tersebut, diperoleh 100 citra X-ray,


yang terdiri dari 50 citra jantung normal dan 50 citra jantung dengan kondisi cardiomegaly.

Beberapa citra dalam dataset ini memiliki penanda lateral (lateral marker), yaitu penanda yang umumnya digunakan oleh radiografer untuk menunjukkan sisi tubuh pasien (kanan atau kiri) pada saat pengambilan gambar. Keberadaan penanda ini merupakan bagian dari protokol standar dalam pencitraan medis untuk mencegah kesalahan diagnosis atau tindakan pada sisi tubuh yang salah. Namun, dalam konteks penelitian ini, keberadaan penanda tersebut dianggap sebagai noise visual yang dapat mengganggu proses analisis citra. Oleh karena itu, dilakukan beberapa proses diantaranya yaitu Cropping, Resize, Rescale ke rentang 0-1 (float32), Clahe, Gaussian Blur, Rescale kembali ke 0-255.

1. Cropping

Proses cropping dilakukan untuk memperoleh citra yang lebih fokus dan detail dengan cara menghilangkan area-area yang dianggap kurang relevan atau mengganggu. Dengan demikian, citra yang dihasilkan hanya menampilkan bagian dada dan paru-paru. Berikut ditampilkan citra sebelum dan

setelah dilakukan cropping, dimana citra awal masih berukuran asli.




Gambar 4.1 **a)** Citra X-ray asli **b)** Citra X-ray setelah dilakukan cropping.

Seperti yang terlihat pada Gambar 4.1, setelah dilakukan proses cropping atau pemotongan pada area tertentu, citra menjadi lebih jelas dan gangguan visual (noise) berhasil dikurangi

2. Resize

Resize dilakukan untuk menyesuaikan ukuran citra menjadi 500x500 piksel. Jumlah piksel yang lebih besar pada sebuah citra akan memerlukan waktu pemrosesan yang lebih lama. Gambar 4.2 merupakan citra setelah melalui proses resize.



Gambar 4.2 Citra setelah di-Resize 500x500.

Ukuran 500×500 piksel dipilih karena memberikan keseimbangan antara detail citra yang cukup untuk ekstraksi tekstur dan efisiensi komputasi. Ukuran ini tidak terlalu kecil hingga kehilangan informasi penting, namun juga tidak terlalu besar sehingga menghindari beban komputasi dan potensi noise berlebih. Resolusi ini umum digunakan dalam analisis citra medis karena dinilai optimal untuk mempertahankan pola tekstur yang relevan tanpa mengorbankan kecepatan proses (HARALICK et al., 1973).

3. Rescale kerentang 0-1 (float32)

Rescale ke rentang 0–1 (dari sebelumnya 0–255), pada Gambar 4.3 mengubah nilai piksel citra menjadi bertipe float32 dalam skala kecil, yang

penting untuk menstabilkan perhitungan numerik dalam proses ekstraksi fitur maupun pelatihan model machine learning atau deep learning.



Gambar 4.3 Citra Setelah di-Rescale ke rentang 0-1.

4. Clahe



Gambar 4.4 Citra Setelah dilakukan CLAHE.

CLAHE (Contrast Limited Adaptive Histogram Equalization) dan Histogram Equalization merupakan dua metode yang digunakan untuk meningkatkan

kontras pada citra digital, khususnya pada citra grayscale seperti citra X-ray yang dapat dilihat pada gambar 4.4.

5. Gaussian Blur

Gaussian Blur pada Gambar 4.5 adalah metode smoothing (perataan) citra digital dengan menggunakan filter Gaussian — yaitu filter berbasis distribusi normal (Gaussian function). Teknik ini mengaburkan (blur) gambar dengan cara mengganti nilai setiap piksel dengan rata-rata tertimbang dari piksel-piksel di sekitarnya, di mana piksel yang lebih dekat diberi bobot lebih besar.



Gambar 4.5 Citra Setelah dilakukan Gaussian Blur.

6. Rescale kembali ke 0-255

Pada Gambar 4.6 mengubah gambar hasil preprocessing (yang nilainya dalam rentang 0–1 atau

float) kembali menjadi format uint8 (0-255), agar bisa disimpan sebagai file gambar standar seperti JPEG atau PNG.



Gambar 4.6 Citra Setelah kembali ke rentang 0-255.

B. Ekstraksi Ciri Tekstur

Setelah citra X-ray mengalami pre-processing, tahap berikutnya adalah ekstraksi ciri tekstur yang dilakukan dengan bantuan bahasa pemrograman Python. Proses ini menghasilkan nilai-nilai numerik yang merepresentasikan ciri tekstur dari citra, yang kemudian disimpan secara otomatis dalam format CSV ke Google Drive. Selanjutnya, data tersebut diunduh dan dibuka menggunakan excel untuk mempermudah pengelolaan dan pengecekan sebelum diproses lebih lanjut. Setelah dilakukan penyesuaian, data diformat kembali ke dalam bentuk CSV secara online.

Dalam penelitian ini, jumlah data ciri tekstur yang digunakan sebanyak 100, yang diperoleh dari dua metode, yaitu histogram dan Gray Level Co-occurrence Matrix (GLCM). Daftar lengkap hasil ekstraksi ciri tekstur yang digunakan dapat dilihat pada bagian lampiran.

C. Klasifikasi

Tahap klasifikasi merupakan tahap akhir dalam pelaksanaan penelitian ini. Pada tahap ini, citra X-ray dikategorikan berdasarkan ciri tekstur yang sebelumnya telah diekstraksi. Salah satu indikator visual yang membedakan adalah ukuran jantung pada citra X-ray yang menunjukkan kondisi cardiomegaly umumnya memiliki bayangan jantung yang tampak lebih besar dibandingkan dengan citra jantung normal. Penjelasan lebih mendalam mengenai perbedaan ini dijelaskan pada bagian pembahasan.

Proses klasifikasi dilakukan menggunakan perangkat lunak Weka dengan metode Random Forest. Data yang digunakan berasal dari hasil ekstraksi ciri tekstur yang terdiri atas 100 fitur. Data ini digunakan baik sebagai data pelatihan (training set) maupun sebagai data pengujian (testing set) melalui skema percentage split dengan 10%, 20%, 30%, 40%, 50%,

60%, dan 70%. Dari proses klasifikasi ini akan diperoleh nilai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN), yang selanjutnya digunakan untuk menghitung nilai evaluasi seperti akurasi, presisi, dan recall.

1. Hasil klasifikasi metode Random Forest dengan data latih melalui perangkat lunak Weka.

Weka Explorer

Preprocess Classify Cluster Associate Select attributes Visualize

Classifier: Choose RandomForest -P 100 -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1

Test options:

- ☒ Use training set
- ☐ Supplied test set
- ☐ Cross-validation
- ☐ Percentage split

Result list (right-click for options):

13:41:36 - trees:RandomForest

Classifier output:

```
weka.classifiers.trees.RandomTree -K 0 -M 1.0 -V 0.001 -S 1 -do-not-check-capabilities
Time taken to build model: 0.03 seconds
=== Evaluation on training set ===
Time taken to test model on training data: 0.01 seconds
=== Summary ===
Correctly Classified Instances      100      100      %
Incorrectly Classified Instances    0        0        %
Kappa statistic                    1
Mean absolute error                0.0376
Root mean squared error            0.0719
Relative absolute error            7.52 %
Root relative squared error        14.3778 %
Total Number of Instances         100

=== Detailed Accuracy By Class ===
      TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
      1.000    0.000    1.000     1.000    1.000     1.000    1.000    1.000    Normal
      1.000    0.000    1.000     1.000    1.000     1.000    1.000    1.000    Cardiomegaly
Weighted Avg.    1.000    0.000    1.000     1.000    1.000     1.000    1.000    1.000


=== Confusion Matrix ===
  a b  <-- classified as
50 0 | a = Normal
0 50 | b = Cardiomegaly
```

Gambar 4.7 Klasifikasi metode Random Forest menggunakan data training.

Gambar 4.7 menampilkan hasil klasifikasi menggunakan metode *Random Forest* pada perangkat lunak Weka dengan opsi *use training set*. Hasil yang

ditunjukkan adalah sebanyak 100 prediksi benar (100% akurasi) dan tidak terdapat prediksi yang salah (0% kesalahan), dengan waktu pemrosesan selama 0,01 detik. Pada pengujian ini, data pelatihan digunakan secara langsung sebagai data uji.

2. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 10% percentage split.




Gambar 4.8 Klasifikasi metode Random Forest 10% percentage split.

Gambar 4.8 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat

lunak Weka dengan pengujian menggunakan testingset melalui 10% percentage split. Hasil klasifikasi menunjukkan sebanyak 72 data berhasil diprediksi dengan benar (akurasi 80%) dan 18 data diprediksi salah (kesalahan 20%), dengan waktu pemrosesan sebesar 0 detik. Pada pengujian ini data pelatihan digunakan untuk membangun model, sedangkan data pengujian digunakan untuk mengevaluasi performa model.

3. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 20% percentage split.


Gambar 4.9 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat lunak Weka dengan pengujian menggunakan testingset melalui 20% percentage split. Hasil klasifikasi menunjukkan sebanyak 71 data berhasil diprediksi dengan benar (akurasi 88.75%) dan 9 data diprediksi salah (kesalahan 11.25%), dengan waktu pemrosesan sebesar 0 detik. Pada pengujian ini data pelatihan digunakan untuk membangun model, sedangkan data pengujian digunakan untuk mengevaluasi performa model.



Gambar 4.9 Klasifikasi metode Random Forest 20% percentage split.

4. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 30% percentage split.


Gambar 4.10 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat lunak Weka dengan pengujian menggunakan testingset melalui 30% percentage split. Hasil klasifikasi menunjukkan sebanyak 63 data berhasil diprediksi dengan benar (akurasi 90%) dan 7 data diprediksi salah (kesalahan 10%), dengan waktu pemrosesan sebesar 0 detik.



Gambar 4.10 Klasifikasi metode Random Forest
30% percentage split.

5. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 40% percentage split.


Gambar 4.11 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat lunak Weka dengan pengujian menggunakan testingset melalui 40% percentage split. Hasil klasifikasi menunjukkan sebanyak 54 data berhasil diprediksi dengan benar (akurasi 90%) dan 6 data diprediksi salah (kesalahan 10%), dengan waktu pemrosesan sebesar 0 detik.



Gambar 4.11 Klasifikasi metode Random Forest
40% percentage split.

6. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 50% percentage split.


Gambar 4.12 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat lunak Weka dengan pengujian menggunakan testingset melalui 50% percentage split. Hasil klasifikasi menunjukkan sebanyak 46 data berhasil diprediksi dengan benar (akurasi 92%) dan 4 data diprediksi salah (kesalahan 8%), dengan waktu pemrosesan sebesar 0 detik.



Gambar 4.12 Klasifikasi metode Random Forest
50% percentage split.

7. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 60% percentage split.


Gambar 4.13 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat lunak Weka dengan pengujian menggunakan testingset melalui 60% percentage split. Hasil klasifikasi menunjukkan sebanyak 38 data berhasil diprediksi dengan benar (akurasi 95%) dan 2 data diprediksi salah (kesalahan 5%), dengan waktu pemrosesan sebesar 0 detik.



Gambar 4.13 Klasifikasi metode Random Forest
60% percentage split.

8. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 70% Percentage Split.


Gambar 4.14 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat lunak Weka dengan pengujian menggunakan testingset melalui 70% percentage split. Hasil klasifikasi menunjukkan sebanyak 30 data berhasil diprediksi dengan benar (akurasi 100%) dan 0 data diprediksi salah (kesalahan 0%), dengan waktu pemrosesan sebesar 0 detik.



Gambar 4.14 Klasifikasi metode Random Forest
70% percentage split.

9. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 80% Percentage Split.


Gambar 4.15 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat lunak Weka dengan pengujian menggunakan testingset melalui 80% percentage split. Hasil klasifikasi menunjukkan sebanyak 20 data berhasil diprediksi dengan benar (akurasi 100%) dan 0 data diprediksi salah (kesalahan 0%), dengan waktu pemrosesan sebesar 0,02 detik.



Gambar 4.15 Klasifikasi metode Random Forest
80% percentage split.

10. Hasil Klasifikasi metode Random Forest menggunakan data testingset dan 90% Percentage Split.

Gambar 4.16 menyajikan hasil klasifikasi menggunakan metode Random Forest pada perangkat lunak Weka dengan pengujian menggunakan testingset melalui 90% percentage split. Hasil klasifikasi menunjukkan sebanyak 10 data berhasil diprediksi dengan benar (akurasi 100%) dan 0 data diprediksi salah (kesalahan 0%), dengan waktu pemrosesan sebesar 0 detik.



Gambar 4.16 Klasifikasi metode Random Forest
90% percentage split.

Pada pengujian ini, data pelatihan digunakan sekaligus sebagai data uji dalam proses validasi. Rincian perbandingan hasil evaluasi klasifikasi ditampilkan pada Tabel 4.1.

Berdasarkan Tabel 4.1, dapat dianalisis bahwa setelah dilakukan proses klasifikasi menggunakan Hasil pengujian klasifikasi penyakit jantung menggunakan metode Random Forest menunjukkan variasi nilai akurasi, presisi, dan recall yang naik turun seiring perubahan jumlah data uji. Pada tahap training tanpa data uji, model menghasilkan nilai sempurna (100% akurasi, presisi, dan recall) karena hanya

menguji data yang telah dipelajari, sehingga tidak mencerminkan kemampuan generalisasi model. Ketika mulai dilakukan pengujian dengan data baru (split 10% hingga 60%), terjadi fluktuasi performa. Misalnya, pada split 10%, akurasi turun menjadi 80%, presisi 74%, dan recall 96%.

Tabel 4.1 Hasil Klasifikasi Random Forest

Jenis Pengujian	TP	FN	FP	TN	Akurasi (%)	Presisi (%)	Recall (%)
Training	50	0	0	50	100%	100%	100%
10	45	2	16	27	80%	74%	96%
20	39	3	6	32	89%	87%	93%
30	34	4	3	29	90%	92%	89%
40	29	4	2	25	90%	94%	88%
50	25	3	1	21	92%	96%	89%
60	23	1	1	15	95%	96%	96%
70	17	0	0	13	100%	100%	100%
80	5	0	0	5	100%	100%	100%
90	11	0	0	9	100%	100%	100%

Hal ini disebabkan oleh adanya kesalahan dalam memprediksi data negatif (false positive) dan beberapa kesalahan dalam mendeteksi data positif (false negative). Namun, pada split 20% hingga 60%, performa model mulai stabil dan meningkat secara bertahap karena data uji lebih representatif.

Meskipun demikian, pada split 40% terjadi penurunan recall dari 93% menjadi 88%. Penurunan


ini disebabkan oleh meningkatnya jumlah false negative, yaitu kondisi di mana data yang seharusnya terindikasi penyakit (positif) justru diprediksi sebagai tidak terindikasi (negatif), yang menunjukkan model mulai kesulitan mengenali sebagian kasus positif ketika data uji bertambah. Pada split 70%, 80%, dan 90%, nilai akurasi, presisi, dan recall kembali mencapai 100%. Fenomena ini kemungkinan besar disebabkan oleh jumlah data uji yang sangat kecil pada bagian tersebut, sehingga variasi kasus yang diuji terbatas dan model lebih mudah dalam mengenali pola data. Fluktuasi nilai-nilai evaluasi ini wajar terjadi karena presisi sangat dipengaruhi oleh jumlah false positive, sedangkan recall dipengaruhi oleh false negative. Semakin banyak kesalahan prediksi, maka semakin rendah nilai evaluasi yang dihasilkan. Sebaliknya, jika jumlah kesalahan sedikit atau tidak ada, maka nilai akurasi, presisi, dan recall akan meningkat secara signifikan.

Secara keseluruhan, hasil ini menunjukkan bahwa metode Random Forest memiliki kapabilitas yang baik dalam membedakan citra jantung normal dan cardiomegaly, yang ditunjukkan pada pedoman Google Machine Learning Crash Course, metrik seperti

presisi dan recall di atas 90% umumnya dianggap sangat baik dalam konteks diagnosis medis. Presisi menunjukkan seberapa tepat prediksi positif, sedangkan recall mencerminkan kemampuan model dalam mendeteksi kasus positif yang sebenarnya(developers.google.com).



a)



b)



c)



d)

Gambar 4.17 Sampel citra a) TP, b) FN, c) FP, d) TN.

Gambar 4.17 merupakan sampel dari TP(True Positive) yaitu citra yang terdiagnosis cardiomegaly berhasil dideteksi sebagai cardiomegaly , FN(False

Negative) yaitu citra yang terdiagnosis cardiomegaly tetapi salah diklasifikasikan sebagai normal, FP(False Positive) yaitu citra yang terdiagnosis normal tetapi salah diklasifikasikan sebagai cardiomegaly , TN(True Negative) yaitu citra yang terdiagnosis normal yang berhasil dideteksi sebagai normal.

Penelitian sebelumnya oleh Hidayat et al., (2023) menunjukkan bahwa metode Random Forest dengan split data 80:20 menghasilkan kinerja terbaik dibandingkan split 70:30. Pada split 80:20, akurasi mencapai 94%, dengan presisi 92,8% dan recall 97,2%. Sementara itu, split 70:30 hanya menghasilkan akurasi 92%, presisi 80,3%, dan recall 86,1. Sedangkan pada penelitian ini menggunakan split 70%, 80%, dan 90% mampu memperoleh hasil akurasi, presisi, dan recal masing-masing sebesar 100%, yang artinya metode Random Forest yang digunakan dalam penelitian ini sangat akurat dalam mengklasifikasi citra jantung normal dan cardiomegaly.

Berdasarkan hasil ekstraksi fitur tekstur dari Tabel 4.2 dari citra X-ray jantung, diperoleh bahwa Fitur-fitur citra jantung hasil ekstraksi dalam

penelitian ini diklasifikasikan menjadi dua kategori utama, yaitu Histogram-based dan GLCM-based. Pada kategori Histogram, digunakan enam parameter statistik: mean, variance, skewness, entropy, standar deviasi, dan kurtosis.

Tabel 4.2 Rata-Rata Ciri Tekstur Normal dan Cardiomegaly

Fitur	Kategori	Normal	Cardiomegaly
Mean	Histogram	165.63354	156.798834
Variance	Histogram	2474.94935	2674.597787
Skewness	Histogram	-0.369885664	-0.521746328
Entropy	Histogram	7.481500076	7.461798904
Standar Deviasi	Histogram	49.6730213	51.01087341
Kurtosis	Histogram	2.172925828	2.381655108
Homogeneity	GLCM	0.366214024	0.421821399
Contras	GLCM	30.19719303	20.36504016
Energy	GLCM	7.481500076	7.461798904
Correlation	GLCM	0.993891022	0.995816762

Hasil analisis ciri tekstur pada penelitian ini fitur tekstur histogram mendapatkan hasil lebih tinggi rata-rata jantung normal antara lain: mean, dan entropy, sedangkan citra jantung cardiomegaly lebih kecil, yang dapat menunjukkan bahwa rata-rata dari tingkat kecerahan pada suatu objek dalam citra, serta ukuran yang menunjukkan tingkat kompleksitas pada sebuah gambar lebih tinggi pada citra jantung normal

dibandingkan dengan citra jantung cardiomegaly. Selanjutnya pada fitur tekstur histogram yang memiliki nilai lebih tinggi jantung cardiomegaly dibanding jantung normal antara lain: variance, skewness, standar deviasi, dan kurtosis yang menunjukkan bahwa representasi intensitas abu-abu, tingkat kemiringan relative asimetri dari kurva histogram, akar kuadrat dari variasi elemen gambar, dan ukuran yang menggambarkan ketajaman kurva histogram lebih tinggi pada rata-rata citra cardiomegaly dibandingkan citra jantung normal.

Sedangkan pada fitur tekstur GLCM, didapatkan hasil rata-rata yang lebih tinggi pada jantung normal dibanding jantung cardiomegaly antara lain: kontras, dan energy yang menunjukkan bahwa hasil pengukuran sejauh mana intensitas piksel berbeda dalam matriks ko-occurrence, serta hasil pengukuran tingkat kekacauan atau ketidakpastian dalam distribusi intensitas piksel pada citra, mendapatkan hasil lebih tinggi pada citra jantung normal dibandingkan dengan citra jantung cardiomegaly. Selanjutnya pada fitur tekstur GLCM yang memiliki nilai lebih tinggi jantung cardiomegaly dibanding jantung cardiomegaly antara lain: homogeneity dan correlation yang menunjukkan bahwa analisis distribusi intensitas piksel dalam sebuah citra serta ukuran sejauh mana

hubungan linier antara nilai keabuan piksel-piksel dalam sebuah citra mendapatkan hasil lebih tinggi pada citra jantung cardiomegaly dibandingkan citra jantung normal.

Temuan ini selaras dengan penelitian sebelumnya oleh Ashari et al., (2024) yang melakukan klasifikasi antara citra mammogram normal dan kanker menggunakan fitur histogram dan GLCM. Dalam penelitian tersebut, jaringan kanker menunjukkan mean lebih rendah dibandingkan citra normal yang artinya fitur yang menghitung kecerahan rata-rata objek lebih tinggi pada citra normal. Skewness pada kanker lebih besar (dalam nilai absolut) dibandingkan citra normal yang artinya, fitur yang mengukur penyimpangan distribusi dari intensitas rata-ratanya lebih tinggi pada citra kanker, serta variance dan standar deviasi yang lebih tinggi pada kanker dibandingkan dengan citra normal, yang artinya fitur yang memberikan informasi tentang ukuran kontras pada gambar serta fitur yang menggambarkan tingkat variasi atau penyebaran data dari nilai rata-rata suatu pengukuran lebih tinggi pada citra kanker disbanding citra normal. Fitur GLCM juga menunjukkan bahwa nilai homogeneity dan correlation lebih tinggi pada citra kanker yang artinya, ukuran keseragaman transisi tingkat abu-abu pada gambar serta ukuran linier tingkat saling

ketergantungan tingkat abu-abu dalam suatu gambar lebih tinggi pada citra kanker dibandingkan citra normal.

Tabel 4.1 menunjukkan bahwa akurasi tertinggi diperoleh pada tahap trainingset dengan persentase sebesar 100%, yang berarti seluruh data berhasil diklasifikasikan dengan benar oleh model. Berdasarkan nilai akurasi tersebut, dapat dikatakan bahwa metode Random Forest memiliki performa yang sangat baik dalam mengenali pola citra dari kedua kelas. Data trainingset berfungsi sebagai tolok ukur kebenaran model, sedangkan testingset menunjukkan hasil klasifikasi sebenarnya oleh metodenya. Jika dilihat dari hasil pengujian dengan variasi jumlah data pada testingset, diperoleh akurasi yang cukup tinggi secara keseluruhan. Sebagai contoh, saat jumlah data uji sebanyak 70%, 80%, dan 90% data split, model masih mampu mencapai akurasi, presisi, dan recall sebesar 100%. Hal ini menunjukkan kestabilan dan kemampuan Random Forest dalam mengenali perbedaan antara jantung normal dan cardiomegaly. Hasil ini sejalan dengan penelitian Govindarajan et al., (2020), yang juga menunjukkan efektivitas klasifikasi antara jantung normal dan cardiomegaly menggunakan pendekatan machine learning berbasis fitur morfologi dengan tingkat akurasi

tinggi. Pada saat melakukan proses klasifikasi, data citra yang digunakan dalam penelitian ini diolah menggunakan metode percentage split. Metode ini bekerja dengan cara memisahkan sebagian data untuk melatih sistem, dan sebagian lainnya digunakan untuk menguji apakah sistem mampu mengenali citra dengan benar. Artinya, data yang ada tidak langsung digunakan seluruhnya untuk pelatihan, melainkan sebagian data dilatih terlebih dahulu, kemudian sisanya diuji untuk melihat hasil kinerja dari metode klasifikasi yang digunakan, yaitu Random Forest.

Metode ini diterapkan beberapa kali dengan jumlah data uji yang berbeda-beda untuk melihat sejauh mana pengaruhnya terhadap akurasi sistem. Berdasarkan Tabel 4.1, hasil klasifikasi menunjukkan bahwa ketika jumlah data latih lebih banyak dibanding data uji, hasil akurasi cenderung lebih tinggi. Hal ini ditunjukkan dari hasil terbaik yang diperoleh, yaitu semua data berhasil dikenali dengan benar sehingga menghasilkan nilai akurasi, presisi, dan recall masing-masing sebesar 100%. Sedangkan pada pengujian lainnya, ketika data uji lebih banyak, nilai akurasi sedikit menurun, seperti 95%, 92%, hingga 80%. Berdasarkan hasil tersebut, maka pada penelitian ini digunakan pengujian dengan jumlah data

latih yang lebih besar karena mampu memberikan hasil klasifikasi yang paling baik. Pendekatan ini dipilih karena sederhana dan telah digunakan dalam berbagai penelitian serupa, serta terbukti efektif dalam mengenali perbedaan antara citra jantung normal dan citra cardiomegaly (Govindarajan et al., 2020).

Pengujian dilakukan menggunakan metode percentage split dengan hasil klasifikasi ditampilkan pada lampiran. Berdasarkan hasil tersebut, diketahui bahwa seluruh citra berhasil diklasifikasikan dengan benar oleh model. Dari total 30, 20, dan 10 citra uji, tidak terdapat kesalahan klasifikasi, baik berupa False Positive (prediksi cardiomegaly padahal citra normal) maupun False Negative (prediksi normal padahal citra cardiomegaly). Hal ini menunjukkan bahwa model mampu membedakan antara citra jantung normal dan cardiomegaly dengan sangat baik. Kemungkinan keberhasilan klasifikasi ini tidak lepas dari proses ekstraksi ciri tekstur yang efektif, sehingga mampu menangkap karakteristik penting dari masing-masing kelas. Nilai statistik seperti mean, entropy, kurtosis, dan skewness tampaknya cukup representatif untuk membedakan kedua kondisi jantung tersebut. Selain itu, tahapan preprocessing juga diduga telah berjalan optimal, sehingga fitur penting dari citra tidak

mengalami distorsi atau kehilangan informasi. Dengan hasil klasifikasi yang mencapai akurasi 100%, model yang dibangun terbukti sangat efektif pada data uji ini. Meskipun demikian, tetap diperlukan pengujian lanjutan dengan jumlah data yang lebih besar dan lebih bervariasi untuk memastikan konsistensi performa model pada data yang lebih kompleks.

Penelitian terbaru oleh Alfiyyah, (2024) menyajikan pendekatan Random Forest untuk deteksi cardiomegaly pada citra X-ray dada. Penelitian ini menggunakan teknik pemrosesan citra seperti Sobel filtering dan pengambilan ciri Hu Moments, serta menerapkan metode 5-fold cross-validation. Hasil evaluasi menunjukkan nilai rata-rata sebagai berikut: akurasi 52,4 %, presisi 52,5 %, recall 52,4 %, dan F1-score 51,8 %. Sedangkan pada penelitian ini yang menggunakan dataset citra jantung normal dan cardiomegaly berbasis fitur tekstur pada 10% percentage split diperoleh hasil yang jauh lebih baik. Nilai akurasi mencapai 80%, dengan presisi 74 % dan recall 96%, yang menunjukkan seluruh citra cardiomegaly berhasil dikenali tanpa ada yang salah diklasifikasikan sebagai normal. Keberhasilan ini didukung karena TP dan TN mencapai 33 dan 40 dari total 90 data.

Jika dibandingkan, hasil penelitian Alfiyyah, (2024)

menunjukkan akurasi, presisi, dan recall yang relatif rendah, yaitu masing-masing sebesar 52,4%, 52,5%, dan 52,4%. Sementara itu, pada penelitian ini, hasil terbaik diperoleh pada split data 70%, 80%, dan 90% dengan nilai akurasi, presisi, dan recall yang semuanya mencapai 100%. Bahkan pada split data 10%, performa sudah jauh lebih unggul dengan akurasinya mencapai 80%, presisi 74%, dan recall 96%. Dengan demikian, perbandingan akurasi penelitian ini terhadap penelitian sebelumnya pada split 10% lebih tinggi sebesar 27,6%, presisi lebih tinggi 21,5%, dan recall lebih tinggi 43,6%. Perbandingan ini menunjukkan bahwa pendekatan fitur tekstur menggunakan Histogram dan GLCM dalam penelitian ini jauh lebih efektif dibanding metode yang digunakan oleh penelitian sebelumnya.

Berdasarkan penelitian menggunakan metode Random Forest yang digunakan menunjukkan performa yang sangat optimal dengan nilai akurasi, presisi, dan recall sebesar 100% pada pengujian dengan pembagian data 70%, 80%, dan 90%. Hasil ini mencerminkan kemampuan metode dalam mengklasifikasikan citra jantung normal dan cardiomegaly secara akurat tanpa kesalahan prediksi. Sebagai perbandingan, pada penelitian yang dilakukan oleh Rahmah et al., (2023) Hasil

evaluasi menunjukkan bahwa Random Forest mampu mencapai akurasi tertinggi sebesar 83,33%, dengan nilai precision dan recall masing-masing sebesar 82,11% dan 96,30% pada konfigurasi Hold Out 90:10. Sebaliknya, SVM menunjukkan akurasi maksimum sebesar 81,51% pada konfigurasi Hold Out 60:40, dengan precision 79,80% dan recall 97,53%. Hasil tersebut menunjukkan bahwa Random Forest memiliki keunggulan yang signifikan dibandingkan metode lain, terutama dalam hal ketepatan mendeteksi kondisi positif secara konsisten. Keunggulan ini semakin memperkuat bahwa Random Forest merupakan metode klasifikasi yang andal dan efektif dalam aplikasi diagnosa berbasis citra medis.

BAB V

KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil analisis yang didapatkan dari proses klasifikasi citra X-ray jantung antara kondisi normal dan cardiomegaly, maka diperoleh kesimpulan sebagai berikut:

1. Hasil ekstraksi ciri tekstur pada fitur histogram, citra jantung normal memiliki nilai mean dan entropy histogram yang lebih tinggi dibandingkan cardiomegaly, sedangkan citra jantung normal memiliki nilai *variance*, *skewness*, *standar deviasi*, dan *kurtosis*, yang lebih rendah dari cardiomegaly. Sedangkan pada fitur GLCM, citra jantung normal memiliki nilai *contrast* dan *energy* lebih tinggi, dibanding cardiomegaly. Sebaliknya, citra cardiomegaly unggul pada *homogeneity* dan *correlation*.
2. Klasifikasi citra dilakukan menggunakan metode Random Forest dengan pendekatan percentage split. Dari hasil pengujian 70%, 80%, 90% diperoleh nilai akurasi sebesar 100%, presisi

sebesar 100%, dan recall sebesar 100%. Nilai tersebut menunjukkan bahwa metode Random Forest mampu mengenali seluruh citra cardiomegaly dengan sangat baik tanpa kesalahan deteksi, serta sangat akurat dalam membedakan antara citra jantung normal dan cardiomegaly secara keseluruhan.

B. Saran

Berdasarkan hasil penelitian yang telah dilakukan, maka saran untuk penelitian selanjutnya adalah sebagai berikut:

1. Menggunakan jumlah data yang lebih besar dan bervariasi, agar model dapat diuji lebih menyeluruh terhadap variasi bentuk dan kualitas citra.
2. Menerapkan metode klasifikasi lain untuk mengetahui metode mana yang paling optimal.
3. Melakukan evaluasi dengan teknik validasi silang (*cross-validation*) agar hasil akurasi lebih stabil dan tidak bergantung pada subset data tertentu.

DAFTAR PUSTAKA

- A. Ogungbe, O., R. Iyanda, A., & S. Aderibigbe, A. (2022). Design and Implementation of Diagnosis System for Cardiomegaly from Clinical Chest X-ray Reports. *International Journal of Engineering and Manufacturing*, 12(3), 25–37. <https://doi.org/10.5815/ijem.2022.03.03>
- Agussationo, Y., Soesanti, I., & Najib, W. (2018). Klasifikasi Citra X-Ray Diagnosis Tuberkulosis Berbasis Fitur Statistis. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 2(3), 736–745. <https://doi.org/10.29207/resti.v2i3.523>
- Alfiyyah, N. (2024). *Optimizing Cardiomegaly Detection: A Random Forest Approach to Processed Chest X-ray Imagery*. 2(2), 115–124.
- Algehyne, E. A., Jibril, M. L., Algehainy, N. A., Alamri, O. A., & Alzahrani, A. K. (2022). Fuzzy Neural Network Expert System with an Improved Gini Index Random Forest-Based Feature Importance Measure Algorithm for Early Diagnosis of Breast Cancer in Saudi Arabia. *Big Data and Cognitive Computing*, 6(1). <https://doi.org/10.3390/bdcc6010013>
- Aouat, S., Ait-hammi, I., & Hamouchene, I. (2021). A new

- approach for texture segmentation based on the Gray Level Co-occurrence Matrix. *Multimedia Tools and Applications*, 80(16), 24027–24052.
<https://doi.org/10.1007/s11042-021-10634-4>
- Ariansyah, F. A., Kartini, K., & Maulana, H. (2024). Klasifikasi Pneumonia Pada Citra X-Ray Paru-Paru Menggunakan Algoritma Naive Bayes. *JUTIM (Jurnal Teknik Informatika Musirawas)*, 9(1), 1–14.
<https://doi.org/10.32767/jutim.v9i1.2243>
- Aryuanto, Somawirata, K., & Limpraptono, F. Y. (2009). A New Color Segmentation Method Based on Normalized RGB Chromaticity Diagram. *Seminar on Intelligent Technology and Its Applications*, 1–6.
- Ashari, R., JHMT, H. K., & 2024, undefined. (2024). Classification of normal and cancerous mammogram images based on texture features using the Support Vector Machine (SVM) method. *Journal.Innoscientia.Org*, 1(1), 40–49.
<https://journal.innoscientia.org/index.php/jhmt/article/view/31>
- Azizah, R. N., Huda, M. M., Tricahyo, V. A., & Septarina, A. A. (2024). Implementasi Arsitektur Visual Geometry Group

- 16 (VGG16) untuk Deteksi Cardiomegaly pada Chest X-Ray. *Jurnal Teknik Elektro Dan Komputer TRIAC*, 11(1), 31–36. <https://doi.org/10.21107/triac.v11i1.24371>
- Basuki, U. (2020). Merunut Konstitusionalisme Hak Atas Pelayanan Kesehatan Sebagai Hak Asasi Manusia. *Jurnal Hukum Caraka Justitia*, 1(1), 21–41. <https://ejournal.up45.ac.id/index.php/JHCJ/article/view/699>
- Bougias, H., Georgiadou, E., Malamateniou, C., & Stogiannos, N. (2021). Identifying cardiomegaly in chest X-rays: a cross-sectional study of evaluation and comparison between different transfer learning methods. *Acta Radiologica*, 62(12), 1601–1609. <https://doi.org/10.1177/0284185120973630>
- Breve, F. A. (2022). COVID-19 detection on Chest X-ray images: A comparison of CNN architectures and ensembles[Formula presented]. *Expert Systems with Applications*, 204. <https://doi.org/10.1016/j.eswa.2022.117549>
- Dian, J., Silalahi, F. D., & Setiawan, N. D. (2021). A Heartbeat Monitoring System To Detect Internet Of Things-Based Heart Health Levels Using Android. *JUPITER (Jurnal*

- Penelitian Ilmu Dan Teknologi Komputer*), 13(2), 69–75.
<https://jurnal.polsri.ac.id/index.php/jupiter/article/view/3669>
- Dr. Muslimin. (2011). *Fisika Modern*. 1–123.
- Ermawati, E. (2020). Klasifikasi Nodul Payudara Berdasarkan Ciri Tekstur pada Citra Ultrasonografi Menggunakan Scilab. *Universitas Islam Negeri Walisongo Semarang*.
<https://eprints.walisongo.ac.id/id/eprint/12860/>
- Fuadi, N., Jusli, N., & Harmini. (2022). Pemantauan Dosis Perorangan Menggunakan Thermoluminescence Dosimeter (Tld) Di Wilayah Papua Dan Papua Barat Tahun 2020-2021. *Jurnal Sains Fisika*, 2(1), 63–74.
<http://journal.uin-alauddin.ac.id/index.php/sainfis>
- Gabriel, J. F. (1996). Fisika Kedokteran. In *Buku Kedokteran* (1996th ed.). Jakarta: EGC, 1996.
<https://doi.org/10.1063/1.5080540>
- Givari, M. R., Sulaeman, M. R., & Umaidah, Y. (2022). Perbandingan Algoritma SVM, Random Forest Dan XGBoost Untuk Penentuan Persetujuan Pengajuan Kredit. *Nuansa Informatika*, 16(1), 141–149.
<https://doi.org/10.25134/nuansa.v16i1.5406>

- Gloria Kang GJ, Ewing-Nelson SR, Mackey L, Schlitt JT, Marathe A, Abbas KM, S. S. (2018). Computer-Aided Diagnosis in the Era of Deep Learning. *Physiology & Behavior*, 176(1), 139–148. <https://doi.org/10.1002/mp.13764>.Computer-Aided
- Gour, M., & Jain, S. (2020). *Stacked Convolutional Neural Network for Diagnosis of COVID-19 Disease from X-ray Images*. <http://arxiv.org/abs/2006.13817>
- Govindarajan, S., Tulo, S. K., & Swaminathan, R. (2020). Classification of normal and cardiomegaly conditions in chest radiographs using cardio-mediastinal features. *Studies in Health Technology and Informatics*, 270, 1225–1226. <https://doi.org/10.3233/SHTI200374>
- HARALICK, R. M., SHANMUGAM, K., & DINSTEIN, I. (1973). Textural Features for Image Classification. *Textural Features for Image Classification*, SMC-3. <https://doi.org/https://doi.org/10.1109/TSMC.1973.4309314>
- Hendrawan, A., & Setiyawati, D. (2021). *STUDI DESKRIPTIF PEMBERIAN PHYSICAL THERAPY EXERCISE PADA KONDISI NYERI PUNGGUNG BAWAH MYOGENIC* Descriptive Study of Giving Physical Therapy Exercise in

*Myogenic Lower Back Pain Conditions PENDAHULUAN
Punggung mempunyai peran yang sangat besar dalam
aktif. 14(September), 98–106.*

Hidayat, H., Sunyoto, A., & Al Fatta, H. (2023). Klasifikasi Penyakit Jantung Menggunakan Random Forest Clasifier. *Jurnal SISKOM-KB (Sistem Komputer Dan Kecerdasan Buatan)*, 7(1), 31–40. <https://doi.org/10.47970/siskom-kb.v7i1.464>

Hinzpeter, R., Wagner, M. W., Wurnig, M. C., Seifert, B., Manka, R., & Alkadhi, H. (2017). Texture analysis of acute myocardial infarction with CT: First experience study. *PLoS ONE*, 12(11), 1–16. <https://doi.org/10.1371/journal.pone.0186876>

Indawati, E., & Dewi, N. (2020). *THE EFFECT OF HEALTH EDUCATION ON PREVENTION OF TUBERCULOSITION MEDICINE RESISTANCE IN LUNG TB PATIENTS*. 7(January), 1–6.

Islam, M. T., Aowal, M. A., Minhaz, A. T., & Ashraf, K. (2017). *Abnormality Detection and Localization in Chest X-Rays using Deep Convolutional Neural Networks*. <http://arxiv.org/abs/1705.09850>

Jawahar, M., Prassanna, J., Ravi, V., Anbarasi, L. J., Jasmine, S.

- G., Manikandan, R., Sekaran, R., & Kannan, S. (2022). Computer-aided diagnosis of COVID-19 from chest X-ray images using histogram-oriented gradient features and Random Forest classifier. *Multimedia Tools and Applications*, 81(28), 40451–40468. <https://doi.org/10.1007/s11042-022-13183-6>
- JERROLD T. BUSHBERG, PhD; J. ANTHONY SEIBERT, PhD; EDWIN M. LEIDHOLDT JR, PhD; JOHN M. BOONE, P. (1994). The Essential Physics of Medical Imaging. In C. W. Mitchell (Ed.), *Radiology* (THIRD EDIT, Vol. 191, Issue 3). <https://doi.org/10.1148/radiology.191.3.786>
- Kailasam, R., & Balasubramanian, S. (2025). Deep Learning for Pneumonia Detection: A Combined CNN and YOLO Approach. *Human-Centric Intelligent Systems*, 5(1), 44–62. <https://doi.org/10.1007/s44230-025-00091-9>
- Kermany, D. S., Goldbaum, M., Cai, W., & Lewis, M. A. (2018). Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning Resource Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*, 172(5), 1122-1131.e9. <https://doi.org/10.1016/j.cell.2018.02.010>
- Khan, A., Akram, M. U., & Nazir, S. (2023). Automated grading

of chest x-ray images for viral pneumonia with convolutional neural networks ensemble and region of interest localization. *PLoS ONE*, 18(1 January), 1–19. <https://doi.org/10.1371/journal.pone.0280352>

Kitaguchi, S., Westland, S., & Luo, M. R. (2005). Suitability of texture analysis methods for perceptual texture. *AIC Colour 05 - 10th Congress of the International Colour Association*, 923–926.

Kong, W. Z., & Zhu, S. A. (2007). Multi-face detection based on downsampling and modified subtractive clustering for color images. *Journal of Zhejiang University: Science A*, 8(1), 72–78. <https://doi.org/10.1631/jzus.2007.A0072>

Krane, K. (1992). Modern Physics. In *Sustainability (Switzerland)* (Cet 1, 200, Vol. 11, Issue 1). Jakarta : Penerbit Universitas Indonesia, 1992. http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SISTEM_PEMBETUNGAN_TERPUSAT_STRATEGI_MELESTARI

Lestari, M. I., & Setiawan, P. (2021). Anatomi Jantung dan

- Pembuluh darah. *Buku Ajar Kardiologi*, 7–13.
[https://repository.unsri.ac.id/44828/1/Turnitin
 Anatomi Jantung dan Pembuluh Darah.pdf](https://repository.unsri.ac.id/44828/1/TurnitinAnatomiJantungdanPembuluhDarah.pdf)
- Lilik, N. I. S., & Budiono, I. (2021). Risiko Kematian Pasien Gagal Jantung Kongestif (GJK): Studi Kohort Retrospektif Berbasis Rumah Sakit. *Indonesian Journal of Public Health and Nutrition*, 1(3), 388–395.
<http://journal.unnes.ac.id/sju/index.php/IJPHN>
- Lin, C., Zhang, F., Wu, J., Pai, N., Chen, P., Pai, C., & Kan, C. (2022). *Posteroanterior Chest X-ray Image Classification with a Multilayer 1D Convolutional Neural Network-Based Classifier for Cardiomegaly Level Screening*.
- Marlina, L., Munadi, K., & Arnia, F. (2020). Klasifikasi Kanker Payudara Menggunakan Teknik Support Vector Machine (Svm) Pada Citra Termografi. *Jurnal Komputer, Informasi Teknologi, Dan Elektro*, 5(2), 11–13.
<https://doi.org/10.24815/kitektro.v5i2.15571>
- Metra, M., Teerlink, J. R., Cotter, G., Davison, B. A., Felker, G. M., Filippatos, G., Greenberg, B. H., Pang, P. S., Ponikowski, P., Voors, A. A., Adams, K. F., Anker, S. D., Arias-Mendoza, A., Avendaño, P., Bacal, F., Böhm, M., Bortman, G., Cleland, J. G. F., Cohen-Solal, A., ... Gimpelewicz, C. (2019). Effects of

- Serelaxin in Patients with Acute Heart Failure. *New England Journal of Medicine*, 381(8), 716–726.
<https://doi.org/10.1056/nejmoa1801291>
- Naomi, W. S., Picauly, I., & Toy, S. M. (2021). Faktor Risiko Kejadian Penyakit Jantung Koroner. *Media Kesehatan Masyarakat*, 3(1), 99–107.
<https://doi.org/10.35508/mkm.v3i1.3622>
- Nurkholis, A., Riyantomo, A., & Tafrikan, M. (2017). Sistem Pakar Penyakit Lambung ... SISTEM PAKAR PENYAKIT LAMBUNG MENGGUNAKAN METODE FORWARD CHAINING. *Jurnal Momentum*, 13(1), 32–38.
- Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R., Bhardwaj, P., & Singh, V. (2020). A deep learning and grad-CAM based color visualization approach for fast detection of COVID-19 cases using chest X-ray and CT-Scan images. *Chaos, Solitons and Fractals*, 140, 110190.
<https://doi.org/10.1016/j.chaos.2020.110190>
- Purwaningsih, N., Soesanti, I., & Nugroho, H. A. (2015). Ekstraksi Ciri Tekstur Citra Kulit Sapi Berbasis Co-Occurrence Matrix. *Seminar Nasional Teknologi Informasi Dan Multimedia*, 6–8.
- Rahmah, A., Sepriyanti, N., Zikri, M. H., Ambarani, I., & Shahar,

- M. Y. bin. (2023). Implementation of Support Vector Machine and Random Forest for Heart Failure Disease Classification. *Public Research Journal of Engineering, Data Technology and Computer Science*, 1(1), 34–40. <https://doi.org/10.57152/predatecs.v1i1.816>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Ball, R. L., Langlotz, C., Shpanskaya, K., Lungren, M. P., & Ng, A. Y. (2017). *CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning*. 3–9.
- Rizal, R. A., Gulo, S., Sihombing, O. D. C., Napitupulu, A. B. M., Gultom, A. Y., & Siagian, T. J. (2019). Analisis Gray Level Co-Occurrence Matrix (GLCM) Dalam Mengenali Citra Ekspresi Wajah. *Jurnal Mantik*, 3(January), 31–38. <http://iocscience.org/ejournal/index.php/mantik/article/view/497/302>
- Rosyani, P., Saprudin, S., & Amalia, R. (2021). Klasifikasi Citra Menggunakan Metode Random Forest dan Sequential Minimal Optimization (SMO). *Jurnal Sistem Dan Teknologi Informasi (Justin)*, 9(2), 132. <https://doi.org/10.26418/justin.v9i2.44120>
- Saifullah, S., & Suryotomo, A. P. (2021). Identification of

- chicken egg fertility using SVM classifier based on first-order statistical feature extraction. *ILKOM Jurnal Ilmiah*, 13(3), 285–293.
<https://doi.org/10.33096/ilkom.v13i3.937.285-293>
- Shang, W., Huang, H., Zhu, H., Lin, Y., Qu, Y., & Wang, Z. (2007). A novel feature selection algorithm for text categorization. *Expert Systems with Applications*, 33(1), 1–5. <https://doi.org/10.1016/j.eswa.2006.04.001>
- Shpakov, O. N., & Bogomolov, G. V. (1981). Technogenic activity of man and local sources of environmental pollution. *Studies in Environmental Science*, 17(C), 329–332. [https://doi.org/10.1016/S0166-1116\(08\)71924-1](https://doi.org/10.1016/S0166-1116(08)71924-1)
- Syahrudin, A. N., & Kurniawan, T. (2018). Input dan Output pada Bahasa Pemrograman Python. *Jurnal Dasar Pemrograman Python STMIK*, June 2018, 1–7. <https://www.researchgate.net/publication/338385483>
- Systems, P. R. (2000). B. Jähne, H. Haussecker, and P. Geissler, eds., *Handbook of Computer Vision and Applications*. 1. *Sensors and Imaging*. 2. *Signal Processing and*. 120, 271–273.
- Tang, Y., Tang, Y., Peng, Y., Yan, K., Bagheri, M., Redd, B. A., Brandon, C. J., Lu, Z., Han, M., Xiao, J., & Summers, R. M.

- (n.d.). Automated abnormality classification of chest radiographs using deep convolutional neural networks. *Npj Digital Medicine*. <https://doi.org/10.1038/s41746-020-0273-z>
- Tang, Z., Zhao, W., Xie, X., Zhong, Z., Shi, F., Liu, J., & Shen, D. (2020). *Severity Assessment of Coronavirus Disease 2019 (COVID-19) Using Quantitative Features from Chest CT Images*. 2019, 1–18. <http://arxiv.org/abs/2003.11988>
- Tipler, Paul A.; Llewellyn, R. a. (2008). *Modern Physics - Vol.2. In Modern Physics Fifth Edition*.
- Tsuroyya, F. A., Ramadhani, K. N., & Ramadhani, E. O. (2025). *Tinjauan Organ Jantung sebagai Pusat Kehidupan dalam Sistem Kardiovaskular*. 3.
- Wahidah, W., & Harahap, R. A. (2021). [PJK]: PJK (Penyakit Jantung Koroner) VS SKA (Sindrom Koroner Akut) Prespektif Epidemiologi. *Afiasi: Jurnal Kesehatan Masyarakat*, 6(1), 54–65. <https://doi.org/10.31943/afiasi.v1i4.135>
- Whittaker, A. D., Guyer, D. E., & Miles, G. E. (1984). *Introduction To Digital Image Processing. Paper - American Society of Agricultural Engineers*. <https://doi.org/10.1201/9781315123905-1>

- Windyasari, H., Zulfikah, P., Fakhri, H. A., & Triwahyuni, N. (2024). *Classification of gastric tissue images based on texture characteristics using the Random Forest method*. 1(1), 10–16.
- Zaheeruddin, Jaffery, Z. A., & Singh, L. (2012). Detection and shape feature extraction of breast tumor in mammograms. *Lecture Notes in Engineering and Computer Science*, 2198, 719–724.
- Zaman, M. J. S., Sanders, J., Crook, A. M., Feder, G., Shipley, M., & Timmis, A. (2007). *Cardiothoracic ratio within the “normal” range independently predicts mortality in patients undergoing coronary angiography*. April 1997, 491–494. <https://doi.org/10.1136/hrt.2006.101238>
- Zhou, J., Yan Guo, R., Sun, M., Di, T. T., Wang, S., Zhai, J., & Zhao, Z. (2017). The Effects of GLCM parameters on LAI estimation using texture values from Quickbird Satellite Imagery. *Scientific Reports*, 7(1), 1–12. <https://doi.org/10.1038/s41598-017-07951-w>

LAMPIRAN

Lampiran 1. Code Program Pre-Processing

```
import os
import cv2
import numpy as np
from tqdm import tqdm

def preprocess_xray(img, use_clahe=True, denoise=True):
    # 1. Rescale ke 0-1
    img_norm = img.astype(np.float32) / 255.0

    # 2. CLAHE atau histogram equalization
    if use_clahe:
        clahe = cv2.createCLAHE(clipLimit=2.0,
tileGridSize=(8,8))
        img_eq = clahe.apply((img_norm * 255).astype(np.uint8))
    else:
        img_eq = cv2.equalizeHist((img_norm *
255).astype(np.uint8))

    # 3. Denoise (Gaussian blur)
    if denoise:
```

```

        img_blur = cv2.GaussianBlur(img_eq, (3, 3), sigmaX=0)
    else:
        img_blur = img_eq

# 4. Kembali ke rentang 0–255 untuk disimpan
    return (img_blur * (255.0 /
img_blur.max()))).astype(np.uint8)

def process_all_images(base_presentaseer):
    for root, dirs, files in os.walk(base_presentaseer):
        for file in tqdm(files, desc=f"Processing in {root}"):
            if file.lower().endswith(['.jpg', '.jpeg', '.png']):
                file_path = os.path.join(root, file)

                # Baca gambar grayscale
                img = cv2.imread(file_path,
cv2.IMREAD_GRAYSCALE)

                if img is None:
                    print(f"Gagal membaca: {file_path}")
                    continue

                # Preprocessing
                processed = preprocess_xray(img)

```

```

# Buat presentaseer "preprocessed" jika belum ada
save_presentaseer = os.path.join(root,
"preprocessed")
os.makedirs(save_presentaseer, exist_ok=True)


# Simpan gambar hasil preprocessing
save_path = os.path.join(save_presentaseer, file)
cv2.imwrite(save_path, processed)


print("✔ ☐ Semua gambar selesai diproses.")









# Ganti dengan path presentaseer dataset kamu
dataset_path = 'D:/X RAY/NORMAL'
process_all_images(dataset_path)










```













Lampiran 2. Hasil Ekstraksi Ciri Tekstur

No	Jenis Citra	Asli	Preprocessing				
1	Normal			11	Normal		
2	Normal			12	Normal		
3	Normal			13	Normal		
4	Normal			14	Normal		
5	Normal			15	Normal		
6	Normal			16	Normal		
7	Normal			17	Normal		
8	Normal			18	Normal		
9	Normal			19	Normal		
10	Normal			20	Normal		

21	Normal			31	Normal		
22	Normal			32	Normal		
23	Normal			33	Normal		
24	Normal			34	Normal		
25	Normal			35	Normal		
26	Normal			36	Normal		
27	Normal			37	Normal		
28	Normal			38	Normal		
29	Normal			39	Normal		
30	Normal			40	Normal		

41	Normal			51	Cardiomegaly		
42	Normal			52	Cardiomegaly		
43	Normal			53	Cardiomegaly		
44	Normal			54	Cardiomegaly		
45	Normal			55	Cardiomegaly		
46	Normal			56	Cardiomegaly		
47	Normal			57	Cardiomegaly		
48	Normal			58	Cardiomegaly		
49	Normal			59	Cardiomegaly		
50	Normal			60	Cardiomegaly		

61	Cardiomegaly			71	Cardiomegaly		
62	Cardiomegaly			72	Cardiomegaly		
63	Cardiomegaly			73	Cardiomegaly		
64	Cardiomegaly			74	Cardiomegaly		
65	Cardiomegaly			75	Cardiomegaly		
66	Cardiomegaly			76	Cardiomegaly		
67	Cardiomegaly			77	Cardiomegaly		
68	Cardiomegaly			78	Cardiomegaly		
69	Cardiomegaly			79	Cardiomegaly		
70	Cardiomegaly			80	Cardiomegaly		

81	Cardiomegaly			91	Cardiomegaly		
82	Cardiomegaly			92	Cardiomegaly		
83	Cardiomegaly			93	Cardiomegaly		
84	Cardiomegaly			94	Cardiomegaly		
85	Cardiomegaly			95	Cardiomegaly		
86	Cardiomegaly			96	Cardiomegaly		
87	Cardiomegaly			97	Cardiomegaly		
88	Cardiomegaly			98	Cardiomegaly		
89	Cardiomegaly			99	Cardiomegaly		
90	Cardiomegaly			100	Cardiomegaly		

Lampiran 3. Code Program Python Histogram_GLCM

```
from google.colab import drive
drive.mount('/content/drive')

import os
import glob
import cv2
import numpy as np
import pandas as pd

# Fungsi menghitung entropi
def calculate_entropy(prob):
    return -np.sum(prob[prob > 0] * np.log2(prob[prob > 0]))

# Fungsi menghitung GLCM manual untuk jarak 1 piksel arah
# 0 derajat (horizontal)
def compute_glcml_features(gray_img):
    levels = 256
    glcm = np.zeros((levels, levels), dtype=np.float64)

    # Hitung GLCM
    for i in range(gray_img.shape[0]):
        for j in range(gray_img.shape[1] - 1): # arah horizontal (0
derajat)
            row = gray_img[i, j]
```

```

        col = gray_img[i, j + 1]
        glcm[row, col] += 1

# Normalisasi
glcm /= glcm.sum()

# Inisialisasi nilai fitur
contrast = 0
energy = 0
homogeneity = 0
correlation = 0

mean_i = np.sum(np.arange(levels) * glcm.sum(axis=1))
mean_j = np.sum(np.arange(levels) * glcm.sum(axis=0))
std_i = np.sqrt(np.sum((((np.arange(levels) - mean_i) ** 2) *
glcm.sum(axis=1))))
std_j = np.sqrt(np.sum((((np.arange(levels) - mean_j) ** 2) *
glcm.sum(axis=0))))

for i in range(levels):
    for j in range(levels):
        pij = glcm[i, j]
        contrast += (i - j) ** 2 * pij
        energy += pij ** 2

```

```

        homogeneity += pij / (1 + abs(i - j))
    if std_i > 0 and std_j > 0:
        correlation += ((i - mean_i) * (j - mean_j) * pij) / (std_i
* std_j)

    return contrast, energy, correlation, homogeneity

# Fungsi ekstraksi ciri tekstur
def extract_texture_features(image_path):
    img = cv2.imread(image_path)
    if img is None:
        print(f"⚠️ Gagal membaca: {image_path}")
        return None
    gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
    hist, _ = np.histogram(gray.ravel(), bins=256,
range=[0,256], density=True)
    pixels = np.arange(256)
    μ = np.sum(pixels * hist)
    σ2 = np.sum(((pixels - μ) ** 2 * hist)
    σ = np.sqrt(σ2)
    α3 = np.sum((((pixels - μ) ** 3) * hist) / (σ ** 3 + 1e-8)
    α4 = np.sum((((pixels - μ) ** 4) * hist) / (σ ** 4 + 1e-8)
    H = calculate_entropy(hist)

```

```

# GLCM manual
contrast, energy, correlation, homogeneity =
compute_glcm_features(gray)

return {
    'Filename': os.path.basename(image_path),
    'Mean':  $\mu$ ,
    'Variance':  $\sigma^2$ ,
    'Std_Dev':  $\sigma$ ,
    'Skewness':  $\alpha_3$ ,
    'Kurtosis':  $\alpha_4$ ,
    'Entropy': H,
    'Contrast': contrast,
    'Energy': energy,
    'Correlation': correlation,
    'Homogeneity': homogeneity
}

# Path presentaseer utama
presentaseer_path = '/content/drive/MyDrive/SKRIPSI1'

# Ambil semua file .jpeg dalam subpresentaseer secara
rekursif

```

```

image_paths = glob.glob(presentaseer_path + '/*/*/*.jpg',
recursive=True)

# Cek dan proses
if len(image_paths) == 0:
    print("❌ Tidak ada gambar .jpg ditemukan dalam
subpresentaseer SKRIPSIJANTUNG.")
else:
    print(f"✅ {len(image_paths)} gambar ditemukan.
Memproses...")

features_list = []
for path in image_paths:
    features = extract_texture_features(path)
    if features:
        features_list.append(features)

df = pd.DataFrame(features_list)
output_path = os.path.join(presentaseer_path,
'hasil_ekstraksi_histogram_xray.csv')
df.to_csv(output_path, index=False)
print(f"✅ File CSV berhasil disimpan di: {output_path}")

```

Lampiran 4. Hasil Klasifikasi Ciri Tekstur

Histogram_GLCM pada Python

Klasifikasi	Mean	Variance	Std_Dev	Skewness	Kurtosis	Entropy	Contrast	Energy	Correlation	Homogeneity
Normal	173.634232	1904.176094	43.688662	-0.360555223	2.047220151	7.28771463	26.6199591	0.00057888	0.993016121	0.37743612
Normal	165.232636	2675.32374	51.725318	-0.44755729	2.394547318	7.57603551	30.98282966	0.00040498	0.994204713	0.363910231
Normal	164.634396	2418.040658	49.1735768	-0.229126941	2.081835648	7.51547337	35.26189579	0.00037896	0.992694104	0.345389251
Normal	167.90328	2343.213845	48.4067541	-0.431869552	2.079262125	7.42172601	26.38859719	0.000556754	0.99436355	0.379799068
Normal	167.910092	2346.122417	48.4367878	-0.503977176	2.1771101787	7.37682175	26.26650501	0.000622587	0.994405459	0.389441346
Normal	168.963564	2395.236748	48.941156	-0.394763138	2.312102862	7.49912973	29.06122645	0.00043594	0.993929056	0.365142053
Normal	163.40414	2241.539795	47.3449025	-0.350336955	2.258167949	7.47196196	29.34767134	0.000448646	0.993452532	0.370111467
Normal	169.235256	2571.395847	50.7089326	-0.412113299	2.01760464	7.47064385	29.45663727	0.000534178	0.994276184	0.381907006
Normal	168.052608	2535.003632	50.3488196	-0.434321086	2.177357705	7.5168198	27.71629659	0.000464707	0.994537424	0.379716491
Normal	169.944212	2272.776652	47.6736474	-0.62568973	2.52984767	7.37280057	23.04911423	0.000644957	0.99492734	0.406154772
Normal	161.224952	2333.293797	48.3041799	-0.205879259	2.124338062	7.51900484	34.33503407	0.000377918	0.992632195	0.349166206
Normal	160.364732	2563.799743	50.6339781	-0.188845891	1.992768437	7.56475854	34.59704208	0.000353269	0.993251246	0.342687867
Normal	168.499752	2167.52788	46.5651168	-0.448317493	2.190621634	7.35210313	32.36061323	0.000671753	0.994615788	0.41182861
Normal	163.110508	2450.534264	49.5028713	-0.377411491	2.032035568	7.40246439	27.80201202	0.000615433	0.994331704	0.382480611
Normal	170.44652	2637.728308	51.3588192	-0.402379361	2.052669841	7.49930764	31.22628056	0.000459977	0.994081605	0.364284112
Normal	162.90804	2412.143599	49.1135786	-0.167617947	1.993930189	7.52115289	32.81828858	0.000373663	0.993187409	0.345564046
Normal	168.168208	2459.272071	49.5910483	-0.372731751	2.364910487	7.50187869	27.9080521	0.00045586	0.994327512	0.374688237
Normal	168.86576	2156.00338	46.4327835	-0.293400833	2.1032543	7.44726437	28.34758177	0.000431715	0.993423169	0.361946708
Normal	170.680552	2614.987377	51.1369473	-0.371464715	2.002933109	7.47426429	29.59117836	0.000594427	0.995490447	0.385113253
Normal	167.392072	2176.982792	46.6581482	-0.404821851	2.181500089	7.30297218	25.33192385	0.000597881	0.994182788	0.389384169
Normal	163.109028	2356.096116	48.9536345	-0.247621686	2.341933258	7.53656032	35.58521844	0.000559825	0.994234309	0.389997704
Normal	159.2188	2230.093023	47.2238607	-0.313241066	2.226946183	7.45939079	32.86322244	0.000417431	0.992610578	0.35338532
Normal	143.778804	2402.458152	50.350936	0.009364109	1.87348225	7.7456969	50.46589178	0.00024299	0.992516765	0.298828964
Normal	157.998636	3163.08461	56.241307	-0.513330979	2.154232392	7.62317956	37.72721448	0.000400604	0.994022118	0.343309961
Normal	166.50054	2517.022872	50.1699399	-0.343067428	2.065206452	7.51748448	34.41207214	0.000412069	0.993159415	0.354953161
Normal	154.555224	2311.96127	48.0828684	-0.074139345	1.994820516	7.4904944	37.2498477	0.000354705	0.991398684	0.337019445
Normal	173.823436	2420.915797	49.2028027	-0.606036299	2.623249944	7.45426985	25.80842866	0.000516406	0.994661877	0.378322177
Normal	152.565564	3163.210136	56.2434229	-0.34339394	2.066484345	7.69022492	39.66773547	0.000297885	0.993735828	0.318085904
Normal	171.489832	2448.973583	49.4871052	-0.453650996	2.180751085	7.46701542	31.56659719	0.000463394	0.9935375	0.361919055
Normal	176.344676	2396.947514	48.9586306	-0.431183695	2.075725693	7.39051676	23.89466693	0.00063395	0.995017253	0.391211968
Normal	169.938676	2296.268813	47.9193991	-0.421136716	2.356472336	7.47960471	27.08994389	0.000452203	0.994100773	0.377086121
Normal	168.568876	2548.833488	50.4859732	-0.359833801	1.985906415	7.46414497	29.70639279	0.000522845	0.994172425	0.377599782
Normal	166.78526	2851.809315	53.6041999	-0.403263928	2.06442079	7.51898938	31.38436437	0.000394106	0.994405702	0.349428053
Normal	170.390288	2374.257564	48.7263535	-0.288482542	1.951073769	7.45286977	29.51686373	0.000766429	0.993966848	0.35153202
Normal	163.463276	2391.152659	48.8994137	-0.377122951	1.964803542	7.40940553	33.12918637	0.000522123	0.993055648	0.366140572
Normal	168.99176	2182.477804	46.716997	-0.592066168	2.72820252	7.3478338	23.16486172	0.000708093	0.994966456	0.415093941
Normal	170.055508	2440.145171	49.397256	-0.44930935	2.187379873	7.47668914	26.83332469	0.000459256	0.994498688	0.365374077
Normal	161.105908	2485.072243	49.054989	-0.45525342	2.651527931	7.49975845	24.75944289	0.0005206	0.995014979	0.39685919
Normal	158.235464	2393.750845	48.9259731	-0.122247872	2.179727196	7.53921553	37.29844088	0.000326942	0.993124806	0.32344064
Normal	169.785956	2436.461037	49.360521	-0.368796597	2.022382087	7.46117431	30.50632064	0.000464567	0.993742496	0.363272428
Normal	168.700696	2421.886993	49.2126711	-0.473508606	2.20947504	7.47807726	29.55138677	0.000478973	0.993899901	0.367391551
Normal	165.457476	2392.287208	48.9110132	-0.538914331	2.461284824	7.44483557	25.18113427	0.000635616	0.994736453	0.405515244
Normal	163.97104	2440.435673	49.4007659	-0.107094926	1.750315154	7.44920945	26.36862926	0.000426297	0.994597097	0.357764637
Normal	151.200456	3424.488017	58.5191252	-0.301193077	1.880946801	7.67907824	39.94683367	0.000329674	0.994168642	0.322288228
Normal	175.503104	2399.438454	48.9640633	-0.411693035	1.980715152	7.38277423	32.55285772	0.00064939	0.99509496	0.386848221
Normal	163.7164	2258.743531	47.562404	-0.211653033	1.954933762	7.41103321	28.38737948	0.000529784	0.993715987	0.377965958
Normal	167.226004	2481.415422	49.8138075	-0.529807459	2.42551906	7.49337339	27.07894589	0.000473384	0.994535299	0.371934999
Normal	170.37112	2543.965718	50.377741	-0.674748232	2.574642928	7.41578063	24.30009218	0.000634374	0.995221481	0.400966978
Normal	161.89902	2528.594087	50.2851279	-0.289954403	2.301805864	7.5767256	35.49662124	0.00034947	0.99259574	0.338821596
Normal	166.848392	2406.117799	49.0521946	-0.387681535	2.135893391	7.494914	33.85528657	0.000405929	0.992968666	0.349467741
Cardiomegaly	163.059832	2502.227612	50.0222712	-0.574870047	2.586320387	7.55298333	25.91685772	0.000575279	0.994826818	0.397025415
Cardiomegaly	170.021952	3617.656902	60.1469609	-0.547908874	2.03336164	7.53036337	19.03842084	0.000895758	0.997370715	0.428760048
Cardiomegaly	188.737616	3103.252483	55.7068441	-0.960788556	2.790634189	7.15528987	13.08472545	0.002304348	0.99789391	0.409002867
Cardiomegaly	154.99942	1536.376372	39.6696372	-0.55125283	2.317602742	7.12280872	19.23450902	0.000515541	0.993736509	0.414943103
Cardiomegaly	178.357384	2072.144653	45.5208156	-0.854373682	2.900129795	7.28085283	9.53292796	0.00124909	0.997700771	0.487440473
Cardiomegaly	167.123604	2087.897206	45.6935138	-0.62171162	2.768141519	7.42905674	10.40225651	0.000628923	0.995435658	0.415354992
Cardiomegaly	142.525312	3068.572399	55.3946965	-0.98898682	1.889249693	7.61882233	21.28547495	0.000517812	0.996534854	0.39558297
Cardiomegaly	163.893716	1154.176398	33.7737115	-0.2986203631	3.129683102	6.84024613	31.135938277	0.001328049	0.990753514	0.417607252
Cardiomegaly	157.574868	2585.082851	50.84371	-0.512842503	2.346738568	7.5328462	32.15669339	0.000573774	0.993772134	0.391529324
Cardiomegaly	142.220244	2578.162489	50.7756092	-0.433157287	2.350950952	7.6000146	14.35892184	0.000466556	0.995861248	0.385139216
Cardiomegaly	138.247188	3636.755326	60.3055165	-0.177971695	1.827428893	7.76593602	23.8333467	0.000372344	0.996726113	0.370839887
Cardiomegaly	143.198748	1448.781271	38.0628955	-0.720832815	7.15977669	9.73740206	0.001251811	0.99667639	0.947580169	0.52442352
Cardiomegaly	166.192464	1819.403382	42.654465	-0.319850991	2.305486629	7.36157178	12.99874549	0.000835627	0.996427016	0.452442352
Cardiomegaly	145.224388	3629.168302	60.2425788	-0.355376871	1.924542091	7.71389299	22.6658116	0.000472616	0.996933026	0.389296378
Cardiomegaly	167.71446	1797.984007	42.4026415	-0.470003306	2.628178585	7.34235468	20.3879198	0.000669244	0.9943158	0.41268401
Cardiomegaly	159.975292	3226.388162	58.8012489	-0.487021269	1.950722119	7.51228857	19.84335471	0.000709933	0.996926778	0.408280736
Cardiomegaly	184.37874	1633.516024	40.161779	-0.957303981	3.584595327	7.18352611	8.273707415	0.001414103	0.997470928	0.514112942
Cardiomegaly	172.978916	1747.554599	41.803763	-0.531898119	2.684532476	7.32180893	6.47412024	0.001019134	0.998150277	0.504745938
Cardiomegaly	149.294424	3020.993395	54.9635642	-0.269572006	1.887512874	7.57879774	26.88809218	0.000533904	0.995548833	0.380318844
Cardiomegaly	159.472116	3056.153046	55.2824841	-0.605762665	2.365255886	7.59366194	17.1836513	0.000592545	0.997195251	0.418836305

Cardiomegaly	158.383608	3987.855773	63.1494717	-0.512513571	2.080517619	7.733549	18.97579559	0.000549903	0.997623926	0.407642818
Cardiomegaly	169.8817	1629.494257	40.3669947	-0.674491748	2.714352441	7.20643838	19.39044489	0.000967375	0.994052849	0.454583249
Cardiomegaly	151.787072	2463.758238	49.6362593	-0.688199	2.391899911	7.37055979	17.13844489	0.001079869	0.996515652	0.467968638
Cardiomegaly	133.310364	3549.158798	59.5748168	-0.069525574	1.863986755	7.77326727	27.59503808	0.00033841	0.996115484	0.355632387
Cardiomegaly	151.975384	2917.829658	54.0169386	-0.398139268	1.932845164	7.50868067	26.77513828	0.000628907	0.995415878	0.381126938
Cardiomegaly	168.065128	3991.50203	63.1783351	-0.547161344	1.965348397	7.45360562	14.91895391	0.001560528	0.998132474	0.475883446
Cardiomegaly	151.082828	2389.59648	48.8834991	-0.612900479	2.622133366	7.50512276	46.22951102	0.000540037	0.990288371	0.366978457
Cardiomegaly	147.267468	3811.761113	61.7394616	-0.180730196	1.791032999	7.72024487	20.72010822	0.000462452	0.997284384	0.385840889
Cardiomegaly	154.9138	1580.453602	39.7549192	-0.706063559	2.808814512	7.19303163	19.62591182	0.000900156	0.993796198	0.428926893
Cardiomegaly	159.807348	2564.994681	50.6457765	-0.638348982	2.728925393	7.52113592	11.1501483	0.001015223	0.997828923	0.494813947
Cardiomegaly	147.377304	4199.552986	64.8039581	-0.19036683	1.627709124	7.65237243	18.07583166	0.000555096	0.99784939	0.402179725
Cardiomegaly	149.499784	3566.83664	59.7229993	-0.380083184	2.05690912	7.73729495	19.58262926	0.000512748	0.997256903	0.410710573
Cardiomegaly	152.849188	3610.877244	60.0905753	-0.328209531	1.807732227	7.60463592	19.08286573	0.00073459	0.99735773	0.416718415
Cardiomegaly	137.595664	1875.73548	43.309762	-0.375031502	2.369738996	7.40027679	63.11933467	0.00034186	0.983109802	0.308820375
Cardiomegaly	159.149072	3174.28077	56.3407558	-0.564902205	2.272598411	7.63266251	32.48012024	0.000496019	0.994885453	0.377571588
Cardiomegaly	183.95198	1655.670698	40.6899336	-1.028302664	3.622793963	7.15205127	17.08586774	0.001016123	0.994843191	0.431756672
Cardiomegaly	161.337396	1304.371208	36.1160796	-0.721261219	3.108657972	7.0849579	16.18989579	0.000980215	0.993786363	0.436644435
Cardiomegaly	174.184844	2224.549077	47.1651256	-0.863124235	2.922840959	7.34789113	17.28222044	0.000959015	0.996117701	0.439118173
Cardiomegaly	134.49216	2206.670611	46.9752127	-0.338169717	2.246122085	7.45396972	14.85441283	0.000990519	0.996637834	0.497014258
Cardiomegaly	158.856396	2424.00563	49.2341917	-0.446271096	2.433770791	7.55674675	24.17176754	0.000504155	0.995019653	0.391173594
Cardiomegaly	156.406224	3871.201654	62.2189815	-0.614873182	2.134671106	7.63198161	18.55036473	0.000676733	0.99760716	0.412960305
Cardiomegaly	160.975856	2456.662705	49.5647325	-0.646509474	2.489004304	7.43361193	14.04975551	0.000958324	0.997143572	0.455783392
Cardiomegaly	151.350768	1900.22577	43.5915791	-0.496261316	2.570181812	7.37759107	12.90121443	0.000932598	0.996604236	0.4705358
Cardiomegaly	155.08058	3253.493279	57.0394011	-0.423005084	2.0535093	7.61128657	13.56178758	0.000701945	0.997915585	0.433685392
Cardiomegaly	163.460496	2177.411655	46.6627438	-0.636167835	2.877717765	7.42989171	13.66640882	0.000885395	0.996857598	0.46517459
Cardiomegaly	155.766892	3422.231425	58.4998412	-0.623409605	2.225977828	7.59693389	19.44239679	0.000625451	0.997160401	0.406039804
Cardiomegaly	125.049088	3053.01491	55.2540941	-0.120040589	1.933427738	7.7042849	26.29425651	0.000373651	0.99569752	0.372399509
Cardiomegaly	141.945036	3987.692167	63.1481763	-0.278897473	1.904223197	7.7287747	24.86512224	0.000448457	0.996885769	0.384815051
Cardiomegaly	138.397628	3707.392336	60.8883596	-0.207623672	1.859236858	7.75047213	23.09957916	0.000435912	0.996887127	0.382063971
Cardiomegaly	170.549972	1449.367879	38.0705645	-0.799314259	2.674175029	6.97561064	17.48006413	0.001358765	0.99393798	0.427434349

Lampiran 5. Hasil Perhitungan Confussion Matrix Klasifikasi Trainingset dan Testingset

1) Use Trainningset

$$\begin{aligned} Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\ &= \frac{50 + 50}{50 + 50 + 0 + 0} \times 100\% \\ &= 100\% \end{aligned}$$

$$\begin{aligned} Presisi &= \frac{TP}{TP + FP} \times 100\% \\ &= \frac{50}{50 + 0} \times 100\% \\ &= 100\% \end{aligned}$$

$$\begin{aligned} Recall &= \frac{TP}{TP + FN} \times 100\% \\ &= \frac{50}{50 + 0} \times 100\% \\ &= 100\% \end{aligned}$$

2) 10%Percentage split

$$\begin{aligned}Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\&= \frac{45 + 27}{45 + 27 + 16 + 2} \times 100\% \\&= 80\%\end{aligned}$$

$$\begin{aligned}Presisi &= \frac{TP}{TP + FP} \times 100\% \\&= \frac{45}{45 + 16} \times 100\% \\&= 74\%\end{aligned}$$

$$\begin{aligned}Recall &= \frac{TP}{TP + FN} \times 100\% \\&= \frac{45}{45 + 2} \times 100\% \\&= 96\%\end{aligned}$$

3) 20% Percentage Split

$$\begin{aligned} Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\ &= \frac{39 + 32}{39 + 32 + 6 + 3} \times 100\% \\ &= 89\% \end{aligned}$$

$$\begin{aligned} Presisi &= \frac{TP}{TP + FP} \times 100\% \\ &= \frac{39}{39 + 6} \times 100\% \\ &= 87\% \end{aligned}$$

$$\begin{aligned} Recall &= \frac{TP}{TP + FN} \times 100\% \\ &= \frac{39}{39 + 3} \times 100\% \\ &= 93\% \end{aligned}$$

4) 30% Percentage Split

$$\begin{aligned}Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\&= \frac{34 + 29}{34 + 29 + 3 + 4} \times 100\% \\&= 90\%\end{aligned}$$

$$\begin{aligned}Presisi &= \frac{TP}{TP + FP} \times 100\% \\&= \frac{34}{34 + 3} \times 100\% \\&= 92\%\end{aligned}$$

$$\begin{aligned}Recall &= \frac{TP}{TP + FN} \times 100\% \\&= \frac{34}{34 + 4} \times 100\% \\&= 89\%\end{aligned}$$

5) 40%Percentage Split

$$\begin{aligned}Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\&= \frac{29 + 25}{29 + 25 + 2 + 4} \times 100\% \\&= 90\%\end{aligned}$$

$$\begin{aligned}Presisi &= \frac{TP}{TP + FP} \times 100\% \\&= \frac{29}{29 + 2} \times 100\% \\&= 94\%\end{aligned}$$

$$\begin{aligned}Recall &= \frac{TP}{TP + FN} \times 100\% \\&= \frac{29}{29 + 4} \times 100\% \\&= 88\%\end{aligned}$$

6) 50% Percentage Split

$$\begin{aligned}Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\&= \frac{25 + 21}{25 + 21 + 1 + 3} \times 100\% \\&= 92\%\end{aligned}$$

$$\begin{aligned}Presisi &= \frac{TP}{TP + FP} \times 100\% \\&= \frac{25}{25 + 1} \times 100\% \\&= 96\%\end{aligned}$$

$$\begin{aligned}Recall &= \frac{TP}{TP + FN} \times 100\% \\&= \frac{25}{25 + 3} \times 100\% \\&= 89\%\end{aligned}$$

7) 60% Percentage Split

$$\begin{aligned}Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\&= \frac{23 + 15}{23 + 15 + 1 + 1} \times 100\% \\&= 95\%\end{aligned}$$

$$\begin{aligned}Presisi &= \frac{TP}{TP + FP} \times 100\% \\&= \frac{23}{23 + 1} \times 100\% \\&= 96\%\end{aligned}$$

$$\begin{aligned}Recall &= \frac{TP}{TP + FN} \times 100\% \\&= \frac{23}{23 + 1} \times 100\% \\&= 96\%\end{aligned}$$

8) 70% Percentage Split

$$\begin{aligned}Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\&= \frac{17 + 13}{17 + 13 + 0 + 0} \times 100\% \\&= 100\%\end{aligned}$$

$$\begin{aligned}Presisi &= \frac{TP}{TP + FP} \times 100\% \\&= \frac{17}{17 + 0} \times 100\% \\&= 100\%\end{aligned}$$

$$\begin{aligned}Recall &= \frac{TP}{TP + FN} \times 100\% \\&= \frac{17}{17 + 0} \times 100\% \\&= 100\%\end{aligned}$$

9) 80% Percentage Split

$$\begin{aligned}Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\&= \frac{11 + 9}{11 + 19 + 0 + 0} \times 100\% \\&= 100\%\end{aligned}$$

$$\begin{aligned}Presisi &= \frac{TP}{TP + FP} \times 100\% \\&= \frac{11}{11 + 0} \times 100\% \\&= 100\%\end{aligned}$$

$$\begin{aligned}Recall &= \frac{TP}{TP + FN} \times 100\% \\&= \frac{11}{11 + 0} \times 100\% \\&= 100\%\end{aligned}$$

10) 90% Percentage Split

$$\begin{aligned}Akurasi &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\&= \frac{5 + 5}{5 + 5 + 0 + 0} \times 100\% \\&= 100\%\end{aligned}$$

$$\begin{aligned}Presisi &= \frac{TP}{TP + FP} \times 100\% \\&= \frac{5}{5 + 0} \times 100\% \\&= 100\%\end{aligned}$$

$$\begin{aligned}Recall &= \frac{TP}{TP + FN} \times 100\% \\&= \frac{5}{5 + 0} \times 100\% \\&= 100\%\end{aligned}$$

Lampiran 6. Tabel Hasil Klasifikasi Trainingset dan Testingset 70% Percentage Split

1) Trainningset

No	Predicted	Actual	No	Predicted	Actual
1	Normal	Normal	51	Cardiomegaly	Cardiomegaly
2	Normal	Normal	52	Cardiomegaly	Cardiomegaly
3	Normal	Normal	53	Cardiomegaly	Cardiomegaly
4	Normal	Normal	54	Cardiomegaly	Cardiomegaly
5	Normal	Normal	55	Cardiomegaly	Cardiomegaly
6	Normal	Normal	56	Cardiomegaly	Cardiomegaly
7	Normal	Normal	57	Cardiomegaly	Cardiomegaly
8	Normal	Normal	58	Cardiomegaly	Cardiomegaly
9	Normal	Normal	59	Cardiomegaly	Cardiomegaly
10	Normal	Normal	60	Cardiomegaly	Cardiomegaly
11	Normal	Normal	61	Cardiomegaly	Cardiomegaly
12	Normal	Normal	62	Cardiomegaly	Cardiomegaly
13	Normal	Normal	63	Cardiomegaly	Cardiomegaly
14	Normal	Normal	64	Cardiomegaly	Cardiomegaly
15	Normal	Normal	65	Cardiomegaly	Cardiomegaly
16	Normal	Normal	66	Cardiomegaly	Cardiomegaly
17	Normal	Normal	67	Cardiomegaly	Cardiomegaly
18	Normal	Normal	68	Cardiomegaly	Cardiomegaly
19	Normal	Normal	69	Cardiomegaly	Cardiomegaly
20	Normal	Normal	70	Cardiomegaly	Cardiomegaly
21	Normal	Normal	71	Cardiomegaly	Cardiomegaly
22	Normal	Normal	72	Cardiomegaly	Cardiomegaly
23	Normal	Normal	73	Cardiomegaly	Cardiomegaly
24	Normal	Normal	74	Cardiomegaly	Cardiomegaly
25	Normal	Normal	75	Cardiomegaly	Cardiomegaly
26	Normal	Normal	76	Cardiomegaly	Cardiomegaly
27	Normal	Normal	77	Cardiomegaly	Cardiomegaly
28	Normal	Normal	78	Cardiomegaly	Cardiomegaly
29	Normal	Normal	79	Cardiomegaly	Cardiomegaly
30	Normal	Normal	80	Cardiomegaly	Cardiomegaly
31	Normal	Normal	81	Cardiomegaly	Cardiomegaly
32	Normal	Normal	82	Cardiomegaly	Cardiomegaly
33	Normal	Normal	83	Cardiomegaly	Cardiomegaly
34	Normal	Normal	84	Cardiomegaly	Cardiomegaly
35	Normal	Normal	85	Cardiomegaly	Cardiomegaly
36	Normal	Normal	86	Cardiomegaly	Cardiomegaly

37	Normal	Normal	87	Cardiomegaly	Cardiomegaly
38	Normal	Normal	88	Cardiomegaly	Cardiomegaly
39	Normal	Normal	89	Cardiomegaly	Cardiomegaly
40	Normal	Normal	90	Cardiomegaly	Cardiomegaly
41	Normal	Normal	91	Cardiomegaly	Cardiomegaly
42	Normal	Normal	92	Cardiomegaly	Cardiomegaly
43	Normal	Normal	93	Cardiomegaly	Cardiomegaly
44	Normal	Normal	94	Cardiomegaly	Cardiomegaly
45	Normal	Normal	95	Cardiomegaly	Cardiomegaly
46	Normal	Normal	96	Cardiomegaly	Cardiomegaly
47	Normal	Normal	97	Cardiomegaly	Cardiomegaly
48	Normal	Normal	98	Cardiomegaly	Cardiomegaly
49	Normal	Normal	99	Cardiomegaly	Cardiomegaly
50	Normal	Normal	100	Cardiomegaly	Cardiomegaly

2) 70% Percentage Split

No	Predicted	Actual	No	Predicted	Actual
1	Cardiomegaly	Cardiomegaly	16	Normal	Normal
2	Normal	Normal	17	Normal	Normal
3	Normal	Normal	18	Cardiomegaly	Cardiomegaly
4	Cardiomegaly	Cardiomegaly	19	Normal	Normal
5	Cardiomegaly	Cardiomegaly	20	Cardiomegaly	Cardiomegaly
6	Normal	Normal	21	Cardiomegaly	Cardiomegaly
7	Normal	Normal	22	Cardiomegaly	Cardiomegaly
8	Cardiomegaly	Cardiomegaly	23	Cardiomegaly	Cardiomegaly
9	Normal	Normal	24	Normal	Normal
10	Normal	Normal	25	Normal	Normal
11	Cardiomegaly	Cardiomegaly	26	Cardiomegaly	Cardiomegaly
12	Normal	Normal	27	Normal	Normal
13	Normal	Normal	28	Normal	Normal
14	Cardiomegaly	Cardiomegaly	29	Normal	Normal
15	Normal	Normal	30	Cardiomegaly	Cardiomegaly

3) 80% Percentage Split

No	Predicted	Actual	No	Predicted	Actual
1	Cardiomegaly	Cardiomegaly	11	Cardiomegaly	Cardiomegaly
2	Normal	Normal	12	Cardiomegaly	Cardiomegaly
3	Normal	Normal	13	Cardiomegaly	Cardiomegaly
4	Cardiomegaly	Cardiomegaly	14	Normal	Normal
5	Normal	Normal	15	Normal	Normal
6	Normal	Normal	16	Cardiomegaly	Cardiomegaly
7	Normal	Normal	17	Normal	Normal
8	Cardiomegaly	Cardiomegaly	18	Normal	Normal
9	Normal	Normal	19	Normal	Normal
10	Cardiomegaly	Cardiomegaly	20	Cardiomegaly	Cardiomegaly

4) 90% Percentage Split

No	Predicted	Actual	No	Predicted	Actual
1	Cardiomegaly	Cardiomegaly	6	Cardiomegaly	Cardiomegaly
2	Cardiomegaly	Cardiomegaly	7	Normal	Normal
3	Cardiomegaly	Cardiomegaly	8	Normal	Normal
4	Normal	Normal	9	Normal	Normal
5	Normal	Normal	10	Cardiomegaly	Cardiomegaly

Lampiran 7. Daftar Riwayat Hidup

DAFTAR RIWAYAT HIDUP

A. Identitas Diri

Nama Lengkap : Hesti Windyasari
Tempat,Tanggal Lahir : Kendal, 27 OKtober 2002
Jenis Kelamin : Perempuan
Agama : Islam
Alamat Rumah : Dusun Gentan Kidul Rt.06 Rw.04
Desa. Boja Kec. Boja Kab. Kendal Prov.
Jawa Tengah
No Handphone : 085329469299
Email : hestiwindyaa27@gmail.com

B. Riwayat Pendidikan

1. Taman Kanak-Kanak(TK) Bustanul Athfal Weleri
2. Sekolah Dasar Negeri(SDN) 2 Bebenan
3. Sekolah Menengah Pertama(SMP) Negeri 2 Boja
4. Sekolah Menengah Akhir(SMA) Negeri 1 Singorojo

Semarang, 24 Juni 2025

Penulis,

Hesti Windyasari

NIM. 2108026001

Lampiran 8. Persetujuan Pembimbing

PERSETUJUAN PEMBIMBING


Proposal Skripsi ini telah disetujui oleh Pembimbing
untuk dilaksanakan Seminar Proposal.

Disetujui pada

Hari : Rabu,

Tanggal : 15 Januari 2025


Pembimbing I,



Muhammad Ardhi Khalif M.Sc

NIP. 198210092011011010

Pembimbing II,



Irman Said Prastyo M.Sc

NIP. 199112282019031009

Mengetahui,

Ketua Program Studi Fisika



Alwiyah Nurhayati, M.Si, Ph.D

NIP. 19811211 201101 2006

Lampiran 9. Lembar Pengesahan



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI WALISONGO
FAKULTAS SAINS DAN TEKNOLOGI
Jl. Prof. Dr. Hamka Ngaliyan Semarang
Telp. 024-7601295 Fax. 7615387

LEMBAR PENGESAHAN

Naskah proposal skripsi berikut ini:

Judul : **IDENTIFIKASI CITRA X-RAY JANTUNG NORMAL
DAN PEMBESARAN JANTUNG (CARDIOMEGALY)
BERDASARKAN EKSTRAKSI CIRI TEKSTUR
MENGUNAKAN METODE RANDOM FOREST**

Penulis : **Hesti Windyasari**

NIM : **2108026001**

Jurusan : **Fisika**

Telah diujikan dalam sidang proposal skripsi oleh Dewan Penguji
Fakultas Sains dan Teknologi UIN Walisongo dan dapat diterima
sebagai salah satu syarat melanjutkan penelitian.

Semarang, 23 April 2025

DEWAN PENGUJI

Penguji I,

Irman Said Prastyo, M.Sc.
NIP. 199112282019031009

Penguji III,

Sheilla Rully Anggita, M.Si.
NIP. 199005052019032017

Pembimbing I,

Muhammad Ardi Khalif, M.Sc.
NIP. 198210092011011010

Penguji II,

Hartono, M.Sc.
NIP. 199009242019031006

Penguji IV,

Istikomah, M.Sc.
NIP. 199011262019032021

Pembimbing II,

Irman Said Prastyo, M.Sc.
NIP. 199112282019031009