

**DETEKSI OSTEOPOROSIS MENGGUNAKAN *NEURAL NETWORK*
BERDASARKAN ANALISIS TEKSTUR CITRA *DENTAL PANORAMIC*
RADIOGRAPHY (DPR)**

SKRIPSI



**UIN SUNAN AMPEL
S U R A B A Y A**

Disusun Oleh
NILNA ALMUMTAZAH
H92219054

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL
SURABAYA**

2023

PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : NILNA ALMUMTAZAH

NIM : H92219054

Program Studi : Matematika

Angkatan : 2019

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul "DETEKSI OSTEOPOROSIS MENGGUNAKAN *NEURAL NETWORK* BERDASARKAN ANALISIS TEKSTUR CITRA *DENTAL PANORAMIC RADIOGRAPHY* (DPR)". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 11 Januari 2023

Yang menyatakan,



NILNA ALMUMTAZAH

NIM. H92219054

LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

Nama : NILNA ALMUMTAZAH
NIM : H92219054
Judul Skripsi : DETEKSI OSTEOPOROSIS MENGGUNAKAN *NEURAL NETWORK* BERDASARKAN ANALISIS TEKSTUR CITRA *DENTAL PANORAMIC RADIOGRAPHY (DPR)*

telah diperiksa dan disetujui untuk diujikan.

Pembimbing I



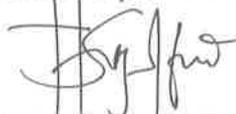
Dian Candra Rini Novitasari, M.Kom
NIP. 198511242014032001

Pembimbing II



Nurissaidah Ulinnuha, M.Kom
NIP. 199011022014032004

Mengetahui,
Ketua Program Studi Matematika
UIN Sunan Ampel Surabaya



Yuniar Farida, M.T
NIP. 197905272014032002

PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama : NILNA ALMUMTAZAH
NIM : H92219054
Judul Skripsi : DETEKSI OSTEOPOROSIS MENGGUNAKAN *NEURAL NETWORK* BERDASARKAN ANALISIS TEKSTUR CITRA *DENTAL PANORAMIC RADIOGRAPHY* (DPR)

Telah dipertahankan di depan Tim Penguji
pada tanggal 16 Januari 2023

Mengesahkan,
Tim Penguji

Penguji I



Aris Fanani, M.Kom
NIP. 198701272014031002

Penguji II



Putrotie Keumala Intan, M.Si
NIP. 198805282018012001

Penguji III



Dian Candra Rini Novitasari, M.Kom
NIP. 198511242014032001

Penguji IV



Nurissaidah Ulinuha, M.Kom
NIP. 199011022014032004

Mengetahui,

Dekan Fakultas Sains dan Teknologi
Universitas Sunan Ampel Surabaya




Depul Hamdani, M.Pd
NIP. 196507312000031002



UIN SUNAN AMPEL
SURABAYA

KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpustakaan@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : NILNA ALMUMTAZAH
NIM : H92219059
Fakultas/Jurusan : SAINTEK / MATEMATIKA
E-mail address : nilnafikida@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Skripsi Tesis Desertasi Lain-lain (.....)
yang berjudul :

DETEKSI OSTEOPOROSIS MENGGUNAKAN NEURAL NETWORK BERDASARKAN

ANALISIS TEKSTUR CITRA DENTAL PANORAMIC RADIOGRAPHY (DPR)

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 25 Januari 2023

Penulis

(NILNA ALMUMTAZAH)
nama terang dan tanda tangan

ABSTRAK

DETEKSI OSTEOPOROSIS MENGGUNAKAN *NEURAL NETWORK* BERDASARKAN ANALISIS TEKSTUR CITRA *DENTAL PANORAMIC* *RADIOGRAPHY (DPR)*

Osteoporosis sebagai salah satu penyakit tulang paling umum mengalami peningkatan kasus secara signifikan setiap tahunnya dikarenakan perubahan gaya hidup serta penuaan populasi yang cepat. Salah satu upaya dalam pencegahan terjadinya osteoporosis adalah dengan melakukan deteksi dini kondisi tulang untuk mengetahui kepadatan mineral tulang (BMD). Citra *Dental Panoramic Radiography (DPR)* merupakan alternatif yang dapat digunakan untuk mengestimasi nilai BMD. Adapun tujuan dilakukannya penelitian ini adalah untuk mengklasifikasikan tulang normal, tulang yang mengalami osteopenia, dan tulang yang mengalami osteoporosis melalui beberapa tahapan diantaranya *preprocessing* dengan melakukan *Region of Interest (RoI)* pada tulang mandibula, ekstraksi fitur tekstur dengan metode *Gray Level Run Length Matrix (GLRLM)* untuk memperoleh nilai vektor fiturnya, klasifikasi menggunakan *Neural Network* metode *Backpropagation*, dan evaluasi sistem menggunakan *confusion matrix multiclass*. Penelitian ini memperoleh hasil yang baik, dimana nilai rata-rata sensitivitas tertinggi sebesar 89.44% dengan nilai rata-rata akurasi dan spesifisitas masing-masing sebesar 89.41% dan 94.84%.

Kata kunci: Backpropagation, Dental Panoramic Radiography, Deteksi, Neural Network, Osteoporosis

ABSTRACT

DETECTION OF OSTEOPOROSIS USING NEURAL NETWORK BASED ON TEXTURE ANALYSIS OF DENTAL PANORAMIC RADIOGRAPHY (DPR) IMAGES

Osteoporosis as one of the most common bone diseases experiences a significant increase in cases every year due to lifestyle changes and rapid aging of the population. One of the efforts to prevent osteoporosis is by early detection of bone conditions to determine bone mineral density (BMD). Dental Panoramic Radiography (DPR) imagery is an alternative that can be used to estimate BMD values. The purpose of this study was to classify normal bones, bones with osteopenia, and bones with osteoporosis through several stages including preprocessing by performing Region of Interest (RoI) on mandibular bones, texture feature extraction using the Gray Level Run Length Matrix (GLRLM) method to obtain feature vector values, classification using the Neural Network Backpropagation method, and system evaluation using a multiclass confusion matrix. This study obtained good results, where the highest average sensitivity value was 89.44% with an average accuracy and specificity value of 89.41% and 94.84%, respectively.

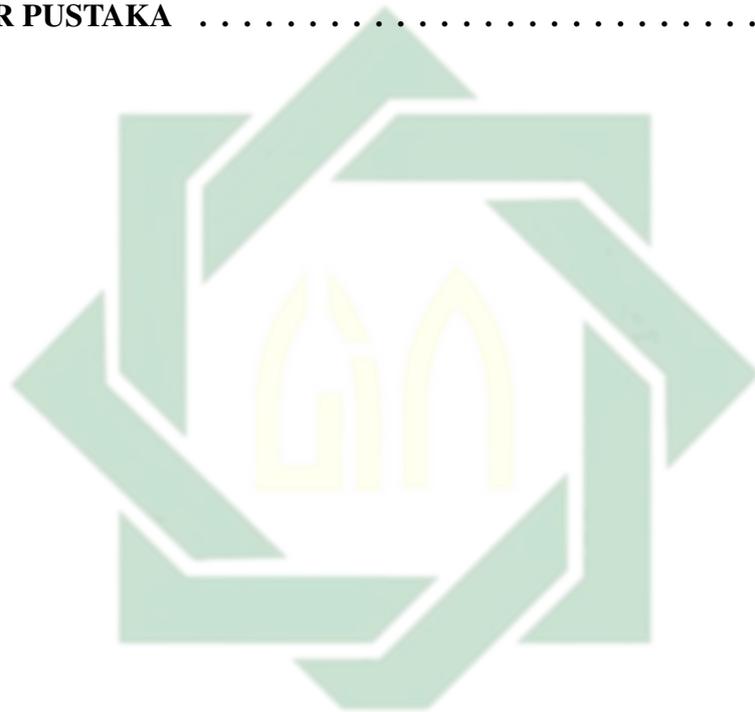
Keywords: Backpropagation, Dental Panoramic Radiography, Detection, Neural Network, Osteoporosis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PERNYATAAN KEASLIAN	ii
LEMBAR PERSETUJUAN PEMBIMBING	iii
PENGESAHAN TIM PENGUJI SKRIPSI	iv
LEMBAR PERSETUJUAN PUBLIKASI	v
ABSTRAK	vi
ABSTRACT	vii
DAFTAR ISI	1
DAFTAR TABEL	4
DAFTAR GAMBAR	5
I PENDAHULUAN	7
1.1. Latar Belakang Masalah	7
1.2. Rumusan Masalah	13
1.3. Tujuan Penelitian	13
1.4. Manfaat Penelitian	14
1.5. Batasan Masalah	14
1.6. Sistematika Penulisan	14
II TINJAUAN PUSTAKA	16
2.1. Osteoporosis	16
2.2. Tulang Mandibula	18
2.3. Citra Digital	19
2.4. <i>Dental Panoramic Radiography</i> (DPR)	20
2.5. <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE)	20
2.6. <i>Region of Interest</i> (RoI)	21
2.7. Augmentasi Data	22
2.8. <i>Gray Level Run Length Matrix</i> (GLRLM)	24
2.8.1. SRE	24

2.8.2. LRE	25
2.8.3. GLN	25
2.8.4. RLN	26
2.8.5. RP	26
2.8.6. LGRE	26
2.8.7. HGRE	27
2.8.8. SRLGE	27
2.8.9. SRHGE	28
2.8.10. LRLGE	28
2.8.11. LRHGE	29
2.9. Normalisasi	29
2.9.1. Normalisasi <i>Min-Max</i>	29
2.9.2. Normalisasi <i>Z-Score</i>	30
2.10. <i>K-Fold Cross Validation</i>	30
2.11. <i>Neural Network</i>	31
2.12. <i>Backpropagation</i>	32
2.13. <i>Confusion Matrix</i>	36
2.14. Integrasi Keislaman	39
III METODE PENELITIAN	43
3.1. Jenis Penelitian	43
3.2. Jenis dan Sumber Data	43
3.3. Kerangka Penelitian	44
3.4. Rancangan Uji Coba	47
IV HASIL DAN PEMBAHASAN	48
4.1. <i>Preprocessing</i>	48
4.1.1. <i>Contrast Limited Adaptive Histogram Equalization (CLAHE)</i>	48
4.1.2. <i>Region of Interest (RoI)</i>	50
4.1.3. Augmentasi	51
4.2. Ekstraksi Fitur Menggunakan Metode GLRLM	51
4.3. Klasifikasi Osteoporosis Menggunakan Metode Backpropagation	70

	3
4.4. Evaluasi Sistem Hasil Klasifikasi Osteoporosis	77
4.5. Aplikasi Deteksi Osteoporosis	87
4.6. Integrasi Keislaman	88
V PENUTUP	91
5.1. Kesimpulan	91
5.2. Saran	92
DAFTAR PUSTAKA	92



UIN SUNAN AMPEL
S U R A B A Y A

DAFTAR TABEL

2.1	Interpretasi Nilai BMD	17
2.2	<i>Confusion Matrix Multiclass</i>	36
4.1	GLRLM Sudut 0	55
4.2	GLRLM Sudut 45	55
4.3	GLRLM Sudut 90	56
4.4	GLRLM Sudut 135	56
4.5	Pembagian Data <i>K-Fold Cross Validation</i>	70
4.6	Bobot dan Bias antara <i>Input dan Hidden Layer</i>	71
4.7	Bobot dan Bias antara <i>Hidden dan Output Layer</i>	71
4.8	<i>Confusion Matrix Multiclass Fold 1</i>	77
4.9	<i>Confusion Matrix Multiclass Fold 2</i>	78
4.10	<i>Confusion Matrix Multiclass Fold 3</i>	78
4.11	<i>Confusion Matrix Multiclass Fold 4</i>	78
4.12	<i>Confusion Matrix Multiclass Fold 5</i>	78
4.13	Hasil Uji Coba Sudut 135° <i>Node Hidden 100 Learning Rate 0.1</i>	81
4.14	Hasil Rata-Rata Uji Coba Sudut 135° <i>Node Hidden 100</i>	82

DAFTAR GAMBAR

2.1	Mikroarsitektur Tulang	17
2.2	Anatomi Tulang Mandibula	19
2.3	Citra DPR	20
2.4	CLAHE Citra DPR	21
2.5	RoI Citra DPR	22
2.6	Augmentasi Warna	23
2.7	Orientasi Arah GLRLM	24
2.8	<i>K-Fold Cross Validation</i>	31
2.9	Ilustrasi Jaringan Saraf	31
2.10	Arsitektur <i>Backpropagation</i>	32
2.11	<i>Confusion Matrix Multiclass</i>	38
3.1	Citra DPR	43
3.2	Diagram Alir Penelitian	44
4.1	CLAHE Citra DPR	48
4.2	Histogram Citra DPR Normal	49
4.3	Histogram Citra DPR Osteopenia	49
4.4	Histogram Citra DPR Osteoporosis	50
4.5	RoI Citra DPR	50
4.6	Augmentasi Warna Berdasarkan Kontras	51
4.7	<i>Boxplot</i> Citra DPR Fitur SRE Semua Sudut	58
4.8	<i>Boxplot</i> Citra DPR Fitur LRE Semua Sudut	59
4.9	<i>Boxplot</i> Citra DPR Fitur GLN Semua Sudut	60
4.10	<i>Boxplot</i> Citra DPR Fitur RLN Semua Sudut	61
4.11	<i>Boxplot</i> Citra DPR Fitur RP Semua Sudut	62
4.12	<i>Boxplot</i> Citra DPR Fitur LGRE Semua Sudut	63
4.13	<i>Boxplot</i> Citra DPR Fitur HGRE Semua Sudut	64

4.14	<i>Boxplot</i> Citra DPR Fitur SRLGE Semua Sudut	65
4.15	<i>Boxplot</i> Citra DPR Fitur SRHGE Semua Sudut	66
4.16	<i>Boxplot</i> Citra DPR Fitur LRLGE Semua Sudut	67
4.17	<i>Boxplot</i> Citra DPR Fitur LRHGE Semua Sudut	68
4.18	Diagram Batang Hasil Fitur	69
4.19	Hasil Rata-Rata Perbandingan <i>Node Hidden</i> Pada <i>K-Fold 5 Hidden Layer 1</i>	83
4.20	Hasil Rata-Rata Perbandingan <i>Node Hidden</i> Pada <i>K-Fold 10 Hidden Layer 1</i>	84
4.21	Hasil Rata-Rata Perbandingan <i>Node Hidden</i> Pada <i>K-Fold 5 Hidden Layer 2</i>	85
4.22	Hasil Rata-Rata Perbandingan <i>Node Hidden</i> Pada <i>K-Fold 10 Hidden Layer 2</i>	86
4.23	Tampilan Awal Aplikasi	87
4.25	Tampilan Kedua Aplikasi	88

UIN SUNAN AMPEL
S U R A B A Y A

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Eksistensi tulang dalam tubuh manusia tak hanya berfungsi sebagai penyangga tubuh, tetapi juga berfungsi sebagai tempat otot untuk melekat dan melindungi organ vital. Tulang berkembang dari masa kanak-kanak hingga dewasa. Meski tulang manusia tampak kuat, namun kesehatannya tetap perlu dijaga karena tulang tidak kebal terhadap penyakit (Fatri and Eviyanti, 2022). Penyakit tulang merupakan suatu kondisi yang merusak kerangka sehingga menyebabkan tulang menjadi rapuh dan rawan patah (Ardhy, 2019). Penyakit tulang sering tidak terdeteksi, menyebabkan penyakit berkembang ke titik dimana tidak lagi dapat diobati. Lansia lebih rentan terkena penyakit tulang, hal ini tertuang pada ayat 4 Al-Qur'an surat Maryam yang berbunyi:

قَالَ رَبِّ إِنِّي وَهَنَ الْعَظْمُ مِنِّي وَتَعَلَ الرَّأْسُ شَيْبًا وَلَمْ أَكُنْ بِدُعَائِكَ رَبَّ شَقِيًّا

artinya: Dia (Zakaria) berkata, "Wahai Tuhanku, sesungguhnya tulangku telah lemah, kepalaku telah dipenuhi uban, dan aku tidak pernah kecewa dalam berdoa kepada-Mu, wahai Tuhanku. (QS. Maryam 19:4).

Salah satu penyakit tulang yang menyerang jutaan orang setiap tahunnya di seluruh dunia adalah osteoporosis (Fan et al., 2021). Osteoporosis termasuk jenis penyakit tidak menular serta merupakan penyakit tulang yang paling umum (Melton et al., 1992). Diperkirakan lebih dari 200 juta orang menderita osteoporosis (Lee et al., 2020) serta lebih dari 8.9 juta kasus patah tulang osteoporosis terjadi setiap tahun di seluruh dunia (Alzubaidi and Otoom, 2020). Persentase pria dan

wanita dengan usia lebih dari 50 tahun yang menderita osteoporosis adalah 6.3% pada pria dan 21.2% pada wanita atau sekitar 1 dari 5 pria dan 1 dari 3 wanita akan menderita patah tulang osteoporosis (International Osteoporosis Foundation, 2022). Secara umum, wanita pascamenopause memiliki risiko lebih tinggi terkena osteoporosis karena hilangnya hormon estrogen setelah menopause (Kementerian Kesehatan Republik Indonesia, 2015).

Osteoporosis termasuk masalah kesehatan masyarakat yang cukup serius karena prevalensinya di seluruh dunia (Silverman, 1979; Genant et al., 1999). Perubahan gaya hidup menjadi salah satu faktor yang mengakibatkan kasus osteoporosis dan patah tulang terus meningkat di masa depan. Sehat dan sakit adalah anugerah dari Tuhan yang tidak dapat dihentikan oleh kekuatan apapun. Namun ketika menerima anugerah penyakit harus tetap berikhtiar semaksimal mungkin dan disertai dengan doa, hasilnya tetaplah ketentuan Tuhan. Ikhtiar dalam Islam sangat dianjurkan untuk membantu penyembuhan sebagaimana firman Allah pada ayat 80 Al-Qur'an surat Asy-Syu'ara:

وَإِذَا مَرِضْتُ فَهُوَ يَشْفِينِ

artinya: “Dan apabila aku sakit, Dialah yang menyembuhkan aku.” (QS. Asy-Syu'ara 26:80).

Berobat hanyalah sebuah ikhtiar, sedangkan yang memberi kesembuhan yakni Allah SWT, bukan obatnya. Anjuran berobat juga diserukan oleh Nabi sebagaimana hadis yang telah diriwayatkan oleh Abu Dawud:

حَدَّثَنَا مُحَمَّدُ بْنُ عَبْدِ الْوَاسِطِيِّ حَدَّثَنَا يَزِيدُ بْنُ هَارُونَ أَخْبَرَنَا إِسْمَاعِيلُ بْنُ عَيَّاشٍ عَنْ ثَعْلَبَةَ بْنِ مُسْلِمٍ عَنْ أَبِي عِمْرَانَ الْأَنْصَارِيِّ عَنْ أُمِّ الدَّرْدَاءِ عَنْ أَبِي الدَّرْدَاءِ قَالَ قَالَ رَسُولُ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ إِنَّ اللَّهَ أَنْزَلَ الدَّاءَ وَالِدَّوَاءَ وَجَعَلَ لِكُلِّ دَاءٍ دَوَاءً فَتَدَاوَوْا وَلَا تَدَاوَوْا بِحَرَامٍ

artinya: Telah menceritakan kepada kami Muhammad bin 'Ubadah Al Wasithi telah menceritakan kepada kami Yazid bin Harun telah mengabarkan kepada kami Isma'il bin 'Ayyasy dari Tsa'labah bin Muslim dari Abu Imran Al Anshari dari Ummu Ad Darda dari Abu Ad Darda ia berkata, "Rasulullah shallallahu 'alaihi wasallam bersabda: "Sesungguhnya Allah telah menurunkan penyakit dan obat, dan menjadikan bagi setiap penyakit terdapat obatnya, maka berobatlah dan jangan berobat dengan sesuatu yang haram!" (HR. Abu Dawud No. 3376).

Salah satu contoh ikhtiar dalam pencegahan osteoporosis yaitu dengan melakukan deteksi dini dari kondisi tulang. Metode deteksi osteoporosis yang sering digunakan adalah pengukuran *Bone Mineral Density* (BMD) atau kepadatan mineral tulang menggunakan *Dual-energy X-ray Absorptiometry* (DXA) (Lee et al., 2020). Namun informasi terkait dengan mikroarsitektur tulang tidak dapat diketahui melalui pengukuran BMD karena DXA hanya mengukur kadar kalsium dan mineral dalam tubuh. Selain itu, tingginya biaya dan terbatasnya ketersediaan pemeriksaan menggunakan alat ini membuat teknik ini kurang efektif (Yu et al., 2019). Sehingga diperlukan opsi deteksi alternatif selain dengan menggunakan alat tersebut. Alternatif lain yang dapat digunakan dalam deteksi osteoporosis yakni *Dental Panoramic Radiography* (DPR).

Citra DPR merupakan salah satu jenis citra *extra-oral* yang sering digunakan oleh dokter gigi sebelum bertindak. Bagian dari citra DPR yang digunakan untuk pemeriksaan osteoporosis adalah tulang kortikal mandibula dan tulang trabekula mandibula (Sela, 2021). Proses deteksi dapat dilakukan dengan mengukur lebar tulang kortikal mandibula dan menganalisis kepadatan tulang trabekula mandibula (Adyanti et al., 2020). Akan tetapi hal tersebut tidak dapat dideteksi oleh DXA, sehingga diperlukan metode lain seperti DPR untuk merepresentasikan

mikroarsitektur tulang sebagai indeks kualitas tulang. Selain itu, citra DPR memiliki biaya yang lebih terjangkau dan tersedia secara luas (Yeung and Mozos, 2020) serta dapat memberikan informasi yang sangat baik untuk deteksi dini osteoporosis (Aliaga et al., 2020). Proses deteksi berdasarkan citra DPR dapat dilakukan dengan menggunakan *machine learning* serta pengolahan citra digital. Risiko kesalahan penentuan osteoporosis dapat diminimalkan, demikian juga biaya diagnosis yang tinggi menggunakan analisis tekstur yang diperoleh menggunakan sistem *Computer Aided Diagnosis* (CAD). CAD memiliki tiga tahap, yaitu *preprocessing*, ekstraksi fitur, dan tahap klasifikasi.

Tahap *preprocessing* bertujuan untuk meningkatkan kualitas citra supaya lebih mudah dalam proses deteksi. Salah satu metode perbaikan kualitas citra yang digunakan untuk meningkatkan kontras adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE). CLAHE merupakan pengembangan dari metode *Adaptive Histogram Equalization* (AHE). Pada studi kasus lain terdapat penelitian yang membandingkan metode HE, AHE, dan CLAHE untuk peningkatan kualitas berbasis histogram pada citra gestur tangan. CLAHE menghasilkan nilai MSE terendah dan nilai PSNR tertinggi pada keempat uji coba, artinya CLAHE merupakan metode yang paling baik dibandingkan HE dan AHE (Yustiantara et al., 2021). Penelitian serupa juga dilakukan oleh Hapsari dkk. dengan menggunakan citra iris diperoleh hasil bahwa metode perbaikan histogram dengan menggunakan CLAHE lebih baik dibandingkan HE dan AHE (Hapsari et al., 2020).

Tahap ekstraksi fitur bertujuan untuk mengambil nilai ciri dari suatu citra. Pada penelitian ini, jenis ekstraksi fitur yang digunakan yaitu ekstraksi fitur tekstur. Terdapat beragam metode untuk analisis tekstur salah satunya yaitu *Gray Level Run Length Matrix* (GLRLM) yang diartikan sebagai fitur statistik tingkat tinggi dengan

menerapkan matriks menunjukkan jumlah *pixel* (jarak) yang tercakup dari *Pixel of Interest* (PoI) ke *pixel* berdasarkan kesamaan nilai intensitas keabuan (Novitasari et al., 2019). Pada permasalahan lain terdapat penelitian yang memprediksi perkembangan *post-endovascular aortic aneurysm repair* dengan membandingkan tiga metode ekstraksi fitur tekstur GLCM, GLDM, dan GLRLM. Pada penelitian tersebut metode GLRLM memperoleh akurasi paling tinggi sebesar 87.23% sedangkan GLCM 85.17% dan 86.09% untuk GLDM (Ding et al., 2020). Metode GLRLM juga pernah dikombinasikan dengan metode GLCM dan mendapatkan hasil yang lebih baik dibandingkan hanya menggunakan GLCM saja (Chandraprabha and Akila, 2019).

Tahap klasifikasi bertujuan untuk mendeteksi apakah citra tersebut merupakan citra normal, citra osteopenia, atau citra osteoporosis. Salah satu metode klasifikasi adalah *Neural Network* atau Jaringan Saraf Tiruan (JST) metode *Backpropagation*. *Backpropagation* ini dikenal dengan *multilayer perceptron*, yang terdapat banyak *hidden layer* untuk meng-*update* nilai bobot (Fitri et al., 2021). Algoritma *Backpropagation* akan menunjukkan hasil kinerja yang lebih bagus karena dilakukan latihan yang berulang-ulang. *Backpropagation* memiliki tiga tahap yaitu *feed forward*, *backward*, dan *update* bobot bias. Pada studi kasus lain terdapat penelitian-penelitian yang mengimplementasikan metode *Backpropagation* seperti penelitian terkait pengklasifikasian citra daun herbal berdasarkan ekstraksi ciri bentuk dengan model jaringan 2-10-5-1 menghasilkan akurasi sebesar 88.75% (Herdiansah et al., 2022). Penelitian terkait pengklasifikasian mutu buah naga putih berdasarkan ekstraksi fitur bentuk dengan menggunakan model arsitektur jaringan 5-8-5-3 diperoleh akurasi pengujian terbaik sebesar 86,67% (Fitri et al., 2021). Penelitian yang dilakukan oleh Wisudawati, dkk. terkait klasifikasi tumor payudara

berdasarkan ekstraksi fitur tesktur citra mammogram juga menggunakan metode *Backpropagation* yang mana pada penelitian tersebut diperoleh akurasi sebesar 95.83% (Wisudawati et al., 2021).

Penelitian terkait dengan perbandingan metode *Backpropagation* dengan metode lain pernah dilakukan oleh Yunarto, dkk. yang membandingkan metode *Backpropagation* dengan metode *Support Vector Machine* (SVM), pada studi kasus pengenalan jenis biji jagung menggunakan ekstraksi fitur tekstur dengan perolehan akurasi sebesar 97.5% untuk metode *Backpropagation* sedangkan untuk metode SVM sebesar 97.1% (Yunarto et al., 2020). Metode *Backpropagation* juga pernah dibandingkan dengan metode *Learning Vector Quantization* (LVQ) untuk pengenalan pola bangun datar geometri. Pada penelitian tersebut metode *Backpropagation* tidak hanya unggul dalam hasil akurasi namun juga unggul dalam waktu proses pelatihan yang lebih cepat dibandingkan metode LVQ pada (Hendriyani, 2020). Selain itu terdapat penelitian yang membandingkan metode *Backpropagation* dengan metode SVM dan *Probabilistic Neural Network* (PNN) untuk mendeteksi tumor otak berdasarkan ekstraksi fitur tekstur citra MRI otak dimana metode *Backpropagation* lebih unggul dengan akurasi sebesar 93% sedangkan SVM dan PNN masing-masing sebesar 87% dan 89% (Ayyappa et al., 2020). Penelitian yang dilakukan oleh Napoleon dan Kalaiarasi membandingkan metode *Backpropagation* dengan metode *Linear Discriminant Analysis* (LDA) dan SVM untuk mengklasifikasikan kanker paru berdasarkan data *chest X-Ray* dengan hasil akurasi terbaik pada *Backpropagation* sebesar 87.5% menggunakan model jaringan 8-6-2 (Napoleon and Kalaiarasi, 2022). Metode *Backpropagation* pada penelitian yang dilakukan Ghazal, dkk. dibandingkan dengan lima metode lain untuk klasifikasi 30 jenis buah menggunakan kombinasi ekstraksi fitur warna, tekstur, dan bentuk. Kelima metode tersebut diantaranya

metode SVM, LDA, *Naïve Bayes* (NB), *K-Nearest Neighbor* (KNN), dan *Decision Tree* (DT) dengan akurasi terbaik *Backpropagation* sebesar 100% (Ghazal et al., 2021).

Berdasarkan permasalahan di atas serta pembahasan penelitian terdahulu, peneliti akan menggunakan *Neural Network* metode *Backpropagation* untuk mengklasifikasikan data citra DPR tulang mandibula dan analisis tekstur untuk menentukan kepadatan tulang. Sebagaimana yang telah diketahui bahwa osteoporosis merupakan salah satu penyakit yang telah mempengaruhi jutaan orang di dunia, oleh karena itu berbagai tindakan medis dilakukan untuk menekan kasus osteoporosis. Salah satu tindakan yang dilakukan adalah dengan melakukan deteksi dini sehingga pasien dapat diberikan penanganan secara cepat dan tepat. Deteksi dini penting dilakukan karena apabila telah terjadi patah tulang dapat dikatakan sudah sangat terlambat untuk dilakukan pencegahan serta membutuhkan biaya perawatan yang tidak sedikit dan dapat berisiko kematian.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan, peneliti merumuskan masalah sebagai berikut:

1. Bagaimana hasil ekstraksi fitur tesktur citra DPR menggunakan metode GLRLM?
2. Bagaimana hasil klasifikasi tulang normal, tulang osteopenia, dan tulang osteoporosis menggunakan *Neural Network* metode *Backpropagation*?

1.3. Tujuan Penelitian

Berdasarkan rumusan masalah yang ada, maka tujuan dari penelitian ini adalah sebagai berikut:

1. Mengetahui hasil ekstraksi fitur tekstur citra DPR menggunakan metode GLRLM.
2. Mengetahui hasil klasifikasi tulang normal, tulang osteopenia, dan tulang osteoporosis menggunakan *Neural Network* metode *Backpropagation*.

1.4. Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah sebagai berikut:

1. Menambah wawasan terkait model GLRLM dan *Neural Network* metode *Backpropagation*.
2. Memberikan alternatif bagi tenaga medis untuk deteksi osteoporosis.
3. Menambah literatur penelitian selanjutnya.

1.5. Batasan Masalah

Adapun batasan masalah dari penelitian ini adalah sebagai berikut:

1. Data pada penelitian ini adalah data citra DPR bagian tulang mandibula dengan tiga kelas yaitu tulang normal, tulang osteopenia, dan tulang osteoporosis.
2. Ekstraksi fitur tekstur dilakukan dengan menggunakan metode GLRLM.
3. Uji coba yang akan dilakukan adalah sudut GLRLM, pembagian data dengan *k-fold cross validation*, jumlah *hidden layer*, jumlah *node* pada *hidden layer*, dan uji coba nilai *learning rate*.

4. *Output* dari penelitian ini berupa informasi hasil klasifikasi penyakit osteoporosis menggunakan *Neural Network* metode *Backpropagation*.

1.6. Sistematika Penulisan

Bagian ini berisi tentang paparan garis-garis besar isi tiap bab.

1. BAB I PENDAHULUAN

Meliputi latar belakang masalah mengenai osteoporosis, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, dan sistematika penulisan.

2. BAB II TINJAUAN PUSTAKA

Mencakup dasar teori osteoporosis, pengolahan citra berupa *preprocessing*, ekstraksi fitur tekstur GLRLM, *Neural Network*, *Backpropagation*, dan evaluasi sistem dengan *confusion matrix multiclass* serta integrasi keislaman terkait penelitian ini.

3. BAB III METODE PENELITIAN

Meliputi jenis penelitian, sumber data yang digunakan, kerangka penelitian yang terdiri dari *preprocessing*, ekstraksi fitur tekstur, klasifikasi, serta evaluasi sistem, dan juga rancangan uji coba penelitian yang akan dilakukan.

4. BAB IV HASIL DAN PEMBAHASAN

Mencakup hasil dari *preprocessing*, ekstraksi fitur menggunakan GLRLM, hasil klasifikasi menggunakan *Neural Network* metode *Backpropagation*, evaluasi menggunakan *confusion matrix multiclass*, aplikasi deteksi, dan integrasi keislaman serta analisis dari hasil-hasil yang didapat untuk menjawab rumusan masalah.

5. BAB V PENUTUP

Meliputi kesimpulan dari penelitian yang menjawab rumusan masalah serta saran kepada para peneliti selanjutnya.



UIN SUNAN AMPEL
S U R A B A Y A

BAB II

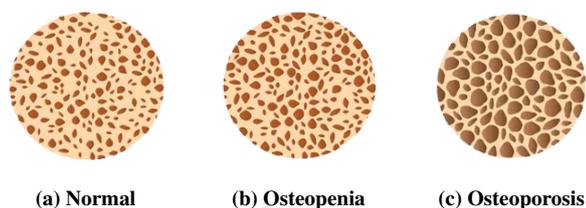
TINJAUAN PUSTAKA

2.1. Osteoporosis

Tulang merupakan jaringan hidup yang memiliki pembuluh darah sendiri dan terdiri dari berbagai protein, mineral, dan vitamin. Struktur ini memungkinkan tulang untuk terus tumbuh, berubah, dan memperbaiki diri sepanjang hidup. Tubuh manusia memiliki lebih dari 200 tulang dengan morfologi dan ukuran berbeda yang dapat menghadirkan fungsi struktural dan melindungi organ vital seperti tulang tengkorak dan tulang dada. Selain itu, tulang bertanggung jawab untuk produksi sel darah dalam sumsum tulang, tempat penyimpanan mineral dan tempat perlekatan untuk otot (Wawrzyniak and Balawender, 2022; Manzini et al., 2021; Venkatraman and Swamiappan, 2020).

Penyakit tulang yang sering terjadi yaitu osteoporosis yang ditandai dengan penurunan massa tulang serta kerusakan mikroarsitektur tulang, sehingga meningkatkan risiko patah tulang (Franciotti et al., 2021; Kathirvelu et al., 2019). Sementara osteopenia ditandai dengan penurunan massa tulang serta berkurangnya kepadatan mineral tulang, yang jika dibiarkan akan berkembang menjadi osteoporosis (Teng et al., 2021). Osteoporosis tidak menunjukkan gejala sampai patah tulang pertama terjadi (Sela and Pulungan, 2019; Yu et al., 2019), sehingga osteoporosis sering disebut sebagai *silent disease* karena banyak orang tidak mengetahui bahwa dirinya menderita osteoporosis (Alzubaidi and Otoom, 2020). Sebagian besar patah tulang osteoporosis terjadi di tulang belakang (*lumbar spine*), paha (*femur*) pergelangan tangan (*karpus*), dan tulang rahang (*mandibula*). Namun

tidak menutup kemungkinan patah tulang osteoporosis juga dapat terjadi pada bagian tulang lainnya.



Gambar 2.1 Mikroarsitektur Tulang

Deteksi pasien dengan risiko tinggi patah tulang saat ini semakin difokuskan salah satunya dengan pengukuran *Bone Mineral Density* (BMD) atau kepadatan mineral tulang. BMD merupakan salah satu komponen risiko patah tulang sehingga untuk mengetahui penilaian risiko patah tulang yang akurat harus mempertimbangkan faktor risiko lain, seperti usia, jenis kelamin, riwayat keluarga, riwayat patah tulang, etnis, alkohol, merokok, gizi buruk, kekurangan vitamin D, gangguan makan, sering jatuh, dan kurang olahraga (Kanis et al., 2005). Tabel 2.1 menunjukkan hasil interpretasi dari pemeriksaan nilai BMD.

Tabel 2.1 Interpretasi Nilai BMD

Nilai BMD	Kategori
Lebih dari -1	Normal
-2.5 sampai dengan -1	Osteopenia
Kurang dari -2.5	Osteoporosis

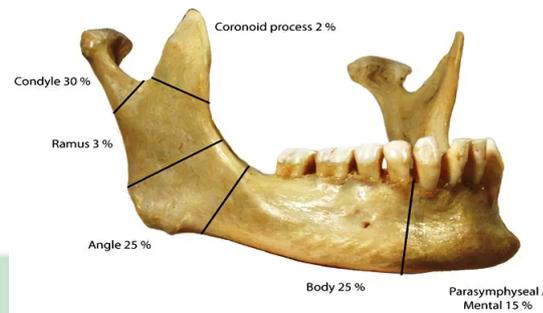
Faktor genetik memang berperan penting dalam peningkatan risiko osteoporosis, namun faktor gaya hidup juga memiliki peranan dalam perkembangan tulang dari masa ke masa. Oleh karena itu, sebagai tindakan pencegahan penting bagi segala usia mulai dari anak-anak sampai dengan lanjut usia untuk memperhatikan hal-hal berikut ini:

1. Diet bergizi dengan asupan kalsium yang cukup
2. Menghindari malnutrisi protein dan kurang gizi
3. Mempertahankan pasokan vitamin D yang cukup
4. Berpartisipasi dalam aktivitas fisik secara teratur
5. Menghindari merokok dan perokok pasif
6. Menghindari minum berat dan teratur
7. Mencegah jatuh
8. Meningkatkan kualitas hidup setelah patah tulang pertama

2.2. Tulang Mandibula

Tulang mandibula atau tulang rahang bawah merupakan bagian dari tulang wajah dan merupakan satu-satunya tulang wajah yang dapat bergerak. Tulang mandibula berkembang dari dua tulang terpisah, yang kemudian menyatu bersama sekitar usia satu tahun. Tulang mandibula memiliki bentuk melengkung seperti pelana kuda yang lebar, pipih, dan mengarah ke atas pada bagian ramus kiri dan kanan sehingga membentuk pilar. Mandibula memiliki banyak fungsi untuk gerakan wajah, seperti berbicara dan menelan, serta memberikan dukungan jalan napas. Posisi tulang mandibula yang menonjol pada tulang wajah mengakibatkan tulang mandibula sering mengalami cedera meskipun tulang mandibula merupakan tulang yang kuat. Selain itu, tulang ini sering mengalami tekanan atau benturan, baik secara sengaja ataupun tidak sengaja. Pola tulang mandibula dapat dikaitkan pada tingkat mikrostruktur kondisi tulang bagian lain dari kerangka dalam tubuh. Terjadinya osteoporosis pada tulang belakang (*lumbar spine*) dan tulang paha (*femur*) akan

memberikan indikasi osteoporosis pada tulang mandibula (Lestari and Utari, 2013). Selain itu, perubahan kecil pada kepadatan tulang mandibula membantu dokter mendeteksi osteoporosis pada tahap awal (Alzubaidi and Ootom, 2020).



Gambar 2.2 Anatomi Tulang Mandibula

Sumber: (Gaillard, 2009)

2.3. Citra Digital

Citra merupakan gambaran atau kemiripan dari suatu objek. Citra analog tidak dapat diolah secara langsung karena tidak dapat ditampilkan di komputer. Sehingga citra analog harus diubah menjadi citra digital, agar komputer dapat memprosesnya. Citra digital merupakan citra yang dapat diproses oleh komputer. Sebuah citra digital diwakili oleh matriks dengan baris M dan kolom N , dimana perpotongan antara baris dan kolom disebut *pixel*. *Pixel* mempunyai dua parameter, yaitu koordinat dan intensitas atau warna. Nilai yang terdapat pada koordinat (x, y) adalah $f(x, y)$, yang merupakan intensitas atau warna *pixel* pada titik itu (Andono et al., 2017).

Citra digital dibagi menjadi tiga jenis berdasarkan tingkat warnanya, diantaranya adalah: citra RGB, citra *grayscale*, dan citra biner. Citra RGB memiliki masing-masing *pixels* warna dalam tiga komponen, yaitu *red*, *green*, dan *blue*. Nilai setiap *pixel* berkisar antara 0 hingga 255. Oleh karena itu, warna yang ditampilkan adalah $225 \times 225 \times 225$. Citra *grayscale* adalah citra yang memiliki warna dari putih

yang bergradasi hingga menjadi hitam. Nilai dari setiap *pixel*-nya berkisar dari 0 yang berwarna hitam hingga 255 yang berwarna putih. Sedangkan citra biner merupakan citra yang setiap *pixel*-nya hanya berwarna hitam atau putih. Sehingga, setiap *pixel*-nya mempunyai dua nilai saja, dimana warna hitam bernilai 0 dan warna putih bernilai 1.

2.4. Dental Panoramic Radiography (DPR)

Radiografi panoramik adalah teknik sinar-X yang digunakan untuk menampilkan struktur gigi dan rahang, termasuk rahang atas (*maxilla*) dan rahang bawah (*mandibula*) serta struktur penunjangnya (Adyanti et al., 2020). Radiografi panoramik merupakan salah satu sinar-X *extra-oral* yang mana detektor film terdapat di dalam mesin, sedangkan pada sinar-X *intra-oral* penempatan detektor film terletak di dalam mulut. Salah satu kelebihan citra DPR adalah pancaran radiasi yang relatif kecil dimana untuk satu kali foto menggunakan citra DPR jumlah radiasi yang diterima pasien setara dengan jumlah radiasi empat kali foto menggunakan *intra-oral* (Wulandari et al., 2019). Hasil dari citra DPR juga tidak mengubah anatomi tulang rahang yang sebenarnya.



Gambar 2.3 Citra DPR

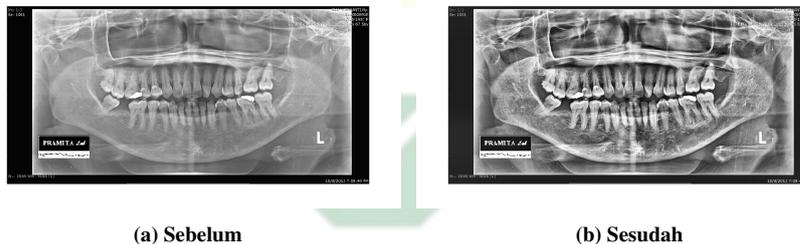
2.5. Contrast Limited Adaptive Histogram Equalization (CLAHE)

CLAHE adalah metode peningkatan kontras yang memperluas HE dan AHE, yang tentunya lebih baik dari HE dan AHE. CLAHE berhasil mengatasi masalah yang dimiliki oleh AHE dengan membatasi *over-enhancement noise* pada citra sehingga menghasilkan citra-citra yang natural (Zakaria and Emran, 2020). Tidak

seperti AHE, CLAHE membatasi kontras dan mengambil nilai maksimum *clip* dan mengubahnya menjadi nilai abu-abu (Erwin and Ningsih, 2020). Pada CLAHE histogram yang dibuat memberikan nilai batas yang merupakan batas maksimum untuk tinggi histogram (Kumbhar and Godbole, 2020). Proses perhitungan CLAHE dihitung dengan *clip limit* histogram, dimana *clip limit* (γ) dihitung dengan persamaan berikut (Abood, 2018; Chang et al., 2018; Saifullah, 2020):

$$\gamma = \frac{K}{L} \left(1 + \frac{c}{100} (s_{max} - 1) \right) \quad (2.1)$$

Pada persamaan 4.1 nilai K merupakan luas *region size*, L merupakan nilai *grayscale*, c merupakan *clip factor* yang memiliki rentang nilai 0 sampai 100, dan s_{max} merupakan kemiringan maksimum. Berikut merupakan gambar citra DPR sebelum dan sesudah melalui proses CLAHE:

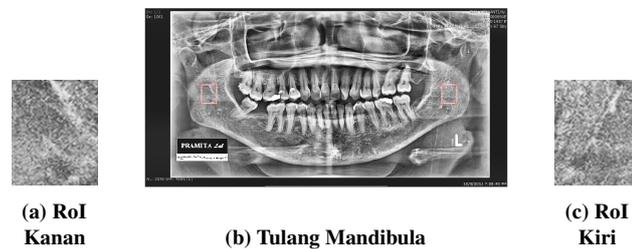


Gambar 2.4 CLAHE Citra DPR

2.6. Region of Interest (RoI)

Salah satu bagian penting dalam mendeteksi menggunakan data citra adalah penggunaan *Region of Interest* (RoI). RoI dapat mendefinisikan objek tertentu dari wilayah yang diamati (Goyal et al., 2017; Zhang and Yang, 2014). Saat mendeteksi osteoporosis, RoI tersegmentasi pada area yang sesuai dengan tulang kortikal, tulang trabekula, dan tulang rawan sendi (Iwaszkiewicz and Leszczyński, 2019). Klasifikasi dapat dilakukan secara mendetail pada area spesifiknya dengan menggunakan RoI. Hal tersebut yang menjadikan peran penting dalam mendeteksi osteoporosis. Contoh

RoI yang digunakan pada DPR dapat dilihat pada gambar berikut:



Gambar 2.5 RoI Citra DPR

Pada Gambar 2.5 di atas dapat dilihat bahwa RoI membatasi daerah mandibula di bawah gigi. Hasil dari pembatasan RoI akan dipotong berdasarkan tulang mandibula kanan dan kiri dengan demikian hasil deteksi akan lebih akurat.

2.7. Augmentasi Data

Augmentasi data merupakan suatu teknik yang digunakan untuk memperkaya jumlah data tanpa menghilangkan esensinya (Sakinah et al., 2020). Proses augmentasi ini dapat membantu model dalam mencegah *overfitting* (Sagar, 2021). Jenis augmentasi pada data citra yang sering digunakan yaitu augmentasi geometris yang disebut juga sebagai augmentasi posisi dan augmentasi warna (Rani, 2021). Teknik augmentasi posisi mempengaruhi posisi nilai *pixel* dari citra asli masukan untuk membuat citra *augmented* (Pandian et al., 2022; Rani, 2021). Sedangkan teknik augmentasi warna menyesuaikan properti warna melalui perubahan nilai *pixel* dari citra asli untuk membuat citra *augmented* (Pandian et al., 2022). Berikut merupakan metode yang digunakan pada augmentasi warna:

1. *Brightness*, berkaitan dengan faktor kecerahan citra untuk membuatnya lebih gelap atau berwarna terang.

$$B(x, y) = A(x, y) \pm \omega \quad (2.2)$$

Dimana apabila nilai ω positif maka kecerahan akan bertambah, sebaliknya jika ω negatif kecerahan akan berkurang.

2. *Contrast*, berkaitan dengan perbedaan kontras di antara bagian-bagian citra yang berbeda.

$$B(x, y) = A(x, y) \cdot \omega \quad (2.3)$$

Dimana apabila nilai $\omega > 1$ maka kontras akan naik, namun jika $\omega < 1$ maka kontras akan turun.

3. *Saturation*, didefinisikan sebagai perbedaan warna di antara berbagai warna *pixel* citra.

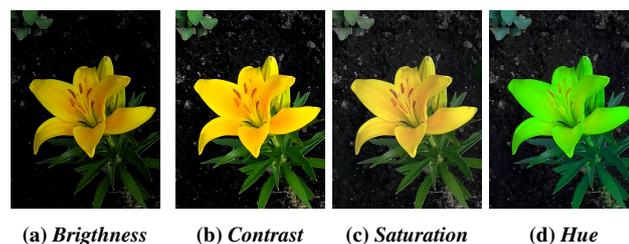
$$S = 1 - \frac{\min(R, G, B)}{\frac{R + G + B}{3}} \quad (2.4)$$

Dimana R, G, B menyatakan *red, green, dan blue*.

4. *Hue*, berkaitan dengan visibilitas bayangan citra dengan mengubah nuansa warna citra.

$$H = \tan\left(\frac{3(G - B)}{(R - G) + (R - B)}\right) \quad (2.5)$$

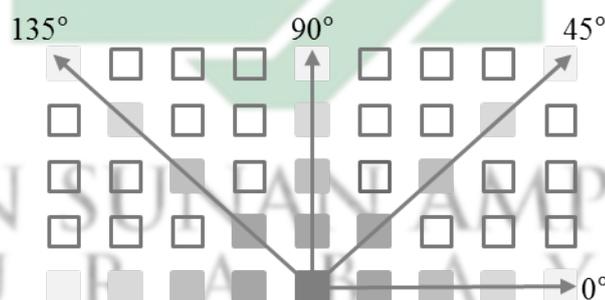
Dimana R, G, B menyatakan *red, green, dan blue*.



Gambar 2.6 Augmentasi Warna

2.8. *Gray Level Run Length Matrix (GLRLM)*

Karakteristik intrinsik suatu citra dalam hal ukuran, keteraturan, dan kekasaran adalah tekstur. Pada citra, tekstur dapat diinterpretasikan berdasarkan nilai keabuan. Pendekatan ekstraksi fitur tekstur secara garis besar dibagi menjadi empat pendekatan, yaitu transformasi, model, struktur, dan statistik (Alaei et al., 2019). Pada penelitian ini, evaluasi statistik tekstur dilakukan dengan GLRLM. *Gray Level Run Length Matrix* atau biasa disebut dengan GLRLM adalah proses ekstraksi fitur menggunakan statistik orde tinggi (Öztürk and Akdemir, 2018).



Gambar 2.7 Orientasi Arah GLRLM

2.8.1. SRE

SRE (*Short Run Emphasis*) menunjukkan distribusi *short run*. SRE merepresentasikan berapa banyak tekstur yang terdiri dari *short run* dalam arah sudut tertentu. Semakin kasar tekstur dari suatu citra maka semakin rendah nilai SRE. Perhitungan SRE dengan menggunakan Persamaan 2.6 (Öztürk and Akdemir,

2018; Mishra et al., 2018; Zhang et al., 2019; Bakhshipour, 2021).

$$SRE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j|\theta)}{j^2} \quad (2.6)$$

Pada Persamaan 2.6 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.2. LRE

LRE (*Long Run Emphasis*) menunjukkan distribusi *long run*. LRE merepresentasikan berapa banyak tekstur yang terdiri dari *long run* dalam arah sudut tertentu. Semakin tinggi nilai LRE, semakin kasar tekstur suatu citra. Perhitungan LRE dengan menggunakan Persamaan 2.7.

$$LRE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R j^2 p(i, j|\theta) \quad (2.7)$$

Pada Persamaan 2.7 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.3. GLN

GLN (*Gray-Level Non-uniformity*) menunjukkan nilai *pixel* yang sama di semua citra sepanjang arah tertentu. Nilai GLN akan semakin rendah jika nilai intensitas keabuan sama di semua citra. Perhitungan GLN dengan menggunakan

Persamaan 2.8.

$$GLN = \frac{1}{N} \sum_{i=1}^G \left(\sum_{j=1}^R p(i, j|\theta) \right)^2 \quad (2.8)$$

Pada Persamaan 2.8 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.4. RLN

RLN (*Run-Length Non-uniformity*) menunjukkan panjang lintasan yang sama di semua citra sepanjang arah tertentu. Nilai RLN akan semakin rendah jika *run length* sama di semua citra. Perhitungan RLN dengan menggunakan Persamaan 2.9.

$$RLN = \frac{1}{N} \sum_{i=1}^R \left(\sum_{j=1}^G p(i, j|\theta) \right)^2 \quad (2.9)$$

Pada Persamaan 2.9 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.5. RP

RP (*Run Percentage*) digunakan untuk mengukur kesamaan dan pembagian *run* dari suatu citra sepanjang arah tertentu. Perhitungan RP dengan menggunakan Persamaan 2.10.

$$RP = \frac{N}{\sum_{i=1}^G \sum_{j=1}^R p(i, j|\theta)} \quad (2.10)$$

Pada Persamaan 2.10 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.6. LGRE

LGRE (*Low Gray-Level Run Emphasis*) menunjukkan distribusi relatif dari nilai intensitas keabuan yang rendah. Perhitungan LGRE dengan menggunakan Persamaan 2.11.

$$LGRE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j | \theta)}{i^2} \quad (2.11)$$

Pada Persamaan 2.11 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.7. HGRE

HGRE (*High Gray-Level Run Emphasis*) menunjukkan distribusi relatif dari nilai intensitas keabuan yang tinggi. Perhitungan HGRE dengan menggunakan Persamaan 2.12.

$$HGRE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R i^2 p(i, j | \theta) \quad (2.12)$$

Pada Persamaan 2.12 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.8. SRLGE

SRLGE (*Short Run Low Gray-Level Emphasis*) menunjukkan distribusi relatif dari *short run* dan nilai intensitas keabuan yang rendah. Perhitungan SRLGE dengan menggunakan Persamaan 2.13.

$$SRLGE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j|\theta)}{i^2 j^2} \quad (2.13)$$

Pada Persamaan 2.13 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.9. SRHGE

SRHGE (*Short Run High Gray-Level Emphasis*) menunjukkan distribusi relatif dari *short run* dan nilai intensitas keabuan tinggi. Perhitungan SRHGE dengan menggunakan Persamaan 2.14.

$$SRHGE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{i^2 p(i, j|\theta)}{j^2} \quad (2.14)$$

Pada Persamaan 2.14 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.10. LRLGE

LRLGE (*Long Run Low Gray-Level Emphasis*) menunjukkan distribusi relatif dari *long run* dan nilai intensitas keabuan yang rendah. Perhitungan LRLGE dengan

menggunakan Persamaan 2.15.

$$LRLGE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{j^2 p(i, j|\theta)}{i^2} \quad (2.15)$$

Pada Persamaan 2.15 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.8.11. LRHGE

LRHGE (*Long Run High Gray-Level Emphasis*) menunjukkan distribusi relatif dari *long run* dan nilai intensitas keabuan yang tinggi. Perhitungan LRHGE dengan menggunakan Persamaan 2.16.

$$LRHGE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R i^2 j^2 p(i, j|\theta) \quad (2.16)$$

Pada Persamaan 2.16 nilai N merupakan jumlah *pixel* dengan G merupakan intensitas tingkat keabuan dan R merupakan panjang lintasan sepanjang arah tertentu θ , adapun i dan j sebagai baris dan kolom.

2.9. Normalisasi

Normalisasi merupakan teknik untuk menskalakan nilai dari fitur sehingga fitur memiliki range nilai yang sama dan lebih kecil (Borkin et al., 2019). Terdapat beberapa jenis normalisasi seperti normalisasi *min-max*, normalisasi *z-score*, dan normalisasi *decimal scaling*.

2.9.1. Normalisasi *Min-Max*

Normalisasi *min-max* merupakan metode normalisasi paling sederhana berdasarkan penskalaan ulang rentang nilai fitur. Pemilihan rentang target tergantung pada sifat data (Borkin et al., 2019). Perhitungan normalisasi *min-max* dengan menggunakan Persamaan 2.17 dan 2.18 (Yamak et al., 2019).

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2.17)$$

$$x' = a + \frac{(x - \min(x))(b - a)}{\max(x) - \min(x)} \quad (2.18)$$

Pada Persamaan 2.17 nilai x merupakan nilai atribut data dan nilai x' merupakan nilai atribut baru hasil normalisasi. Sedangkan pada Persamaan 2.18 diberikan rentang nilai dengan a sebagai nilai *minimum* dan b sebagai nilai *maximum*.

2.9.2. Normalisasi *Z-Score*

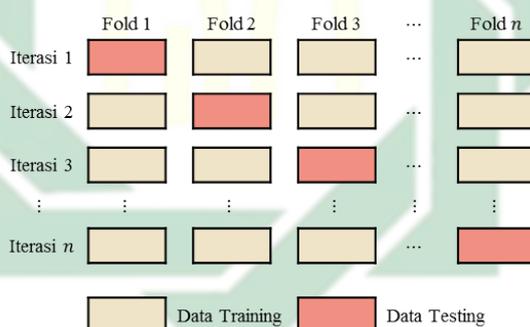
Normalisasi *z-score* merupakan metode normalisasi berdasarkan nilai rata-rata dan standar deviasi dari data dikarenakan nilai minimum dan maksimum dari suatu data tidak diketahui (Henderi et al., 2021; Imron and Prasetyo, 2020). Nilai *z-score* berkisar antara negatif hingga positif tak terhingga. Perhitungan normalisasi *z-score* dengan menggunakan Persamaan 2.19.

$$x' = \frac{x - \mu}{\sigma} \quad (2.19)$$

Pada Persamaan 2.19 nilai x merupakan nilai atribut data, μ merupakan nilai rata-rata, σ merupakan nilai standar deviasi, dan nilai x' merupakan nilai atribut baru hasil normalisasi.

2.10. K-Fold Cross Validation

Cross-validation merupakan metode yang dikembangkan untuk meningkatkan keakuratan proses klasifikasi. *Cross-validation* membagi kumpulan data secara acak ke dalam jumlah tertentu (Koklu and Ozkan, 2020). *K-fold cross validation* membagi kumpulan data menjadi dua subbagian yaitu data *training* dan *testing* sesuai dengan nilai k , dimana data *testing* akan menggunakan 1 bagian sedangkan data *training* menggunakan $k - 1$ sisanya (Pal and Patel, 2020; Saud et al., 2020). Pada metode *k-fold cross validation* seluruh proses diulang sebanyak k kali dengan mengubah data *training* dan *testing*. Proses pembagian data dengan menggunakan *k-fold cross validation* dapat dilihat pada Gambar 2.8.

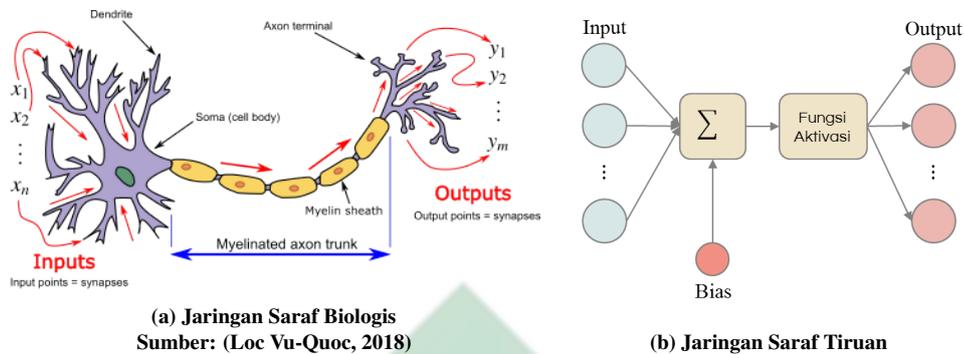


Gambar 2.8 K-Fold Cross Validation

2.11. Neural Network

Neural Network adalah jaringan saraf tiruan yang menyerupai jaringan saraf biologis manusia pada arsitektur *computer* dan arsitektur algoritma baru terhadap *computer* konvensional (Nawawi et al., 2019). Jaringan Saraf Tiruan (JST) memproses informasi dengan sifat yang mirip dengan sistem saraf manusia melalui pelatihan *big data*. JST juga memiliki kemampuan untuk mentolerir kesalahan untuk membuat prediksi yang baik (Putri, 2020). Algoritma *Neural Network* mampu menyelesaikan masalah nonlinear dengan baik menggunakan algoritma pengenalan

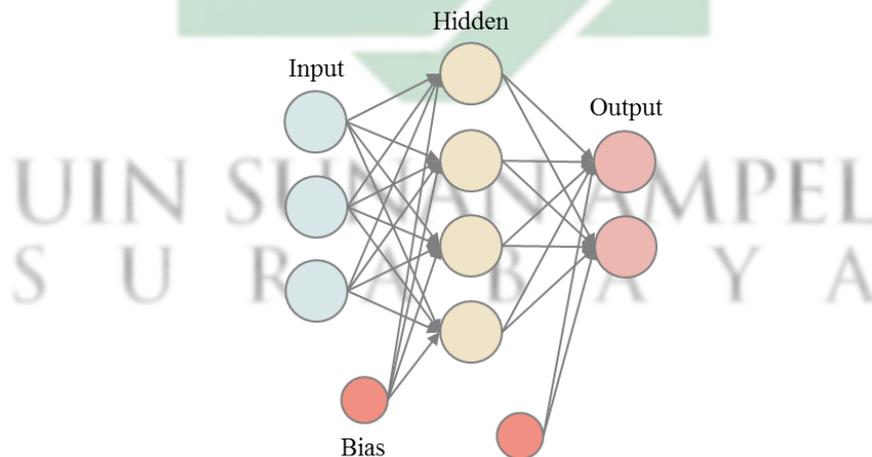
pola (Arsi and Somantri, 2018).



Gambar 2.9 Ilustrasi Jaringan Saraf

2.12. Backpropagation

Backpropagation termasuk *Neural Network* metode *supervised learning* menggunakan jaringan *multilayer* dengan fitur khusus untuk mengurangi *error* pada hasil *output*. Biasanya pada proses klasifikasi menggunakan nilai *output* sistem dan nilai masing-masing *countdown* dalam proses klasifikasi *Backpropagation* untuk mengoreksi bobot berdasarkan nilai *error* (Krismantoro et al., 2021).



Gambar 2.10 Arsitektur *Backpropagation*

Jaringan *Backpropagation* terdiri dari *input layer*, *hidden layer*, dan *output layer*. Sinyal *input* merambat ke arah depan (*forward propagation*). *Backward propagation* terjadi ketika jaringan mengembalikan *output* dengan *error* (Said et al.,

2021). Arsitektur *Backpropagation* dapat diubah dengan menambahkan *hidden layer* dan jumlah *node* pada setiap *layer*.

Perhitungan pada metode *Backpropagation* terdiri dari tiga tahap, yaitu: tahap pertama adalah *feed forward* atau yang biasa disebut dengan *forward propagation* (perambatan maju), tahap kedua adalah *backward* atau yang biasa disebut dengan *backpropagation* (perambatan mundur), dan tahap ketiga adalah *update* bobot. Berikut langkah-langkah proses klasifikasi menggunakan metode *Backpropagation* (Krisnantoro et al., 2021):

1. Inisialisasi bobot awal dengan menggunakan nilai random
2. Tahap *forward propagation* (perambatan maju)
 - (a) Setiap *node input* ($x_i, i = 1, 2, 3, \dots, n$) memperoleh sinyal x_i dan melanjutkan sinyal tersebut ke seluruh *node* pada *hidden layer*.
 - (b) Setiap *node hidden layer* ($z_j, j = 1, 2, 3, \dots, p$) menghitung jumlah bobot sinyal *input*, ditunjukkan pada Persamaan 2.20.

$$z_{inj} = v_{j0} + \sum_{i=1}^n x_i v_{ji} \quad (2.20)$$

Kemudian menggunakan fungsi aktivasi untuk menghitung sinyal *hidden layer*-nya, ditunjukkan pada Persamaan 2.21.

$$z_j = f(z_{inj}) = \frac{1}{1 + \exp^{-z_{inj}}} \quad (2.21)$$

Pada Persamaan 2.20 nilai v_{j0} merupakan bobot bias pada *hidden layer node* ke- j , x_i merupakan data ke- i , dan v_{ji} merupakan bobot data ke- i pada *hidden layer node* ke- j . Sedangkan pada Persamaan 2.21 nilai $f(z_{inj})$ merupakan fungsi aktivasi yang terdapat di *hidden layer*. Adapun fungsi aktivasi yang digunakan adalah fungsi sigmoid.

- (c) Setiap *node output* ($y_k, k = 1, 2, 3, \dots, m$) menghitung jumlah bobot sinyal *hidden layer*, ditunjukkan pada Persamaan 2.22.

$$y_{ink} = w_{k0} + \sum_{j=1}^p z_j w_{kj} \quad (2.22)$$

Kemudian menggunakan fungsi aktivasi untuk menghitung sinyal *output*-nya, ditunjukkan pada Persamaan 2.23.

$$y_k = f(y_{ink}) = y_{ink} \quad (2.23)$$

Pada Persamaan 2.22 nilai w_{k0} merupakan bobot bias pada *node output* ke- k , z_j merupakan *node hidden layer* ke- j , w_{kj} merupakan bobot *node hidden layer* ke- j *node output* ke- k . Sedangkan pada Persamaan 2.23 nilai $f(y_{ink})$ merupakan fungsi aktivasi pada *output layer*. Adapun fungsi aktivasi yang digunakan adalah fungsi linear.

3. Tahap perambatan balik (*backward propagation*)

- (a) Setiap *node output* ($y_k, k = 1, 2, 3, \dots, m$) memperoleh pola target yang sesuai dengan pola *input*, kemudian menghitung nilai *error* ditunjukkan pada Persamaan 2.24.

$$\delta_k = (t_k - y_k) f'(y_{ink}) \quad (2.24)$$

Kemudian menghitung koreksi bobot dan bias ditunjukkan pada Persamaan 2.25 dan 2.26.

$$\Delta w_{kj} = \alpha \delta_k z_j \quad (2.25)$$

$$\Delta w_{k0} = \alpha \delta_k \quad (2.26)$$

Pada Persamaan 2.24 nilai t_k merupakan target pada *node* ke- k , y_k merupakan hasil pada *output layer node* ke- k , dan $f'(y_{ink})$ adalah turunan dari fungsi aktivasi pada *output layer*. Sedangkan pada Persamaan 2.25 dan 2.26 nilai α merupakan *learning rate*, δ_k merupakan nilai *error* pada *output layer node* ke- k , z_j merupakan *output* pada *hidden layer node* ke- j .

- (b) Setiap *node hidden layer* ($z_j, j = 1, 2, 3, \dots, p$) menghitung jumlah nilai *error output*-nya, ditunjukkan pada Persamaan 2.27.

$$\delta_{inj} = \sum_{j=1}^p \delta_k w_{kj} \quad (2.27)$$

Menghitung informasi *error* dengan mengalikan nilai ini dengan turunan dari fungsi aktivasinya, ditunjukkan pada Persamaan 2.28.

$$\delta_j = \delta_{inj} f'(z_{inj}) \quad (2.28)$$

$$f'(z_{inj}) = f(z_{inj}) (1 - f(z_{inj})) \quad (2.29)$$

Kemudian menghitung koreksi bobot dan bias, ditunjukkan pada Persamaan 2.30 dan 2.31.

$$\Delta v_{ji} = \alpha \delta_j x_i \quad (2.30)$$

$$\Delta v_{j0} = \alpha \delta_j \quad (2.31)$$

Pada Persamaan 2.27 nilai δ_k merupakan nilai *error* pada *output layer node* ke- k dan w_{kj} merupakan bobot *node hidden layer* ke- j *node output* ke- k . Nilai δ_{inj} pada Persamaan 2.28 merupakan nilai *error* pada *hidden layer node* ke- j dan $f'(z_{inj})$ merupakan turunan dari fungsi aktivasi pada *hidden layer*. Sedangkan pada Persamaan 2.30 dan 2.31 nilai α

merupakan *learning rate*, δ_{inj} nilai *error* pada *hidden layer node* ke- j , dan x_i merupakan data ke- i .

4. Tahap *update* bobot dan bias

- (a) Setiap *node output* ($y_k, k = 1, 2, 3, \dots, m$) dilakukan *update* bobot dan bias ($j = 0, 1, 2, \dots, p$), ditunjukkan pada Persamaan 2.32.

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} \quad (2.32)$$

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} + \beta \Delta w_{kj}(\text{lama}) \quad (2.33)$$

Setiap *node hidden layer* ($z_j, j = 1, 2, 3, \dots, p$) dilakukan *update* bobot dan bias ($i = 0, 1, 2, \dots, n$) ditunjukkan pada Persamaan 2.34.

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji} \quad (2.34)$$

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji} + \beta \Delta v_{ji}(\text{lama}) \quad (2.35)$$

Pada Persamaan 2.32 nilai w merupakan bobot *hidden layer* pada *output layer*. Sedangkan nilai v pada Persamaan 2.34 merupakan bobot *input layer* pada *hidden layer*. Nilai β pada Persamaan 2.33 dan 2.35 menunjukkan nilai momentum yang berfungsi untuk mempercepat proses pembelajaran.

- (b) Kondisi akan berhenti jika sudah memenuhi batas toleransi.

2.13. *Confusion Matrix*

Confusion matrix merupakan metode untuk mengevaluasi hasil kinerja suatu sistem klasifikasi dengan menginformasikan perbandingan antara kelas prediksi hasil klasifikasi sistem dengan kelas yang sebenarnya (Pi and Lima, 2021). *Confusion matrix multiclass* merupakan *confusion matrix* untuk n kelas yang dapat dilihat pada

Tabel 2.2, dimana i adalah kelas ke- i , j adalah baris ke- j yang merupakan kelas aktual (sebenarnya), dan k adalah kolom ke- k yang merupakan kelas prediksi (hasil klasifikasi sistem).

Tabel 2.2 Confusion Matrix Multiclass

Kelas Aktual	Kelas Prediksi		
	Normal	Osteopenia	Osteoporosis
Normal	x_{11}	x_{12}	x_{13}
Osteopenia	x_{21}	x_{22}	x_{23}
Osteoporosis	x_{31}	x_{32}	x_{33}

Terdapat empat istilah pada *confusion matrix* yang digunakan untuk merepresentasikan hasil proses klasifikasi, diantaranya sebagai berikut:

1. TP (*True Positive*), merupakan jumlah data pada kelas osteoporosis yang terprediksi benar sebagai data pada kelas osteoporosis oleh sistem. Rumus yang digunakan untuk menghitung nilai TP pada *confusion matrix multiclass* ditunjukkan pada persamaan berikut:

$$TP_{all} = \sum_{j=i}^n x_{jj} \quad (2.36)$$

2. FN (*False Negative*), merupakan jumlah data pada kelas osteoporosis yang terprediksi salah sebagai data pada kelas non-osteoporosis oleh sistem. Rumus yang digunakan untuk menghitung nilai FN pada *confusion matrix multiclass* ditunjukkan pada persamaan berikut:

$$FN_i = \sum_{j=1 \ \& \ j \neq i}^n x_{ij} \quad (2.37)$$

3. FP (*False Positive*), merupakan jumlah data pada kelas non-osteoporosis yang terprediksi salah sebagai data pada kelas osteoporosis oleh sistem. Rumus yang digunakan untuk menghitung nilai FP pada *confusion matrix multiclass* ditunjukkan pada persamaan berikut:

$$FP_i = \sum_{j=1 \ \& \ j \neq i}^n x_{ji} \quad (2.38)$$

4. TN (*True Negative*), merupakan jumlah data pada kelas non-osteoporosis yang terprediksi benar sebagai data pada kelas non-osteoporosis oleh sistem. Rumus yang digunakan untuk menghitung nilai TN pada *confusion matrix multiclass* ditunjukkan pada persamaan berikut:

$$TN_i = \sum_{j=1 \ \& \ j \neq i}^n \sum_{k=1 \ \& \ k \neq i}^n x_{jk} \quad (2.39)$$

Kelas Aktual	Kelas Prediksi			Kelas Aktual	Kelas Prediksi		
	Normal	Osteopenia	Osteoporosis		Normal	Osteopenia	Osteoporosis
Normal	TP	FN	FN	Normal	TN	FP	TN
Osteopenia	FP	TN	TN	Osteopenia	FN	TP	FN
Osteoporosis	FP	TN	TN	Osteoporosis	TN	FP	TN

(a) Kelas Normal

(b) Kelas Osteopenia

Kelas Aktual	Kelas Prediksi		
	Normal	Osteopenia	Osteoporosis
Normal	TN	TN	FP
Osteopenia	TN	TN	FP
Osteoporosis	FN	FN	TP

(c) Kelas Osteoporosis

TP	FN	FP	TN
----	----	----	----

Gambar 2.11 *Confusion Matrix Multiclass*

Evaluasi kinerja kuantitatif dari metode yang diusulkan menggunakan metrik evaluasi seperti akurasi, sensitivitas, dan spesifisitas yang dihitung secara statistik

dari *confusion matrix*.

1. Akurasi, merupakan perhitungan untuk mendapatkan hasil keakuratan sistem dalam klasifikasi. Rumus yang digunakan untuk menghitung akurasi pada *confusion matrix multiclass* ditunjukkan pada persamaan berikut:

$$Akurasi = \frac{TP_{all}}{n_{all}} \times 100\% \quad (2.40)$$

2. Sensitivitas, merupakan rasio dari nilai data positif yang diklasifikasikan benar dengan semua data positif. Rumus yang digunakan untuk menghitung sensitivitas pada *confusion matrix multiclass* ditunjukkan pada persamaan berikut:

$$Sensitivitas = \frac{\sum_{i=1}^n \frac{TP_i}{TP_i + FN_i}}{n} \times 100\% \quad (2.41)$$

3. Spesifisitas, merupakan rasio dari nilai data negatif yang diklasifikasikan benar dengan semua data negatif. Rumus yang digunakan untuk menghitung spesifisitas pada *confusion matrix multiclass* ditunjukkan pada persamaan berikut:

$$Spesifisitas = \frac{\sum_{i=1}^n \frac{TN_i}{TN_i + FP_i}}{n} \times 100\% \quad (2.42)$$

2.14. Integrasi Keislaman

Kesehatan merupakan hal yang penting dalam Islam dan merupakan nikmat yang patut disyukuri oleh seluruh umat manusia. Mengenai pentingnya kesehatan, Rasulullah SAW bersabda:

حَدَّثَنَا الْمُتَّقِيُّ بْنُ إِبرَاهِيمَ أَخْبَرَنَا عَبْدُ اللَّهِ بْنُ سَعِيدٍ هُوَ ابْنُ أَبِي هِنْدٍ عَنْ أَبِيهِ عَنْ ابْنِ

عَبَّاسٍ رَضِيَ اللَّهُ عَنْهُمَا قَالَ قَالَ النَّبِيُّ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ نِعْمَتَانِ مَغْبُونٌ فِيهِمَا كَثِيرٌ مِنَ النَّاسِ الصَّحَّةُ وَالْفَرَاغُ قَالَ عَبَّاسُ الْعَنْبَرِيُّ حَدَّثَنَا صَفْوَانُ بْنُ عَيْسَى عَنْ عَبْدِ اللَّهِ بْنِ سَعِيدِ بْنِ أَبِي هِنْدٍ عَنْ أَبِيهِ سَمِعْتُ ابْنَ عَبَّاسٍ عَنِ النَّبِيِّ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ مِثْلَهُ

artinya: Telah menceritakan kepada kami Al Makki bin Ibrahim telah mengabarkan kepada kami Abdullah bin Sa'id yaitu Ibnu Abu Hind dari Ayahnya dari Ibnu Abbas radiallahu 'anhuma dia berkata; Nabi shallallahu 'alaihi wasallam bersabda: "Dua kenikmatan yang sering dilupakan oleh kebanyakan manusia adalah kesehatan dan waktu luang." 'Abbas Al 'Anbari mengatakan; telah menceritakan kepada kami Shufwan bin Isa dari Abdullah bin Sa'id bin Abu Hind dari Ayahnya saya mendengar Ibnu Abbas dari Nabi shallallahu 'alaihi wasallam seperti hadits di atas. (HR. Bukhori No. 5933).

Ada kalanya seseorang memiliki tubuh yang sehat namun tidak memiliki waktu luang. Ada juga yang justru sebaliknya, mempunyai waktu luang namun tubuhnya tidak sehat. Jika seseorang memiliki dua nikmat ini, yaitu kesehatan dan waktu luang, tetapi tidak mensyukuri nikmat tersebut dan melalaikan semua perintah-Nya sehingga kedua nikmat tersebut berlalu dengan sia-sia, maka termasuk orang yang terperdaya (Kiranti et al., 2022). Inti dari hadis tersebut adalah untuk selalu memaksimalkan segala sesuatu ketika masih diberikan nikmat kesehatan dan waktu luang. Namun, ketika seseorang menderita suatu penyakit harus terus mengerahkan dirinya sendiri untuk memulihkan kesehatannya. Salah satunya adalah dengan melakukan pengobatan sebagaimana sabda Rasulullah SAW:

حَدَّثَنَا هَارُونُ بْنُ مَعْرُوفٍ وَأَبُو الطَّاهِرِ وَأَحْمَدُ بْنُ عَيْسَى قَالُوا حَدَّثَنَا ابْنُ وَهْبٍ أَخْبَرَنِي عُمَرُ بْنُ الْوَيْهَقِيِّ وَهُوَ ابْنُ الْحَارِثِ عَنْ عَبْدِ رَبِّهِ بْنِ سَعِيدٍ عَنْ أَبِي الزُّبَيْرِ عَنْ جَابِرٍ عَنْ رَسُولِ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ أَنَّهُ قَالَ لِكُلِّ دَاءٍ دَوَاءٌ فَإِذَا أُصِيبَ دَوَاءُ الدَّاءِ بَرَأَ بِإِذْنِ اللَّهِ عَزَّ وَجَلَّ

artinya: Telah menceritakan kepada kami Harun bin Ma'ruf dan Abu Ath Thahir serta Ahmad bin 'Isa mereka berkata; Telah menceritakan kepada kami Ibnu Wahb; Telah mengabarkan kepadaku 'Amru yaitu Ibnu Al Harits dari 'Abdu Rabbih bin Sa'id dari Abu Az Zubair dari Jabir dari Rasulullah shallallahu 'alaihi wasallam, beliau bersabda: "Setiap penyakit ada obatnya. Apabila ditemukan obat yang tepat untuk suatu penyakit, maka akan sembuhlah penyakit itu dengan izin Allah 'azza wajalla." (HR. Muslim No. 4084)

Berdasarkan hadis di atas, Nabi memerintahkan umatnya untuk berobat setiap kali memiliki penyakit. Berobat tidak menentang tawakkal, sama halnya dengan menolak lapar, haus, panas dan dingin dengan kebalikannya. Ungkapan Nabi "setiap penyakit ada obatnya" mendorong para pasien maupun para dokter yang merawat, serta menganjurkan untuk mencari dan menyelidiki obat-obatan (Arifin and Rachmawati, 2022). Hal ini juga sesuai dengan kaidah fiqih yang berbunyi:

لَا ضَرَرَ وَلَا ضِرَارَ

artinya: "Tidak boleh melakukan sesuatu yang membahayakan diri sendiri ataupun orang lain."

Berdasarkan kaidah tersebut seseorang yang tidak melakukan pengobatan dapat dikatakan membahayakan dirinya sendiri, oleh karena itu penderita osteoporosis perlu melakukan ikhtiar untuk mencegah risiko patah tulang. Salah satu cara yang dapat dilakukan sebagai pencegahan adalah dengan melakukan deteksi dini. Islam memang melarang ramalan tapi memperbolehkan prediksi. Ramalan dilarang keras karena tidak ilmiah dan mendahului kehendak Allah sebagaimana pada ayat 65 Al-Qur'an surat An-Naml yang berbunyi:

قُلْ لَا يَعْلَمُ مَنْ فِي السَّمَوَاتِ وَالْأَرْضِ الْغَيْبَ إِلَّا اللَّهُ وَمَا يَشْعُرُونَ أَيَّانَ يُبْعَثُونَ

artinya: Katakanlah (Nabi Muhammad), "Tidak ada siapapun di langit dan di bumi

yang mengetahui sesuatu yang gaib selain Allah. Mereka juga tidak mengetahui kapan mereka akan dibangkitkan." (QS. An-Naml 27:65)

Berbeda dengan prediksi yang merupakan suatu perkiraan didasarkan pada ilmu pengetahuan atau keilmiahan. Prediksi tetap diperbolehkan dan tidak dilarang selama memiliki manfaat dan kemasalahatan bagi umat. Allah sendiri yang memberi perintah pada ayat 29 Al-Qur'an surat Ar-Rum untuk mengikuti pengetahuan bukan hawa nafsu.

بَلِ اتَّبَعَ الَّذِينَ ظَلَمُوا أَهْوَاءَهُمْ بِغَيْرِ عِلْمٍ فَمَنْ يَهْدِي مَنْ أَضَلَّ اللَّهُ وَمَا لَهُمْ مِنْ تُصْرِينِ

Artinya: "Akan tetapi, orang-orang yang zalim mengikuti hawa nafsunya tanpa (berdasarkan) ilmu. Maka, siapakah yang dapat memberi petunjuk kepada orang yang telah disesatkan Allah? Tidak ada seorang penolongpun bagi mereka." (QS. Ar-Rum 30:29).

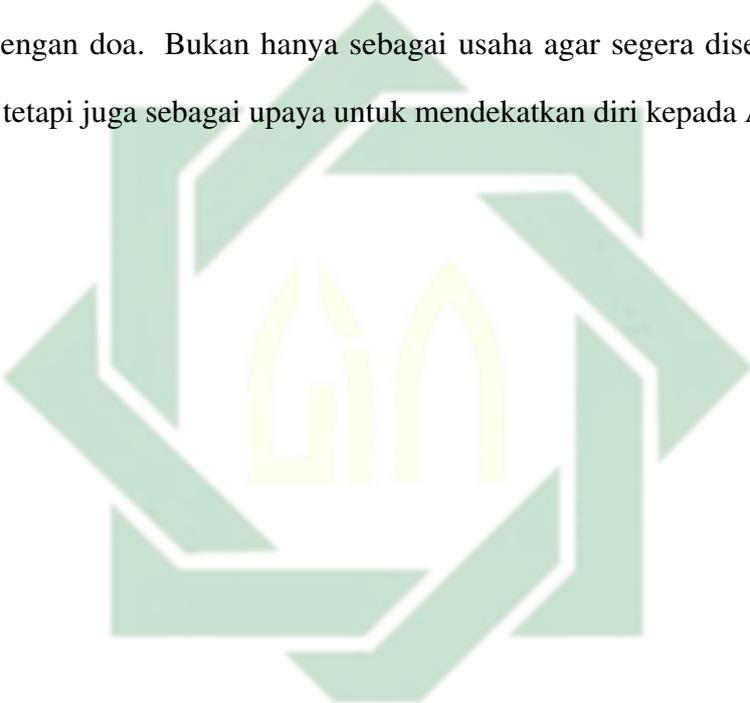
Permasalahan prediksi berdasarkan fakta, data, dan penelitian ilmiah meliputi prediksi hujan, prediksi terjadinya bencana, prediksi kelahiran, prediksi perkembangan penyakit, prediksi status kesehatan, prediksi keuangan, dan prediksi sifat-sifat suatu objek atau alam. Prediksi ini bersifat ilmiah dan menggunakan sains nyata. Jika digunakan sesuai dengan Sunnatullah yang diberikan oleh Allah pasti akan mendatangkan banyak manfaat bagi umat manusia. Sehingga prediksi atau yang dalam penelitian ini berupa deteksi diperbolehkan, karena didasari oleh ilmu pengetahuan dan dimaksudkan untuk mengurangi risiko yang lebih parah lagi.

Pelaksanaan deteksi sebagai upaya pencegahan juga harus disertai dengan doa. Sebagaimana kisah Nabi Ayyub As yang tidak pernah menyerah dalam memohon kesembuhan kepada Allah SWT dengan senantiasa memanjatkan doa ketika mendapat ujian penyakit selama bertahun-tahun. Doa yang dipanjatkan oleh Nabi Ayyub As tertulis pada ayat 83 Al-Qur'an surat Al-Anbiya yang berbunyi:

وَأَيُّوبَ إِذْ نَادَى رَبَّهُ أَنِّي مَسَّنِيَ الضُّرُّ وَأَنْتَ أَرْحَمُ الرَّاحِمِينَ

artinya: (Ingatlah) Ayyub ketika dia berdoa kepada Tuhannya, “(Ya Tuhanku,) sesungguhnya aku telah ditimpa penyakit, padahal Engkau Tuhan Yang Maha Penyayang dari semua yang penyayang.” (QS. Al-Anbiya 21:83).

Pada ayat tersebut menjelaskan bahwa segala usaha untuk berobat tetap harus disertai dengan doa. Bukan hanya sebagai usaha agar segera disembuhkan dari penyakit, tetapi juga sebagai upaya untuk mendekatkan diri kepada Allah SWT.



UIN SUNAN AMPEL
S U R A B A Y A

BAB III

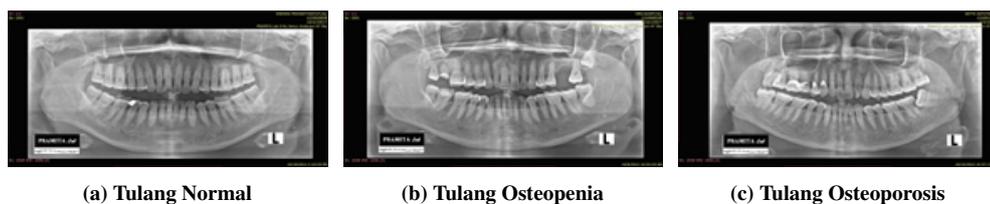
METODE PENELITIAN

3.1. Jenis Penelitian

Penelitian terkait dengan deteksi osteoporosis berdasarkan citra *Dental Panoramic Radiography* (DPR) menggunakan metode ekstraksi fitur tekstur GLRLM dan klasifikasi *Neural Network* metode *Backpropagation* secara fungsional termasuk dalam penelitian terapan. Hasil proses klasifikasi ini dimaksudkan untuk memberikan metode alternatif dalam mendeteksi dan memfasilitasi pemeriksaan osteoporosis. Penelitian terapan sering diartikan sebagai tindakan yang berorientasi aplikasi dalam memecahkan masalah.

3.2. Jenis dan Sumber Data

Pada penelitian ini jenis data yang digunakan berupa data sekunder. Data yang digunakan tersebut merupakan data citra *Dental Panoramic Radiography* (DPR) dengan fokus pada tulang mandibula. Data citra DPR diperoleh dari Laboratorium Klinik Pramita Jl. Raya Jemur Andayani 67 Surabaya (Adyanti, 2018). Data yang diperoleh ada sebanyak 58 data tulang normal, 26 tulang osteopenia, dan 15 data tulang osteoporosis dengan total sebanyak 99 data citra DPR.



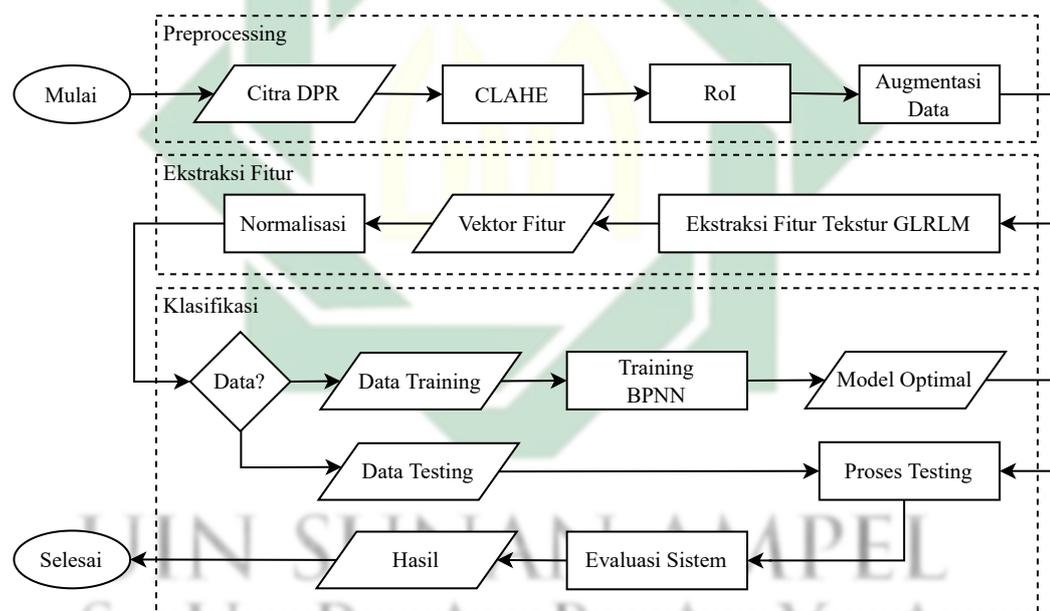
Gambar 3.1 Citra DPR

Sumber: (Adyanti, 2018)

Data citra DPR akan dianalisis menggunakan ekstraksi fitur tekstur GLRLM untuk mengetahui tingkat kepadatan mineral tulang pada mandibula. Vektor fitur yang telah diperoleh kemudian digunakan sebagai *input* klasifikasi *Neural Network* metode *Backpropagation* untuk mendapatkan hasil klasifikasi dari ketiga kelas tulang tersebut.

3.3. Kerangka Penelitian

Penyelesaian masalah pada penelitian ini dapat dilakukan secara bertahap seperti terlihat pada gambar di bawah ini.



Gambar 3.2 Diagram Alir Penelitian

Berdasarkan Gambar 3.2 tahapan dalam penelitian ini adalah:

1. *Input* data citra DPR

Data citra DPR yang telah diperoleh sebelumnya (99 data dengan rincian 58 data tulang normal, 26 data tulang osteopenia, dan 15 data tulang osteoporosis) akan digunakan sebagai *input*. Data citra DPR tersebut dalam format bmp

berukuran 1976×976 *pixel* yang telah diklasifikasikan oleh ahli ke dalam tiga kelas.

2. Melakukan proses CLAHE

Pada tahap *preprocessing* dilakukan perbaikan citra dengan meningkatkan kontras citra menggunakan metode CLAHE berdasarkan Persamaan 4.1 dengan nilai *clip limit* sebesar 0.02.

3. Melakukan proses RoI

Data selanjutnya akan melalui proses RoI berupa *cropping* pada tulang mandibula kiri dan kanan, masing-masing berukuran 80×100 *pixel*. RoI dilakukan dengan menggunakan titik koordinat, untuk tulang mandibula sebelah kanan koordinat yang digunakan yaitu (310, 420). Sedangkan koordinat tulang mandibula sebelah kiri yaitu (1620, 420). Proses RoI tersebut bertujuan untuk memfokuskan citra DPR pada tulang mandibula sehingga hasil yang diperoleh lebih optimal.

4. Melakukan augmentasi data

Data osteoporosis dan osteopenia akan diaugmentasi untuk menyeimbangkan jumlah data dengan menggunakan augmentasi warna berdasarkan kontras. Rentang nilai kontras yang digunakan mulai dari 0.5 sampai 1.5 sehingga diperoleh variasi data untuk tulang mandibula sebelah kanan dan kiri. Pada tulang osteoporosis akan dilakukan tiga kali proses augmentasi dari data asli sehingga akan diperoleh total sebanyak 60 data tulang osteoporosis. Sedangkan pada tulang osteopenia akan dilakukan satu kali proses augmentasi sehingga akan diperoleh total sebanyak 52 data tulang osteopenia. Adapun pada tulang normal tidak dilakukan augmentasi karena data sudah mencukupi (58 data)

sehingga total data keseluruhan sebanyak 170 data citra DPR.

5. Melakukan proses ekstraksi fitur tekstur GLRLM

Data akan melalui tahap ekstraksi fitur untuk memperoleh nilai vektor fiturnya. Pada penelitian ini, ekstraksi fitur tekstur menggunakan metode GLRLM berdasarkan Persamaan 2.6 hingga Persamaan 2.16 dengan variasi empat sudut yaitu sudut 0° , 45° , 90° , dan 135° .

6. Melakukan proses normalisasi

Data yang telah diperoleh dari ekstraksi fitur akan melalui proses normalisasi untuk menyamaratakan rentang nilai dari setiap fitur. Pada proses ini akan digunakan normalisasi *z-score* dan normalisasi *min-max* dengan rentang nilai minimal (*a*) yang diberikan yaitu 0.1 sedangkan rentang nilai maksimal (*b*) yang diberikan yaitu 0.9.

7. Membagi data menjadi data *training* dan data *testing*

Sebelum dilakukan proses klasifikasi data dibagi menjadi dua jenis yaitu data *training* dan data *testing* dengan menggunakan *k-fold cross validation*. Penggunaan *k-fold cross validation* bertujuan untuk membagi data secara acak dan mengelompokkan data sebanyak *k*.

8. Melakukan proses klasifikasi BPNN (*Backpropagation Neural Network*)

Data *training* akan diproses dengan menggunakan klasifikasi *Neural Network* metode *Backpropagation* untuk mendapatkan model optimal yang nantinya akan digunakan oleh data *testing* dalam menentukan klasifikasi penyakit osteoporosis.

9. Melakukan proses evaluasi sistem

Proses evaluasi sistem dilakukan dengan menggunakan *confusion matrix multiclass*. Pada *confusion matrix multiclass* terdapat empat nilai yang diukur yaitu TP, TN, FN, dan FP dengan menggunakan Persamaan 2.36 sampai Persamaan 2.39. Sedangkan tiga parameter yang digunakan yaitu akurasi, sensitivitas, dan spesifisitas dengan menggunakan Persamaan 2.40, 2.41, dan 2.42.

3.4. Rancangan Uji Coba

Pada penelitian ini dilakukan beberapa uji coba untuk memperoleh hasil terbaik. Uji coba pada tahap ekstraksi fitur tekstur GLRLM dilakukan dengan menggunakan empat sudut yang berbeda yaitu 0° , 45° , 90° , dan 135° . Selanjutnya pada tahap pembagian data dilakukan uji coba *k-fold cross validation* dengan nilai *k* yang digunakan yaitu 5 dan 10. Terakhir pada tahap klasifikasi *Neural Network* metode *Backpropagation* dilakukan beberapa uji coba diantaranya uji coba jumlah *hidden layer* sebanyak 1 dan 2, jumlah *node* pada *hidden layer* dengan variasi 50, 100, dan 150, serta uji coba *learning rate* mulai dari 0.1 sampai 0.9 dengan interval 0.1. Pada proses klasifikasi digunakan momentum sebesar 0.9 dengan fungsi aktivasi yang digunakan yaitu fungsi aktivasi sigmoid biner dan linear. Pada penggunaan *hidden layer* sebanyak 1 fungsi aktivasi yang digunakan sigmoid biner dan linear. Sedangkan pada penggunaan *hidden layer* sebanyak 2 fungsi aktivasi yang digunakan sigmoid biner, sigmoid biner, dan linear. Uji coba terbaik dinilai dari evaluasi sistem yang memiliki nilai sensitivitas paling tinggi.

BAB IV

HASIL DAN PEMBAHASAN

4.1. *Preprocessing*

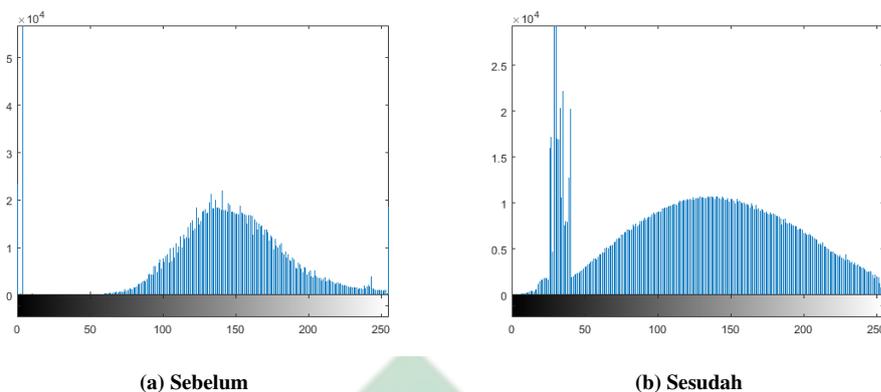
Pada penelitian ini jumlah data yang digunakan sebanyak 99 data citra DPR dengan tiga kelas yaitu tulang normal, osteopenia, dan tulang osteoporosis. Sebelum melakukan proses klasifikasi data tersebut akan melalui tahap *preprocessing* dikarenakan citra yang diperoleh memiliki intensitas pencahayaan yang berbeda dan memiliki kontras yang lemah. Sehingga perlu dilakukan *preprocessing* seperti peningkatan kontras dengan menggunakan metode CLAHE, pemfokusan daerah atau RoI, dan penambahan data menggunakan augmentasi warna berdasarkan nilai kontrasnya.

4.1.1. *Contrast Limited Adaptive Histogram Equalization (CLAHE)*

Metode CLAHE dapat meningkatkan kontras suatu citra sehingga membuat suatu citra menjadi lebih tajam dan lebih jelas. Cara kerja metode CLAHE yaitu dengan membagi citra menjadi beberapa *region*, dimana setiap *region* yang memiliki nilai kontras tinggi akan dibatasi dengan memberikan nilai batas pada histogram yang disebut *clip limit*. Hasil dari proses CLAHE dapat dilihat pada Gambar 4.1.

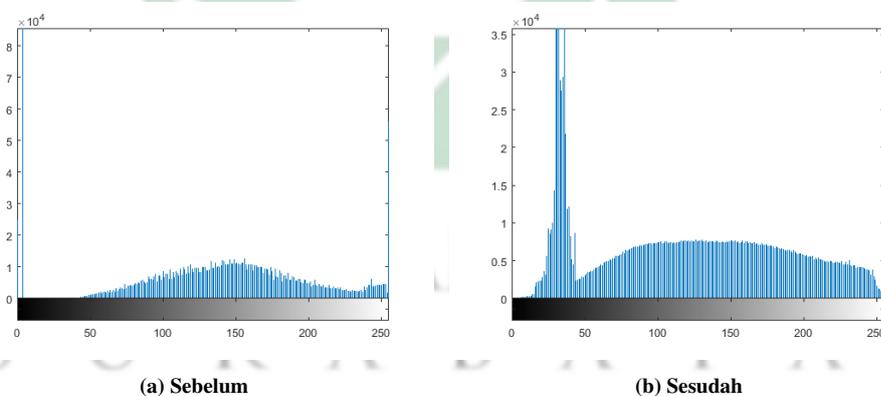


Gambar 4.1 CLAHE Citra DPR



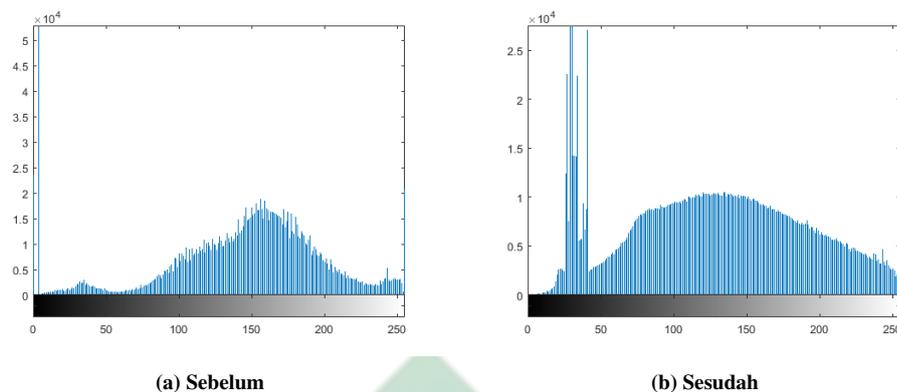
Gambar 4.2 Histogram Citra DPR Normal

Perbandingan histogram citra DPR pada tulang normal dapat dilihat pada Gambar 4.2. Berdasarkan pada Gambar 4.2 citra DPR sebelum dilakukan proses CLAHE memiliki histogram yang cenderung ke arah kanan saja. Sedangkan pada histogram citra DPR sesudah dilakukan proses CLAHE memiliki sebaran histogram yang lebih merata mulai dari *pixel 0* sampai *pixel 255*.



Gambar 4.3 Histogram Citra DPR Osteopenia

Perbandingan histogram citra DPR pada tulang osteopenia dapat dilihat pada Gambar 4.3. Berdasarkan pada Gambar 4.3 citra DPR sebelum dilakukan proses CLAHE memiliki histogram yang cenderung ke arah kanan saja. Sedangkan pada histogram citra DPR sesudah dilakukan proses CLAHE memiliki sebaran histogram yang lebih merata mulai dari *pixel 0* sampai *pixel 255*.

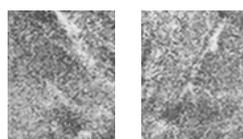


Gambar 4.4 Histogram Citra DPR Osteoporosis

Perbandingan histogram citra DPR pada tulang osteoporosis dapat dilihat pada Gambar 4.4. Berdasarkan pada Gambar 4.4 citra DPR sebelum dilakukan proses CLAHE memiliki sebaran histogram yang tidak merata. Sedangkan pada histogram citra DPR sesudah dilakukan proses CLAHE memiliki sebaran histogram yang lebih merata mulai dari *pixel* 0 sampai *pixel* 255.

4.1.2. Region of Interest (RoI)

Proses RoI bertujuan untuk memfokuskan area yang akan diteliti. Adapun proses yang dilakukan adalah dengan melakukan *cropping* pada tulang mandibula sebelah kanan dan sebelah kiri sebesar 80×100 *pixel*. Proses RoI dilakukan pada koordinat (310, 420) dan (1620, 420). Hasil RoI pada tulang mandibula sebelah kanan dan kiri akan diakumulasi untuk memperoleh proporsi secara menyeluruh. Gambar 4.5 menampilkan hasil dari proses RoI pada tulang mandibula.

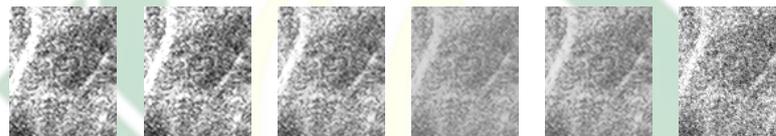


(a) Kanan (b) Kiri

Gambar 4.5 RoI Citra DPR

4.1.3. Augmentasi

Jumlah data yang digunakan pada penelitian tidak seimbang, dimana data tulang normal berjumlah 58 data, sedangkan data tulang osteopenia dan osteoporosis masing-masing sebesar 26 dan 15 data. Sehingga proses augmentasi akan dilakukan pada data osteopenia dan osteoporosis untuk menyeimbangkan jumlah data. Adapun proses augmentasi yang digunakan dengan menggunakan augmentasi warna berdasarkan nilai kontrasnya. Pada penelitian ini rentang nilai kontras yang digunakan mulai dari 0.5 sampai 1.5. Hasil augmentasi warna berdasarkan nilai kontras dapat dilihat pada Gambar 4.6.



Gambar 4.6 Augmentasi Warna Berdasarkan Kontras

Pada penelitian ini proses augmentasi yang dilakukan pada setiap citra DPR berbeda dikarenakan jumlah data yang tidak sama. Pada citra DPR tulang normal tidak dilakukan proses augmentasi karena jumlah data yang sudah cukup. Pada citra DPR tulang osteopenia proses augmentasi hanya dilakukan satu kali sehingga jumlah data yang diperoleh sebanyak 52 data. Pada citra DPR tulang osteoporosis proses augmentasi dilakukan tiga kali sehingga jumlah data yang diperoleh sebanyak 60 data. Total keseluruhan data yang diperoleh setelah proses augmentasi sebanyak 170 data.

4.2. Ekstraksi Fitur Menggunakan Metode GLRLM

Proses ekstraksi fitur tekstur bertujuan untuk mengambil nilai ciri tekstur pada citra DPR. Pada penelitian ini proses ekstraksi fitur tekstur dengan

menggunakan metode *Gray Level Run Length Matrix* (GLRLM). Cara kerja metode GLRLM adalah dengan mencari matriks *run length* yang menunjukkan jumlah keseluruhan munculnya *run* dengan panjang dari tingkat keabuan dalam orientasi arah tertentu. Adapun orientasi arah GLRLM pada penelitian ini adalah 0° , 45° , 90° , dan 135° . Hasil dari matriks *run length* akan digunakan untuk perhitungan 11 fitur pada GLRLM yaitu SRE, LRE, GLN, RLN, RP, LGRE, HGRE, SRLGE, SRHGE, LRLGE, dan LRHGE. Berikut salah satu perhitungan matriks *run length*, dimana baris merupakan tingkat keabuan dan kolom merupakan panjang *run*.

$$I = \begin{bmatrix} 139 & 135 & 135 & \dots & 139 & 157 & 122 \\ 132 & 120 & 142 & \dots & 139 & 157 & 122 \\ 135 & 113 & 120 & \dots & 139 & 157 & 122 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 134 & 149 & 156 & \dots & 163 & 156 & 174 \\ 157 & 190 & 197 & \dots & 153 & 160 & 160 \\ 188 & 182 & 185 & \dots & 175 & 171 & 150 \end{bmatrix}$$

$$RL = \begin{bmatrix} 4 & 4 & 4 & \dots & 4 & 5 & 3 \\ 4 & 3 & 4 & \dots & 3 & 4 & 6 \\ 4 & 3 & 3 & \dots & 3 & 3 & 6 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 4 & 4 & 5 & \dots & 5 & 5 & 5 \\ 5 & 6 & 6 & \dots & 5 & 5 & 5 \\ 6 & 6 & 6 & \dots & 5 & 5 & 4 \end{bmatrix}$$

Perhitungan setiap fitur GLRLM akan membutuhkan nilai N , dimana N merupakan jumlah nilai dari setiap elemen matriks *run length*.

$$N = (4 + 4 + 4 + \dots + 4 + 5 + 3) + \dots + (6 + 6 + 6 + \dots + 5 + 5 + 4) = 75334$$

$$\begin{aligned} SRE &= \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j|0)}{j^2} \\ &= \frac{1}{75334} \left(\left(\frac{4}{1^2} + \frac{4}{2^2} + \frac{4}{3^2} + \dots + \frac{3}{162^2} \right) + \dots + \left(\frac{6}{1^2} + \frac{6}{2^2} + \frac{6}{3^2} + \dots + \frac{4}{162^2} \right) \right) \\ &= 0.0657 \end{aligned}$$

$$\begin{aligned} LRE &= \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R j^2 p(i, j|0) \\ &= \frac{1}{75334} \left((1^2 \cdot 4 + 2^2 \cdot 4 + 3^2 \cdot 4 + \dots + 162^2 \cdot 3) + \dots + (1^2 \cdot 6 + 2^2 \cdot 6 + 3^2 \cdot 6 \right. \\ &\quad \left. + \dots + 162^2 \cdot 4) \right) \\ &= 22.8479 \end{aligned}$$

$$\begin{aligned} GLN &= \frac{1}{N} \sum_{i=1}^G \left(\sum_{j=1}^R p(i, j|0) \right)^2 \\ &= \frac{1}{75334} \left(\left(4 + 4 + 4 + \dots + 3 \right)^2 + \dots + \left(6 + 6 + 6 + \dots + 4 \right)^2 \right) \\ &= 4269.7633 \end{aligned}$$

$$\begin{aligned} RLN &= \frac{1}{N} \sum_{i=1}^R \left(\sum_{j=1}^G p(i, j|0) \right)^2 \\ &= \frac{1}{75334} \left(\left(4 + 4 + 4 + \dots + 6 \right)^2 + \dots + \left(3 + 6 + 6 + \dots + 4 \right)^2 \right) \\ &= 2079.0192 \end{aligned}$$

$$\begin{aligned} RP &= \frac{N}{\sum_{i=1}^G \sum_{j=1}^R p(i, j|0)} \\ &= \frac{75334}{\left(1 \cdot 4 + 2 \cdot 4 + 3 \cdot 4 + \dots + 162 \cdot 3 \right) + \dots + \left(1 \cdot 6 + 2 \cdot 6 + 3 \cdot 6 + \dots + 162 \cdot 4 \right)} \\ &= 7.6257 \end{aligned}$$

$$\begin{aligned} LGRE &= \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j|0)}{i^2} \\ &= \frac{1}{75334} \left(\left(\frac{4}{1^2} + \frac{4}{1^2} + \frac{4}{1^2} + \dots + \frac{3}{1^2} \right) + \dots + \left(\frac{6}{101^2} + \frac{6}{101^2} + \frac{6}{101^2} + \dots \right) \right) \end{aligned}$$

$$+ \frac{4}{101^2} \Big) \Big)$$

$$= 0.6745$$

$$HGRE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R i^2 p(i, j|0)$$

$$= \frac{1}{75334} ((1^2 \cdot 4 + 1^2 \cdot 4 + 1^2 \cdot 4 + \dots + 1^2 \cdot 3) + \dots + (101^2 \cdot 6 + 101^2 \cdot 6$$

$$+ 101^2 \cdot 6 + \dots + 101^2 \cdot 4))$$

$$= 3.8589$$

$$SRLGE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j|0)}{i^2 j^2}$$

$$= \frac{1}{75334} \left(\left(\frac{4}{1^2 \cdot 1^2} + \frac{4}{1^2 \cdot 2^2} + \frac{4}{1^2 \cdot 3^2} + \dots + \frac{3}{1^2 \cdot 162^2} \right) + \dots + \left(\frac{6}{101^2 \cdot 1^2} \right. \right.$$

$$\left. \left. + \frac{6}{101^2 \cdot 2^2} + \frac{6}{101^2 \cdot 3^2} + \dots + \frac{4}{101^2 \cdot 162^2} \right) \right)$$

$$= 0.0444$$

$$SRHGE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{i^2 p(i, j|0)}{j^2}$$

$$= \frac{1}{75334} \left(\left(\frac{1^2 \cdot 4}{1^2} + \frac{1^2 \cdot 4}{2^2} + \frac{1^2 \cdot 4}{3^2} + \dots + \frac{1^2 \cdot 3}{162^2} \right) + \dots + \left(\frac{101^2 \cdot 6}{1^2} + \frac{101^2 \cdot 6}{2^2} \right. \right.$$

$$\left. \left. + \frac{101^2 \cdot 6}{3^2} + \dots + \frac{101^2 \cdot 4}{162^2} \right) \right)$$

$$= 0.2472$$

$$LRLGE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R \frac{j^2 p(i, j|0)}{i^2}$$

$$= \frac{1}{75334} \left(\left(\frac{1^2 \cdot 4}{1^2} + \frac{2^2 \cdot 4}{1^2} + \frac{3^2 \cdot 4}{1^2} + \dots + \frac{162^2 \cdot 3}{1^2} \right) + \dots + \left(\frac{1^2 \cdot 6}{101^2} + \frac{2^2 \cdot 6}{101^2} \right. \right.$$

$$\left. \left. + \frac{3^2 \cdot 6}{101^2} + \dots + \frac{162^2 \cdot 4}{101^2} \right) \right)$$

$$= 15.3713$$

$$LRHGE = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R i^2 j^2 p(i, j|0)$$

$$= \frac{1}{75334} ((1^2 \cdot 1^2 \cdot 4 + 1^2 \cdot 2^2 \cdot 4 + 1^2 \cdot 3^2 \cdot 4 + \dots + 1^2 \cdot 162^2 \cdot 3) + \dots$$

$$+ (101^2 \cdot 1^2 \cdot 6 + 101^2 \cdot 2^2 \cdot 6 + 101^2 \cdot 3^2 \cdot 6 + \dots + 101^2 \cdot 162^2 \cdot 4))$$

$$= 88.1842$$

Perhitungan tersebut hanya perhitungan untuk satu data citra DPR pada satu arah sudut 0° . Sehingga perhitungan harus dilakukan secara berulang sebanyak jumlah data dan pada keempat arah sudut yaitu 0° , 45° , 90° , dan 135° . Nilai fitur yang diperoleh tersebut akan digunakan sebagai *input* pada tahap klasifikasi. Hasil dari perhitungan ekstraksi fitur pada setiap arah sudut dapat dilihat pada Tabel 4.1 hingga Tabel 4.4.

Tabel 4.1 GLRLM Sudut 0

Kelas	Data	Fitur										
		SRE	LRE	GLN	RLN	RP	LGRE	HGRE	SRLGE	SRHGE	LRLGE	LRHGE
Normal	1	0.07	22.85	4269.76	2079.02	7.63	0.67	3.86	0.04	0.25	15.37	88.18
	2	0.08	23.61	2037.97	1166.94	5.46	0.53	9.04	0.04	0.67	11.93	242.77
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	58	0.10	16.73	1479.96	1367.46	4.76	0.46	12.11	0.05	1.08	7.88	203.68
Osteopenia	1	0.11	20.34	1263.76	1023.86	4.42	0.43	14.25	0.05	1.38	9.19	255.70
	2	0.05	26.02	4169.09	2053.62	7.49	0.67	4.14	0.04	0.20	17.17	116.38
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	52	0.04	30.96	2628.72	1791.40	6.15	0.57	6.74	0.03	0.25	17.13	237.79
Osteoporosis	1	0.05	27.28	2837.63	1856.49	6.39	0.59	5.91	0.03	0.29	15.98	161.62
	2	0.07	23.17	3089.59	1635.64	6.58	0.61	5.74	0.04	0.40	14.19	127.89
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	60	0.06	26.49	2251.90	1393.87	5.75	0.55	7.82	0.03	0.52	14.67	191.95

Tabel 4.2 GLRLM Sudut 45

Kelas	Data	Fitur										
		SRE	LRE	GLN	RLN	RP	LGRE	HGRE	SRLGE	SRHGE	LRLGE	LRHGE
Normal	1	0.07	22.72	5734.15	2287.69	13.72	0.75	2.91	0.05	0.18	16.86	67.20
	2	0.08	23.96	3226.57	1384.61	10.61	0.63	5.83	0.05	0.43	14.78	155.07
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	58	0.10	16.73	2396.91	1656.37	9.32	0.57	7.86	0.06	0.70	9.61	131.65
Osteopenia	1	0.11	20.09	2099.63	1261.12	8.69	0.55	9.53	0.06	0.91	11.33	170.78
	2	0.05	26.30	5705.04	2296.40	13.66	0.75	2.97	0.04	0.14	19.39	82.61
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	52	0.04	31.25	3910.41	2069.93	11.56	0.67	4.71	0.03	0.18	20.35	165.35
Osteoporosis	1	0.05	27.17	4134.79	2147.94	11.94	0.68	4.17	0.03	0.20	18.32	116.52
	2	0.07	23.36	4300.99	1860.47	12.11	0.69	4.07	0.05	0.28	16.23	90.25
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	60	0.06	26.34	3285.23	1619.58	10.79	0.63	5.44	0.04	0.36	16.84	135.83

Tabel 4.3 GLRLM Sudut 90

Kelas	Data	Fitur										
		SRE	LRE	GLN	RLN	RP	LGRE	HGRE	SRLGE	SRHGE	LRLGE	LRHGE
Normal	1	0.07	22.82	4476.99	2096.05	12.43	0.69	3.74	0.05	0.24	15.62	85.43
	2	0.08	23.70	2299.82	1218.33	9.24	0.55	8.03	0.05	0.57	12.74	219.22
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	58	0.10	16.59	1481.69	1352.73	7.56	0.47	12.78	0.05	1.14	7.80	218.19
Osteopenia	1	0.11	20.14	1260.34	1001.98	6.98	0.44	15.47	0.05	1.45	9.08	276.53
	2	0.05	26.13	4613.73	2146.93	12.54	0.70	3.71	0.04	0.18	17.80	102.97
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	52	0.04	31.33	2746.12	1826.87	9.97	0.59	6.79	0.03	0.27	17.99	237.80
Osteoporosis	1	0.05	27.03	2859.92	1883.58	10.28	0.59	5.98	0.03	0.29	15.78	168.60
	2	0.07	23.34	3268.48	1678.96	10.80	0.62	5.45	0.04	0.38	14.68	120.35
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	60	0.06	26.39	2493.81	1457.29	9.60	0.57	7.26	0.03	0.48	15.12	177.97

Tabel 4.4 GLRLM Sudut 135

Kelas	Data	Fitur										
		SRE	LRE	GLN	RLN	RP	LGRE	HGRE	SRLGE	SRHGE	LRLGE	LRHGE
Normal	1	0.07	22.83	5865.74	2305.61	13.80	0.75	2.91	0.05	0.18	17.15	67.01
	2	0.08	23.68	3182.58	1379.97	10.50	0.63	6.02	0.05	0.43	14.49	162.76
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	58	0.10	16.76	2249.81	1613.31	9.07	0.56	8.42	0.06	0.74	9.43	141.48
Osteopenia	1	0.11	19.98	2044.94	1257.52	8.58	0.55	10.05	0.06	0.93	11.22	184.66
	2	0.05	26.16	5818.99	2306.04	13.77	0.75	2.90	0.04	0.14	19.26	80.75
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	52	0.04	31.37	3764.10	2041.79	11.46	0.66	4.66	0.03	0.18	20.10	160.57
Osteoporosis	1	0.05	27.35	4054.17	2124.13	11.91	0.67	4.13	0.03	0.20	18.25	112.87
	2	0.07	23.40	4549.00	1888.23	12.37	0.70	3.94	0.05	0.28	16.50	85.78
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	60	0.06	26.34	3488.94	1645.35	11.05	0.64	5.14	0.04	0.34	17.17	127.65

Berdasarkan hasil perhitungan ekstraksi fitur pada Tabel 4.1 hingga Tabel 4.4 dapat dilihat bahwa setiap fitur memiliki rentang nilai yang sangat luas. Hal ini akan mempengaruhi hasil klasifikasi sehingga untuk menyamaratakan rentang nilai dari seluruh fitur ke dalam rentang nilai yang lebih kecil akan dilakukan normalisasi. Pada penelitian ini akan digunakan normalisasi *z-score* dengan menggunakan Persamaan 2.19 dan normalisasi *min-max* dengan menggunakan Persamaan 2.18 dengan rentang nilai minimal (*a*) yang diberikan yaitu 0.1 sedangkan rentang nilai maksimal (*b*) yang diberikan yaitu 0.9.

$$x = \begin{bmatrix} 0.07 & 22.9 & 4269.8 & 2079.02 & 7.6 & 0.67 & 3.9 & 0.04 & 0.25 & 15.4 & 88.2 \end{bmatrix}$$

$$\mu = 589.8$$

$$\sigma = 1368.8$$

$$\begin{aligned} x' &= \frac{x - \mu}{\sigma} \\ &= \frac{\begin{bmatrix} 0.07 & 22.9 & 4269.8 & \dots & 0.25 & 15.4 & 88.2 \end{bmatrix} - 589.8}{1368.8} \\ &= \begin{bmatrix} -0.4308 & -0.4142 & 2.6885 & \dots & -0.4307 & -0.4197 & -0.3665 \end{bmatrix} \end{aligned}$$

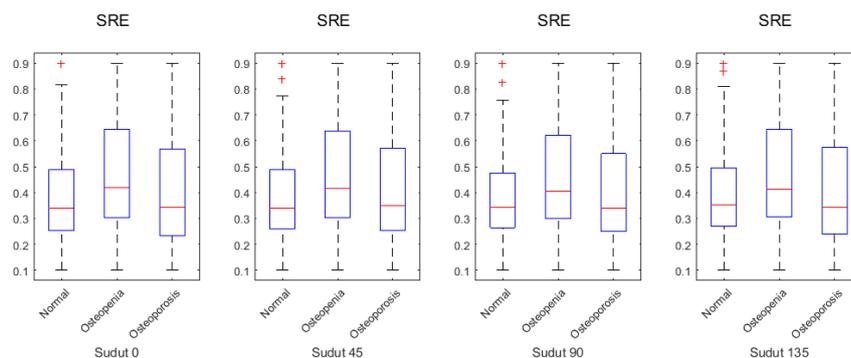
Setelah diperoleh nilai x' selanjutnya akan ditentukan data yang memiliki nilai minimal dan maksimal dari data x' . Data tersebut akan digunakan pada proses normalisasi *min-max*.

$$\min(x') = -0.4309$$

$$\max(x') = 2.6885$$

$$\begin{aligned} x'' &= a + \frac{(x' - \min(x'))(b - a)}{\max(x') - \min(x')} \\ &= 0.1 + \frac{\left(\begin{bmatrix} -0.4308 & -0.4142 & \dots & -0.4197 & -0.3665 \end{bmatrix} - (-0.4309) \right) (0.9 - 0.1)}{2.6885 - (-0.4309)} \\ &= \begin{bmatrix} 0.1000 & 0.1043 & 0.9000 & \dots & 0.1000 & 0.1029 & 0.1165 \end{bmatrix} \end{aligned}$$

Data hasil normalisasi memang memiliki rentang nilai yang lebih kecil namun jumlah data serta jumlah fitur yang tidak sedikit akan membingungkan jika dianalisis secara langsung. Oleh karena itu akan dibuat perbandingan karakteristik data pada setiap fitur dengan menggunakan *boxplot* sebagaimana pada Gambar 4.7 hingga Gambar 4.17.

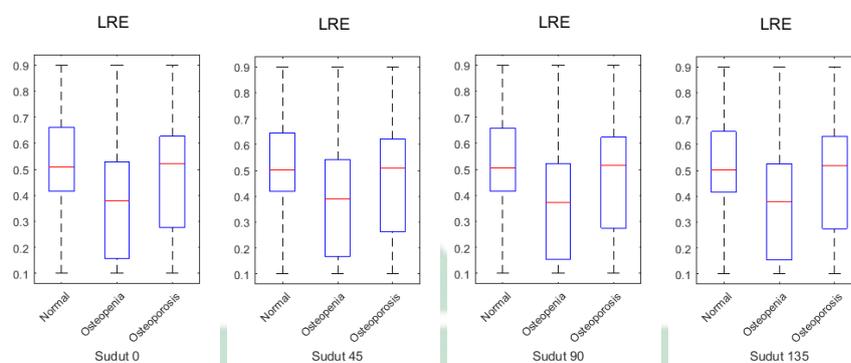


Gambar 4.7 *Boxplot* Citra DPR Fitur SRE Semua Sudut

Berdasarkan Gambar 4.7 data citra DPR tulang osteopenia memiliki nilai fitur SRE lebih tinggi baik pada sudut 0° , 45° , 90° , maupun 135° dibandingkan dengan data citra DPR pada tulang normal dan osteoporosis. Pada sudut 0° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.3017 sampai dengan 0.6448 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.2544–0.4896) dan citra DPR tulang osteoporosis (0.2342–0.5674). Pada sudut 45° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.3019 sampai dengan 0.6381 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.2621 – 0.4887) dan citra DPR tulang osteoporosis (0.2527 – 0.5728).

Pada sudut 90° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.3000 sampai dengan 0.6209 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.2648 – 0.4751) dan citra DPR tulang osteoporosis (0.2502 – 0.5498). Pada sudut 135° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.3074 sampai dengan 0.6429 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.2690 – 0.4946) dan citra DPR tulang osteoporosis (0.2409 – 0.5738). Nilai fitur SRE yang tinggi menunjukkan bahwa citra tersebut memiliki tekstur yang halus.

Sehingga dari ketiga jenis citra DPR tersebut tulang osteopenia yang memiliki tekstur paling halus.

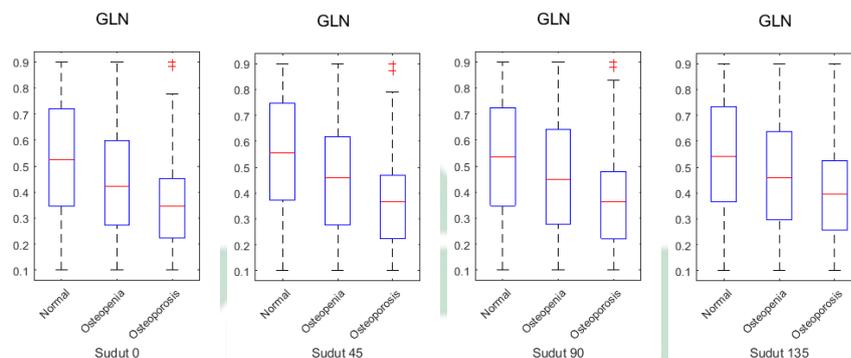


Gambar 4.8 Boxplot Citra DPR Fitur LRE Semua Sudut

Berdasarkan Gambar 4.8 data citra DPR tulang normal memiliki nilai fitur LRE lebih tinggi baik pada sudut 0° , 45° , 90° , maupun 135° dibandingkan dengan data citra DPR pada tulang osteopenia dan osteoporosis. Pada sudut 0° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4162 sampai dengan 0.6607 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.1585 – 0.5290) dan citra DPR tulang osteoporosis (0.2767 – 0.6267). Pada sudut 45° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4196 sampai dengan 0.6437 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.1661 – 0.5412) dan citra DPR tulang osteoporosis (0.2621 – 0.6204).

Pada sudut 90° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4161 sampai dengan 0.6574 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.1555 – 0.5207) dan citra DPR tulang osteoporosis (0.2743 – 0.6234). Pada sudut 135° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4155 sampai dengan 0.6490 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.1556 – 0.5263) dan citra DPR tulang osteoporosis (0.2748 – 0.6294).

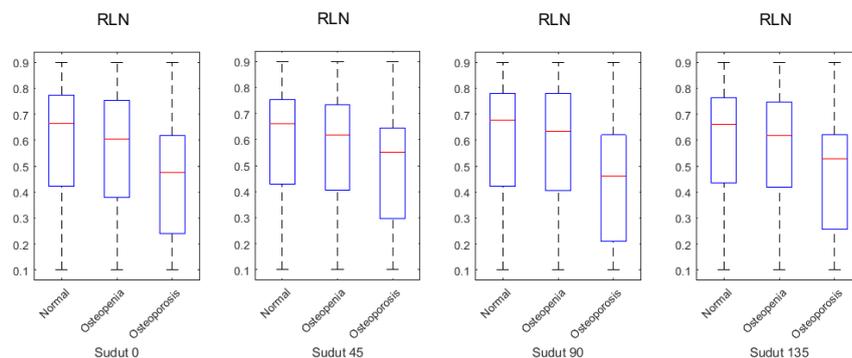
Nilai fitur LRE yang tinggi menunjukkan bahwa citra tersebut memiliki tekstur yang kasar. Sehingga dari ketiga jenis citra DPR tersebut tulang normal yang memiliki tekstur paling kasar.



Gambar 4.9 Boxplot Citra DPR Fitur GLN Semua Sudut

Berdasarkan Gambar 4.9 pada sudut 0° data citra DPR tulang osteoporosis memiliki rentang nilai 0.2231 sampai dengan 0.4534 yang beririsan dengan rentang nilai dari data citra DPR tulang normal (0.3457 – 0.7204) dan citra DPR tulang osteopenia (0.2732 – 0.5981). Pada sudut 45° data citra DPR tulang osteoporosis memiliki rentang nilai 0.2250 sampai dengan 0.4675 yang beririsan dengan rentang nilai dari data citra DPR tulang normal (0.3724 – 0.7460) dan citra DPR tulang osteopenia (0.2770 – 0.6166).

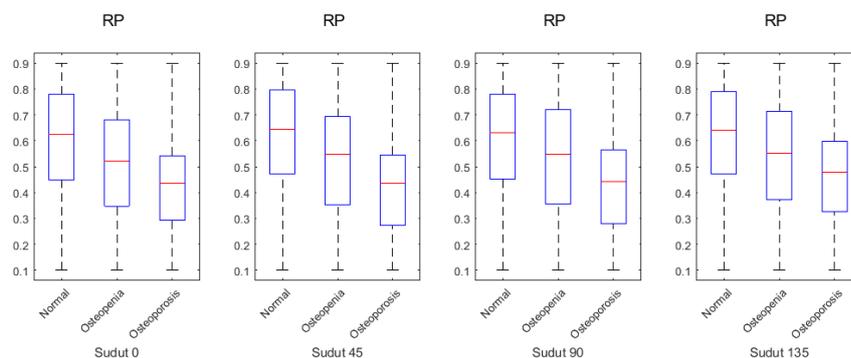
Pada sudut 90° data citra DPR tulang osteoporosis memiliki rentang nilai 0.2218 sampai dengan 0.4791 yang beririsan dengan rentang nilai dari data citra DPR tulang normal (0.3478 – 0.5362) dan citra DPR tulang osteopenia (0.2762 – 0.6415). Pada sudut 135° data citra DPR tulang osteoporosis memiliki rentang nilai 0.2571 sampai dengan 0.5239 yang beririsan dengan rentang nilai dari data citra DPR tulang normal (0.3670 – 0.7348) dan citra DPR tulang osteopenia (0.2954 – 0.6380). Nilai fitur GLN yang rendah menunjukkan bahwa citra tersebut memiliki tingkat keabuan yang seragam.



Gambar 4.10 Boxplot Citra DPR Fitur RLN Semua Sudut

Berdasarkan Gambar 4.10 pada sudut 0° data citra DPR tulang osteoporosis memiliki rentang nilai 0.2406 sampai dengan 0.6187 yang beririsan dengan rentang nilai dari data citra DPR tulang normal (0.4232 – 0.7743) dan citra DPR tulang osteopenia (0.3789 – 0.7541). Pada sudut 45° data citra DPR tulang osteoporosis memiliki rentang nilai 0.2955 sampai dengan 0.6448 yang beririsan dengan rentang nilai dari data citra DPR tulang normal (0.4277 – 0.7535) dan citra DPR tulang osteopenia (0.4056 – 0.7326).

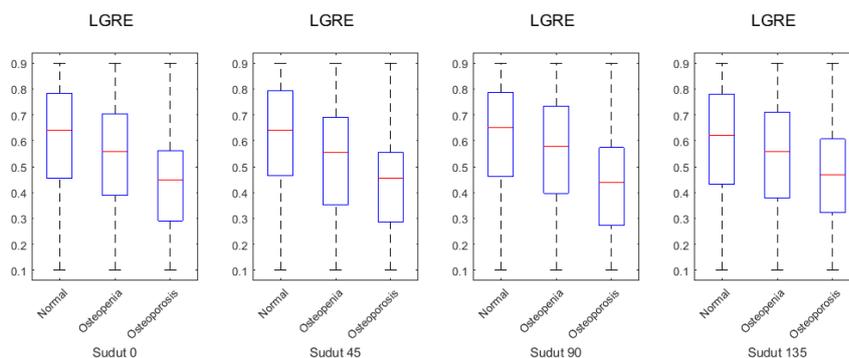
Pada sudut 90° data citra DPR tulang osteoporosis memiliki rentang nilai 0.2115 sampai dengan 0.6192 yang beririsan dengan rentang nilai dari data citra DPR tulang normal (0.4208 – 0.7796) dan citra DPR tulang osteopenia (0.4061 – 0.7791). Pada sudut 135° data citra DPR tulang osteoporosis memiliki rentang nilai 0.2578 sampai dengan 0.6223 yang beririsan dengan rentang nilai dari data citra DPR tulang normal (0.4341 – 0.7633) dan citra DPR tulang osteopenia (0.4195 – 0.7475). Nilai fitur RLN yang rendah menunjukkan bahwa citra tersebut memiliki panjang lintasan yang seragam.



Gambar 4.11 *Boxplot* Citra DPR Fitur RP Semua Sudut

Berdasarkan Gambar 4.11 data citra DPR tulang normal memiliki nilai fitur RP lebih tinggi baik pada sudut 0° , 45° , 90° , maupun 135° dibandingkan dengan data citra DPR pada tulang osteopenia dan osteoporosis. Pada sudut 0° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4492 sampai dengan 0.7793 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.3476 – 0.6819) dan citra DPR tulang osteoporosis (0.2919 – 0.5418). Pada sudut 45° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4719 sampai dengan 0.7967 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.3518 – 0.6934) dan citra DPR tulang osteoporosis (0.2729 – 0.5462).

Pada sudut 90° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4528 sampai dengan 0.7810 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.3565 – 0.5466) dan citra DPR tulang osteoporosis (0.2788 – 0.5657). Pada sudut 135° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4715 sampai dengan 0.7882 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.3712 – 0.7126) dan citra DPR tulang osteoporosis (0.3263 – 0.5980).

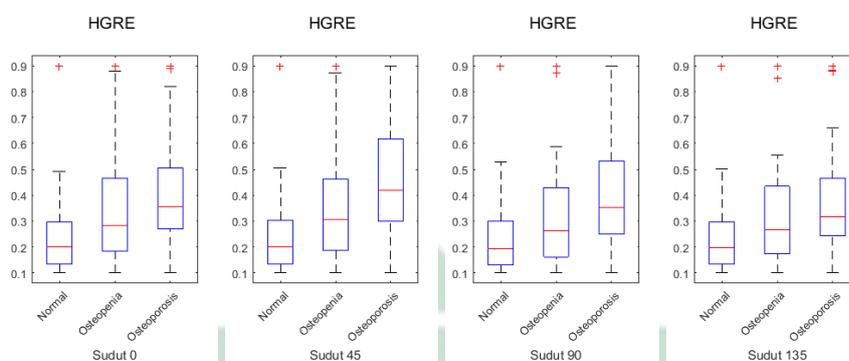


Gambar 4.12 Boxplot Citra DPR Fitur LGRE Semua Sudut

Berdasarkan Gambar 4.12 data citra DPR tulang normal memiliki nilai fitur LGRE lebih tinggi baik pada sudut 0° , 45° , 90° , maupun 135° dibandingkan dengan data citra DPR pada tulang osteopenia dan osteoporosis. Pada sudut 0° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4538 sampai dengan 0.7819 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.3899 – 0.7051) dan citra DPR tulang osteoporosis (0.2915 – 0.5621). Pada sudut 45° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4658 sampai dengan 0.7925 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.3522 – 0.6916) dan citra DPR tulang osteoporosis (0.2876 – 0.5534).

Pada sudut 90° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4610 sampai dengan 0.7866 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.3972 – 0.7327) dan citra DPR tulang osteoporosis (0.2725 – 0.5730). Pada sudut 135° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4330 sampai dengan 0.7800 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.3800 – 0.7089) dan citra DPR tulang osteoporosis (0.3271 – 0.0659). Nilai fitur LGRE yang tinggi menunjukkan bahwa citra tersebut memiliki tingkat

keabuan yang rendah. Sehingga dari ketiga jenis citra DPR tersebut tulang normal yang memiliki tingkat keabuan terendah.

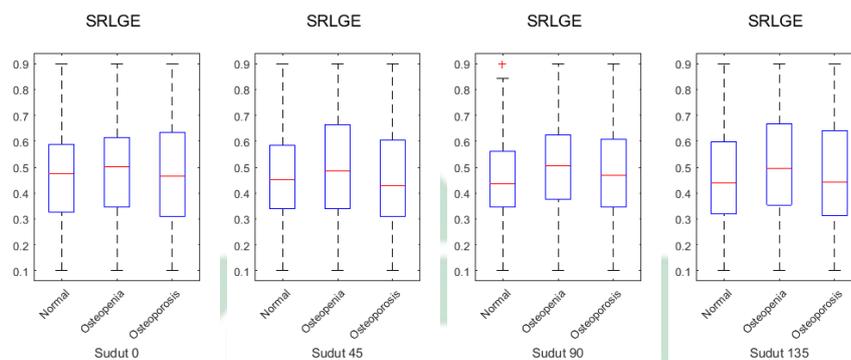


Gambar 4.13 Boxplot Citra DPR Fitur HGRE Semua Sudut

Berdasarkan Gambar 4.13 data citra DPR tulang osteoporosis memiliki nilai fitur HGRE lebih tinggi baik pada sudut 0° , 45° , 90° , maupun 135° dibandingkan dengan data citra DPR pada tulang normal dan osteopenia. Pada sudut 0° citra DPR pada tulang osteoporosis memiliki rentang nilai sekitar 0.2711 sampai dengan 0.5059 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1344 – 0.2961) dan citra DPR tulang osteopenia (0.1831 – 0.4665). Pada sudut 45° citra DPR pada tulang osteoporosis memiliki rentang nilai sekitar 0.2988 sampai dengan 0.6173 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1341 – 0.3042) dan citra DPR tulang osteopenia (0.1867 – 0.4616).

Pada sudut 90° citra DPR pada tulang osteoporosis memiliki rentang nilai sekitar 0.2511 sampai dengan 0.5323 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1317 – 0.3000) dan citra DPR tulang osteopenia (0.1623 – 0.4294). Pada sudut 135° citra DPR pada tulang osteoporosis memiliki rentang nilai sekitar 0.2439 sampai dengan 0.4651 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1300 – 0.2970) dan citra DPR tulang osteopenia (0.1734 – 0.4341). Nilai fitur

HGRE yang tinggi menunjukkan bahwa citra tersebut memiliki tingkat keabuan yang tinggi. Sehingga dari ketiga jenis citra DPR tersebut tulang osteoporosis yang memiliki tingkat keabuan tertinggi.

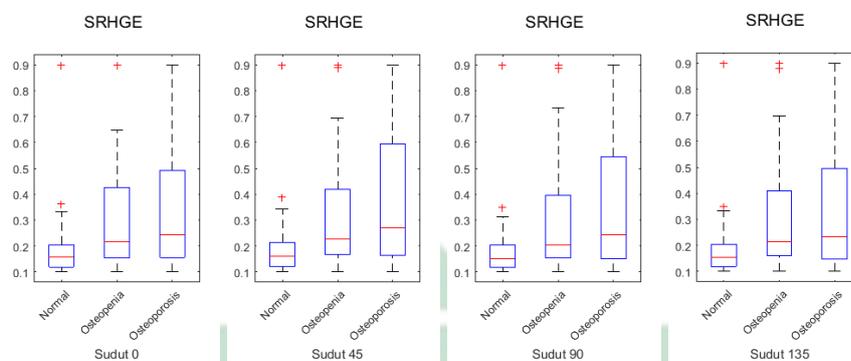


Gambar 4.14 Boxplot Citra DPR Fitur SRLGE Semua Sudut

Berdasarkan Gambar 4.14 data citra DPR tulang osteopenia memiliki nilai fitur SRLGE lebih tinggi dibandingkan dengan data citra DPR pada tulang normal dan osteoporosis. Pada sudut 0° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.3455 sampai dengan 0.6157 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.3261 – 0.5886) dan citra DPR tulang osteoporosis (0.3105 – 0.6335). Pada sudut 45° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.3384 sampai dengan 0.6642 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.3403 – 0.5834) dan citra DPR tulang osteoporosis (0.3100 – 0.6040).

Pada sudut 90° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.3772 sampai dengan 0.6234 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.3462 – 0.5623) dan citra DPR tulang osteoporosis (0.3474 – 0.6069). Pada sudut 135° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.3542 sampai dengan 0.6668 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.3209 – 0.5963) dan citra DPR tulang osteoporosis (0.3115 – 0.6407). Nilai fitur

SRLGE yang tinggi menunjukkan bahwa citra tersebut memiliki tingkat keabuan yang rendah serta panjang lintasan pendek.

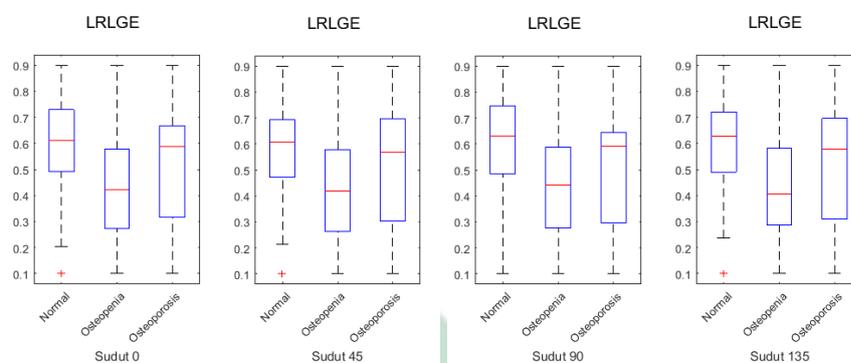


Gambar 4.15 Boxplot Citra DPR Fitur SRHGE Semua Sudut

Berdasarkan Gambar 4.15 data citra DPR tulang osteoporosis memiliki nilai fitur SRHGE lebih tinggi dibandingkan dengan data citra DPR pada tulang normal dan osteopenia. Pada sudut 0° citra DPR pada tulang osteoporosis memiliki rentang nilai sekitar 0.1557 sampai dengan 0.4924 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1193 – 0.2054) dan citra DPR tulang osteopenia (0.1544 – 0.4246). Pada sudut 45° citra DPR pada tulang osteoporosis memiliki rentang nilai sekitar 0.1646 sampai dengan 0.5932 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1221 – 0.2143) dan citra DPR tulang osteopenia (0.1675 – 0.4181).

Pada sudut 90° citra DPR pada tulang osteoporosis memiliki rentang nilai sekitar 0.1517 sampai dengan 0.5456 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1191 – 0.2034) dan citra DPR tulang osteopenia (0.1538 – 0.3948). Pada sudut 135° citra DPR pada tulang osteoporosis memiliki rentang nilai sekitar 0.1468 sampai dengan 0.4957 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1188 – 0.2041) dan citra DPR tulang osteopenia (0.1619 – 0.4096). Nilai fitur SRHGE yang tinggi menunjukkan bahwa citra tersebut memiliki tingkat keabuan

yang tinggi serta panjang lintasan pendek.

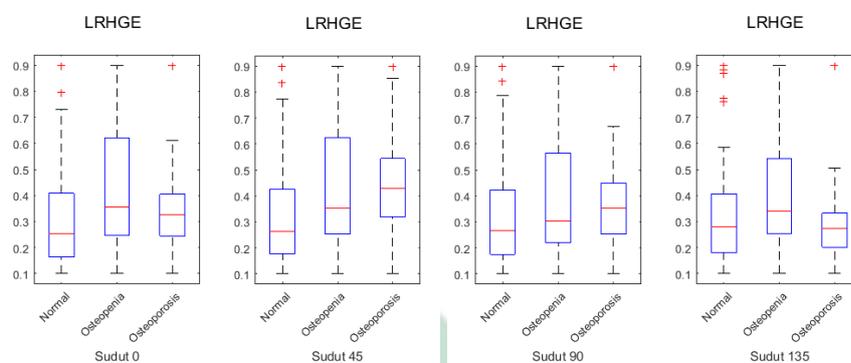


Gambar 4.16 Boxplot Citra DPR Fitur LRLGE Semua Sudut

Berdasarkan Gambar 4.16 data citra DPR tulang normal memiliki nilai fitur LRLGE lebih tinggi baik pada sudut 0° , 45° , 90° , maupun 135° dibandingkan dengan data citra DPR pada tulang osteopenia dan osteoporosis. Pada sudut 0° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4903 sampai dengan 0.7292 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.2719 – 0.5763) dan citra DPR tulang osteoporosis (0.3159 – 0.6678). Pada sudut 45° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4717 sampai dengan 0.6937 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.2643 – 0.5781) dan citra DPR tulang osteoporosis (0.3044 – 0.6961).

Pada sudut 90° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4844 sampai dengan 0.7468 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.2771 – 0.5877) dan citra DPR tulang osteoporosis (0.2956 – 0.6432). Pada sudut 135° citra DPR pada tulang normal memiliki rentang nilai sekitar 0.4891 sampai dengan 0.7209 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang osteopenia (0.2863 – 0.5811) dan citra DPR tulang osteoporosis (0.3095 – 0.6956). Nilai fitur LRLGE yang tinggi menunjukkan bahwa citra tersebut memiliki tingkat

keabuan yang rendah serta panjang lintasan panjang.

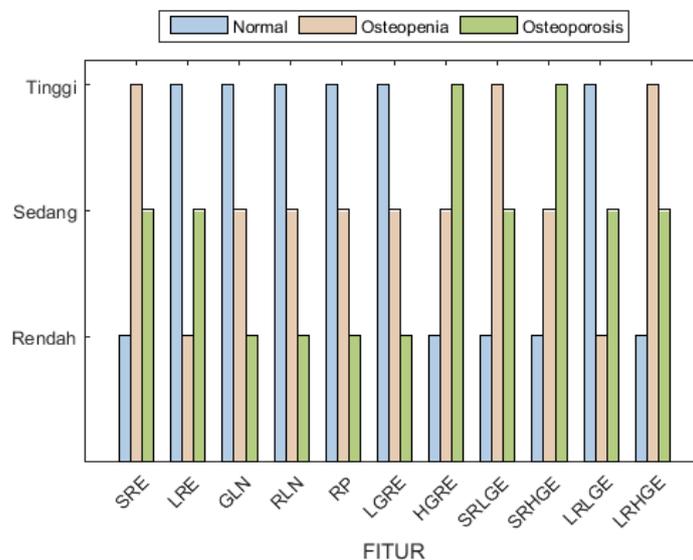


Gambar 4.17 Boxplot Citra DPR Fitur LRHGE Semua Sudut

Berdasarkan Gambar 4.17 data citra DPR tulang osteopenia memiliki nilai fitur LRHGE lebih tinggi baik pada sudut 0° , 45° , 90° , maupun 135° dibandingkan dengan data citra DPR pada tulang normal dan osteoporosis. Pada sudut 0° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.2475 sampai dengan 0.6212 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1627 – 0.4078) dan citra DPR tulang osteoporosis (0.2442 – 0.4050). Pada sudut 45° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.2535 sampai dengan 0.6246 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1767 – 0.4248) dan citra DPR tulang osteoporosis (0.3198 – 0.5433).

Pada sudut 90° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.2208 sampai dengan 0.5637 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1758 – 0.4228) dan citra DPR tulang osteoporosis (0.2547 – 0.4501). Pada sudut 135° citra DPR pada tulang osteopenia memiliki rentang nilai sekitar 0.2534 sampai dengan 0.5418 pada semua sudut. Nilai tersebut juga beririsan dengan rentang nilai dari citra DPR tulang normal (0.1806 – 0.4072) dan citra DPR tulang osteoporosis (0.2022 – 0.3323). Nilai fitur LRHGE yang tinggi menunjukkan bahwa citra tersebut memiliki tingkat keabuan

yang tinggi serta panjang lintasan panjang.



Gambar 4.18 Diagram Batang Hasil Fitur

Berdasarkan Gambar 4.18 citra DPR tulang normal memiliki nilai yang tinggi pada fitur LRE, GLN, RLN, RP, LGRE, dan LRLGE, serta memiliki nilai rendah pada fitur SRE, HGRE, SRLGE, SRHGE, dan LRHGE. Sedangkan citra DPR tulang osteopenia memiliki nilai tinggi pada fitur SRE, SRLGE, dan LRHGE, serta memiliki nilai rendah pada fitur LRE dan LRLGE. Adapun citra DPR tulang osteoporosis memiliki nilai tinggi pada fitur HGRE dan SRHGE, serta memiliki nilai rendah pada fitur GLN, RLN, RP, dan LGRE.

Informasi yang dapat diperoleh dari ekstraksi fitur tekstur citra DPR tulang normal cenderung memiliki tekstur yang kasar dengan tingkat keabuan rendah dan memiliki *run length* pendek. Sedangkan pada citra DPR tulang osteopenia cenderung memiliki tekstur halus dengan tingkat keabuan dan *run length* sedang. Adapun citra DPR tulang osteoporosis memiliki tingkat keabuan tinggi dan tingkat keabuan serta panjang lintasan tidak seragam. Hasil *boxplot* juga menunjukkan bahwa setiap data citra DPR memiliki rentang nilai yang saling beririsan sehingga diperlukan metode

Neural Network untuk mengklasifikasikan data.

4.3. Klasifikasi Osteoporosis Menggunakan Metode Backpropagation

Pada penelitian ini proses klasifikasi dilakukan dengan menggunakan *Neural Network* metode *Backpropagation*. Hasil yang telah diperoleh pada tahap sebelumnya yaitu ekstraksi fitur tekstur yang berjumlah 11 fitur akan digunakan sebagai *input* pada tahap ini. Data hasil ekstraksi fitur akan dibagi menggunakan *k-fold cross validation* menjadi data *training* dan data *testing* dengan nilai *k* yang digunakan sebesar 5 dan 10 yang dapat dilihat pada Tabel 4.5. Data yang digunakan sebagai *input* proses klasifikasi berupa matriks yang berukuran $M \times N$, dimana M merupakan jumlah data sedangkan N merupakan jumlah fitur GLRLM.

Tabel 4.5 Pembagian Data K-Fold Cross Validation

<i>K-Fold</i>	<i>Training</i>	<i>Testing</i>
5	136×11	34×11
	136×11	34×11
	136×11	34×11
	136×11	34×11
	136×11	34×11
10	153×11	17×11
	153×11	17×11
	153×11	17×11
	153×11	17×11
	153×11	17×11
	153×11	17×11
	153×11	17×11
	153×11	17×11
	153×11	17×11

Proses klasifikasi dengan metode *Backpropagation* melakukan perhitungan dengan menggunakan Persamaan 2.20 hingga Persamaan 2.34. Adapun langkah pertama pada *Backpropagation* adalah melakukan inisialisasi bobot dan bias secara *random* dan menentukan nilai parameter-parameter yang akan digunakan seperti *learning rate*, jumlah *node hidden*, jumlah *hidden layer*, dan momentum. Pada

penelitian ini nilai *learning rate*, jumlah *hidden layer*, dan jumlah *node hidden* akan dilakukan uji coba. Berikut merupakan bobot dan bias awal pada *hidden layer* 1 dan *node hidden* 100 yang dapat dilihat pada Tabel 4.6 dan Tabel 4.7.

Tabel 4.6 Bobot dan Bias antara *Input* dan *Hidden Layer*

	v_1	v_2	v_3	v_4	v_5	...	v_{100}
v_0	-3.9233	3.3932	-2.3473	-3.2068	4.9150	...	-6.6412
x_1	3.6010	-3.4253	1.0995	3.3361	-3.0051	...	-4.5438
x_2	-2.0478	2.6801	-0.8380	4.8082	-5.2281	...	3.9856
x_3	0.8474	-5.3171	-2.7576	-3.8721	2.6259	...	2.8736
x_4	-2.2734	0.7905	1.4466	-0.4942	3.2011	...	2.4276
x_5	-4.1023	-1.3516	-3.7951	-1.3673	-2.1283	...	-2.6232
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
x_{11}	4.2977	-4.2980	3.8532	1.9849	-1.3190	...	1.5174

Tabel 4.7 Bobot dan Bias antara *Hidden* dan *Output Layer*

	w_0	z_1	z_2	z_3	z_4	...	z_{100}
w_1	-0.3655	-0.2654	0.3994	-0.4528	-0.7101	...	0.9886

Bobot, bias, serta parameter yang telah diinputkan akan digunakan untuk menghitung masukan pada *hidden layer* dengan menggunakan Persamaan 2.20. Perhitungan tersebut dilakukan secara berulang sebanyak jumlah *node* yang terdapat pada *hidden layer* dimana pada perhitungan ini jumlah *node hidden layer* sebanyak 100 sehingga perhitungan akan dilakukan sebanyak 100 kali.

$$z_{inj} = v_{j0} + \sum_{i=1}^n x_i v_{ji}$$

$$z_{in1} = -3.9233 + ((0.3384 \times 3.6010) + (0.4513 \times -2.0478) + \dots + (0.1781 \times 4.2977))$$

$$= -12.0793$$

Setelah diperoleh nilai dari z_{in1} sampai dengan z_{in100} selanjutnya yaitu menghitung nilai pada *hidden layer* dengan menggunakan Persamaan 2.21. Pada perhitungan ini membutuhkan fungsi aktivasi. Adapun fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid biner. Perhitungan dilakukan secara berulang sebanyak jumlah *node* yang terdapat pada *hidden layer* dimana pada perhitungan ini jumlah *node hidden layer* sebanyak 100 sehingga perhitungan akan dilakukan sebanyak 100 kali.

$$z_j = f(z_{inj}) = \frac{1}{1 + \exp^{-z_{inj}}}$$

$$z_1 = \frac{1}{1 + \exp^{-(-12.0793)}}$$

$$= 0.00000568$$

Setelah diperoleh nilai dari z_1 sampai dengan z_{100} selanjutnya yaitu menghitung masukan pada *output layer* dengan menggunakan Persamaan 2.22. Perhitungan hanya dilakukan 1 kali sesuai dengan jumlah *node* pada *output layer* yaitu 1.

$$y_{ink} = w_{k0} + \sum_{j=1}^p z_j w_{kj}$$

$$y_{in1} = -0.3655 + ((0.00000568 \times -0.2654) + (0.9941 \times 0.3994) + \dots$$

$$+ (0.0004 \times 0.9886))$$

$$= -0.1707$$

Setelah diperoleh nilai dari y_{in1} selanjutnya yaitu menghitung nilai pada *output layer* dengan menggunakan Persamaan 2.23. Pada perhitungan ini membutuhkan fungsi aktivasi. Adapun fungsi aktivasi yang digunakan adalah fungsi aktivasi linear. Perhitungan hanya dilakukan 1 kali sesuai dengan jumlah *node* pada *output layer* yaitu 1.

$$y_k = f(y_{ink}) = y_{ink}$$

$$y_1 = -0.1707$$

Tahap *forward propagation* berakhir setelah diperoleh nilai dari *output layer* (y_1). Selanjutnya yaitu tahap *backward propagation* yang digunakan untuk menghitung kesalahan pada setiap *layer*. Sesuai dengan namanya, tahap ini berjalan mundur dari *output layer* ke *input layer* yang diawali dengan menghitung kesalahan pada *output layer* menggunakan Persamaan 2.24. Perhitungan hanya dilakukan 1 kali sesuai dengan jumlah *node* pada *output layer* yaitu 1.

$$\delta_k = (t_k - y_k) f'(y_{ink})$$

$$\begin{aligned} \delta_1 &= (0 - (-0.1707))(1) \\ &= 0.1707 \end{aligned}$$

Setelah diperoleh nilai dari δ_1 selanjutnya yaitu menghitung koreksi bobot w antara *hidden layer* dan *output layer* dengan menggunakan Persamaan 2.25 dan 2.26. Pada perhitungan ini membutuhkan *learning rate*. Adapun nilai *learning rate* yang digunakan sebesar 0.6. Perhitungan dilakukan secara berulang sebanyak jumlah *node* yang terdapat pada *output layer* dikali jumlah *node* yang terdapat pada *hidden layer* dimana pada perhitungan ini jumlah *node output layer* sebanyak 1 dan jumlah *node hidden layer* sebanyak 100 sehingga perhitungan akan dilakukan sebanyak 100 kali.

$$\Delta w_{kj} = \alpha \delta_k z_j$$

$$\begin{aligned} \Delta w_{11} &= 0.6 \times (0.1707 \times (0.00000568)) \\ &= 0.0005811 \end{aligned}$$

$$\Delta w_{k0} = \alpha \delta_k$$

$$\begin{aligned}\Delta w_{10} &= 0.6 \times (0.1707) \\ &= 0.1024\end{aligned}$$

Setelah diperoleh nilai dari Δw_{11} sampai dengan Δw_{1100} dan juga Δw_{10} selanjutnya yaitu menghitung *error* pada masukan *hidden layer* menggunakan Persamaan 2.27. Perhitungan dilakukan secara berulang sebanyak jumlah *node* yang terdapat pada *hidden layer* dimana pada perhitungan ini jumlah *node hidden layer* sebanyak 100 sehingga perhitungan akan dilakukan sebanyak 100 kali.

$$\begin{aligned}\delta_{in,j} &= \sum_{k=1}^p \delta_k w_{kj} \\ \delta_{in,1} &= ((0.1707 \times -0.2654) + (0.1707 \times 0.3994) + \dots + (0.1707 \times 0.9886)) \\ &= -0.0453\end{aligned}$$

Setelah diperoleh nilai dari $\delta_{in,1}$ sampai dengan $\delta_{in,100}$ dan juga Δw_{k0} selanjutnya yaitu menghitung *error* pada *hidden layer* dengan menggunakan Persamaan 2.28. Perhitungan dilakukan secara berulang sebanyak jumlah *node* yang terdapat pada *hidden layer* dimana pada perhitungan ini jumlah *node hidden layer* sebanyak 100 sehingga perhitungan akan dilakukan sebanyak 100 kali.

$$\begin{aligned}\delta_j &= \delta_{in,j} f'(z_{in,j}) \\ \delta_1 &= -0.0453 \times (0.00000568)(1 - (0.00000568)) \\ &= -0.000257\end{aligned}$$

Setelah diperoleh nilai dari δ_1 sampai dengan δ_{100} selanjutnya yaitu menghitung koreksi bobot dan bias antara *input* dan *hidden layer* dengan menggunakan Persamaan 2.30 dan 2.31. Pada perhitungan ini membutuhkan *learning rate*. Adapun nilai *learning rate* yang digunakan sebesar 0.6. Perhitungan dilakukan secara berulang sebanyak jumlah *node* yang terdapat pada *input layer*

dikali jumlah *node* yang terdapat pada *hidden layer* dimana pada perhitungan ini jumlah *node input layer* sebanyak 11 dan jumlah *node hidden layer* sebanyak 100 sehingga perhitungan akan dilakukan sebanyak 1100 kali.

$$\Delta v_{ji} = \alpha \delta_j x_i$$

$$\begin{aligned} \Delta v_{11} &= 0.6 \times (-0.000257) \times (0.3384) \\ &= -0.00005219 \end{aligned}$$

$$\Delta v_{j0} = \alpha \delta_j$$

$$\begin{aligned} \Delta v_{10} &= 0.6 \times (-0.000257) \\ &= -0.0001542 \end{aligned}$$

Tahap *backward propagation* berakhir setelah diperoleh nilai koreksi bobot Δv_{11} sampai dengan Δv_{11100} dan bias Δv_{10} sampai dengan Δv_{110} . Selanjutnya yaitu tahap *update* bobot dan bias dengan menjumlahkan nilai dari bobot lama dengan koreksi bobot yang diperoleh dengan menggunakan Persamaan 2.32 dan 2.34.

$$\begin{aligned} w_{kj}(\text{baru}) &= w_{kj}(\text{lama}) + \Delta w_{kj} \\ &= (-0.2654) + (0.0005811) \\ &= -0.2654 \end{aligned}$$

$$\begin{aligned} w_{k0}(\text{baru}) &= w_{k0}(\text{lama}) + \Delta w_{k0} \\ &= (-0.3655) + (0.1024) \\ &= -0.2631 \end{aligned}$$

$$\begin{aligned} v_{ji}(\text{baru}) &= v_{ji}(\text{lama}) + \Delta v_{ji} \\ &= (3.6010) + (-0.00005219) \\ &= 3.6010 \end{aligned}$$

$$\begin{aligned}
 v_{j0}(\text{baru}) &= v_{j0}(\text{lama}) + \Delta v_{j0} \\
 &= (-3.9233) + (-0.0001542) \\
 &= -3.9233
 \end{aligned}$$

Optimalisasi *Backpropagation* dapat dilakukan dengan menggunakan nilai momentum. Penggunaan momentum ini dapat digunakan pada saat iterasi kedua, ketiga, dan seterusnya karena perhitungan ini akan melibatkan hasil dari iterasi sebelumnya. Adapun nilai momentum yang digunakan pada penelitian ini sebesar 0.9.

$$\begin{aligned}
 w_{kj}(\text{baru}) &= w_{kj}(\text{lama}) + \Delta w_{kj} + \beta \Delta w_{kj}(\text{lama}) \\
 &= (-0.2654) + (0.0005811) + 0.9(-0.2654 - (-0.2654)) \\
 &= -0.2654
 \end{aligned}$$

$$\begin{aligned}
 w_{k0}(\text{baru}) &= w_{k0}(\text{lama}) + \Delta w_{k0} + \beta \Delta w_{k0}(\text{lama}) \\
 &= (-0.2631) + (0.1024) + 0.9(-0.2631 - (-0.3655)) \\
 &= -0.0685
 \end{aligned}$$

$$\begin{aligned}
 v_{ji}(\text{baru}) &= v_{ji}(\text{lama}) + \Delta v_{ji} + \beta \Delta v_{ji}(\text{lama}) \\
 &= (3.6010) + (-0.00005219) + 0.9(3.6010 - (3.6010)) \\
 &= 3.6010
 \end{aligned}$$

$$\begin{aligned}
 v_{j0}(\text{baru}) &= v_{j0}(\text{lama}) + \Delta v_{j0} + \beta \Delta v_{j0}(\text{lama}) \\
 &= (-3.9233) + (-0.0001542) + 0.9(-3.9233 - (-3.9233)) \\
 &= -3.9233
 \end{aligned}$$

Bobot dan bias yang telah *diupdate* akan digunakan untuk perhitungan data selanjutnya. Seluruh rangkaian proses *Backpropagation* akan berhenti apabila batas toleransi telah terpenuhi.

4.4. Evaluasi Sistem Hasil Klasifikasi Osteoporosis

Proses deteksi osteoporosis menggunakan *Neural Network* metode *Backpropagation* dipengaruhi oleh pembagian data dan arah sudut GLRLM. Selain itu dapat juga dipengaruhi oleh parameter yang digunakan seperti jumlah *hidden layer*, jumlah *node hidden* dan *learning rate*. Uji coba yang digunakan untuk pembagian data adalah *k-fold cross validation* dengan nilai *k* sebesar 5 dan 10. Sedangkan uji coba arah sudut GLRLM yang digunakan adalah 0° , 45° , 90° , dan 135° . Adapun parameter-parameter yang diuji coba yaitu jumlah *hidden layer* sebanyak 1 dan 2, jumlah *node hidden* sebanyak 50, 100, dan 150, dan terakhir uji coba parameter *learning rate* mulai dari 0.1 hingga 0.9.

Hasil dari seluruh uji coba tersebut akan dievaluasi menggunakan *confusion matrix multiclass* berdasarkan nilai akurasi, sensitivitas, dan spesifisitas. Berikut merupakan hasil *confusion matrix multiclass* pada salah satu uji coba lengkap dengan perhitungan TP, FN, FP, dan TN serta akurasi, sensitivitas, dan spesifisitas.

Tabel 4.8 Confusion Matrix Multiclass Fold 1

Kelas Aktual	Kelas Prediksi		
	Normal	Osteopenia	Osteoporosis
Normal	8	3	0
Osteopenia	4	7	0
Osteoporosis	0	3	9

Tabel 4.9 *Confusion Matrix Multiclass Fold 2*

Kelas Aktual	Kelas Prediksi		
	Normal	Osteopenia	Osteoporosis
Normal	11	1	0
Osteopenia	0	10	0
Osteoporosis	0	2	10

Tabel 4.10 *Confusion Matrix Multiclass Fold 3*

Kelas Aktual	Kelas Prediksi		
	Normal	Osteopenia	Osteoporosis
Normal	9	3	0
Osteopenia	0	10	0
Osteoporosis	0	2	10

Tabel 4.11 *Confusion Matrix Multiclass Fold 4*

Kelas Aktual	Kelas Prediksi		
	Normal	Osteopenia	Osteoporosis
Normal	9	3	0
Osteopenia	0	10	0
Osteoporosis	0	1	11

Tabel 4.12 *Confusion Matrix Multiclass Fold 5*

Kelas Aktual	Kelas Prediksi		
	Normal	Osteopenia	Osteoporosis
Normal	10	1	0
Osteopenia	1	10	0
Osteoporosis	0	1	11

Hasil *confusion matrix* pada Tabel 4.8 sampai 4.12 merupakan hasil uji coba saat menggunakan nilai $k = 5$, jumlah *hidden layer* 1, jumlah *node hidden* 100, dan *learning rate* 0.1 pada sudut 135° . Selanjutnya nilai-nilai tersebut akan digunakan untuk mencari nilai TP, FN, FP, dan TN dengan menggunakan Persamaan 2.36, 2.37, 2.38, dan 2.39. Berikut contoh perhitungan nilai TP, FN, FP, dan TN pada *fold* 5.

$$n_{all} = 10 + 1 + 0 + 1 + 10 + 0 + 0 + 1 + 11 = 34$$

$$TP_{all} = \sum_{j=i}^n x_{jj}$$

$$TP_1 = 10$$

$$TP_2 = 10$$

$$TP_3 = 11$$

$$TP_{all} = 10 + 10 + 11 = 31$$

$$FN_i = \sum_{j=1}^n \& j \neq i x_{ij}$$

$$FN_1 = 1 + 0 = 1$$

$$FN_2 = 1 + 0 = 1$$

$$FN_3 = 0 + 1 = 1$$

$$FP_i = \sum_{j=1}^n \& j \neq i x_{ji}$$

$$FP_1 = 1 + 0 = 1$$

$$FP_2 = 1 + 1 = 2$$

$$FP_3 = 0 + 0 = 0$$

$$TN_i = \sum_{j=1}^n \& j \neq i \sum_{k=1}^n \& k \neq i x_{jk}$$

$$TN_1 = 10 + 0 + 1 + 11 = 22$$

$$TN_2 = 10 + 0 + 0 + 11 = 21$$

$$TN_3 = 10 + 1 + 10 + 1 = 22$$

Nilai TP, FN, FP, dan TN yang telah diperoleh akan digunakan untuk mencari nilai dari akurasi, sensitivitas, dan spesifisitas dengan menggunakan Persamaan 2.40, 2.41, dan 2.42.

$$\begin{aligned} \text{Akurasi} &= \frac{TP_{all}}{n_{all}} \times 100\% \\ &= \frac{31}{34} \times 100\% = 91.18\% \end{aligned}$$

$$\begin{aligned} \text{Sensitivitas} &= \frac{\sum_{i=1}^n \frac{TP_i}{TP_i + FN_i}}{n} \times 100\% \\ &= \frac{\frac{10}{10+1} + \frac{10}{10+1} + \frac{11}{11+1}}{3} \times 100\% \\ &= \frac{2.7348}{3} \times 100\% = 91.16\% \end{aligned}$$

$$\begin{aligned} \text{Spesifisitas} &= \frac{\sum_{i=1}^n \frac{TN_i}{TN_i + FP_i}}{n} \times 100\% \\ &= \frac{\frac{22}{22+1} + \frac{21}{21+2} + \frac{22}{22+0}}{3} \times 100\% \\ &= \frac{2.8696}{3} \times 100\% = 95.65\% \end{aligned}$$

Hasil perhitungan *confusion matrix* pada setiap *k-fold* dapat dilihat pada Tabel 4.13.

UIN SUNAN AMPEL
S U R A B A Y A

Tabel 4.13 Hasil Uji Coba Sudut 135° Node Hidden 100 Learning Rate 0.1

Hidden Layer	K-Fold	Fold	Evaluasi (%)		
			Akurasi	Sensitivitas	Spesifisitas
1	5	1	70.59	70.45	85.51
		2	91.18	91.67	95.83
		3	85.29	86.11	93.06
		4	88.24	88.89	94.44
		5	91.18	91.16	95.65
		Rata-Rata	85.29	85.66	92.90
	10	1	58.82	57.78	79.29
		2	88.24	87.78	94.19
		3	94.12	94.44	97.22
		4	82.35	81.11	91.16
		5	82.35	81.11	91.16
		6	70.59	68.89	85.35
		7	94.12	94.44	97.22
		8	82.35	83.33	91.67
		9	88.24	88.89	94.44
10		94.12	94.44	97.22	
	Rata-Rata	83.53	83.22	91.89	
2	5	1	67.65	67.17	84.06
		2	79.41	80.00	90.15
		3	100.00	100.00	100.00
		4	88.24	88.89	94.44
		5	88.24	88.13	94.07
		Rata-Rata	84.71	84.84	92.55
	10	1	58.82	57.78	79.55
		2	100.00	100.00	100.00
		3	82.35	83.33	91.67
		4	94.12	94.44	97.22
		5	82.35	81.11	91.16
		6	82.35	82.22	91.41
		7	82.35	83.33	91.67
		8	82.35	83.33	91.67
		9	82.35	83.33	91.67
10		88.24	87.78	94.19	
	Rata-Rata	83.53	83.67	92.02	

Hasil yang digunakan pada penelitian ini merupakan hasil rata-rata dari seluruh *k-fold* yang dapat dilihat pada Tabel 4.14.

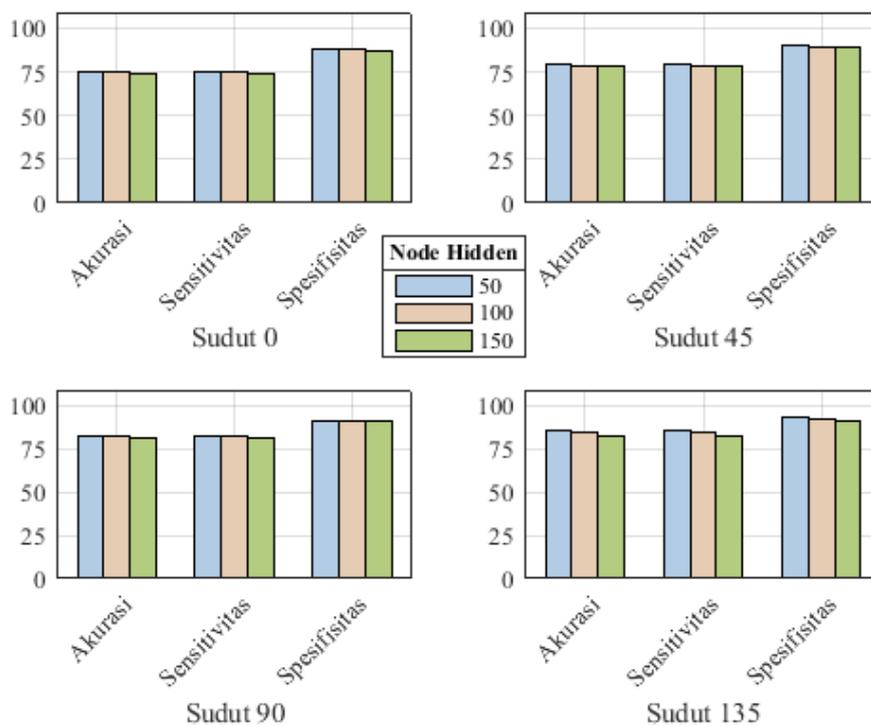
Tabel 4.14 Hasil Rata-Rata Uji Coba Sudut 135° Node Hidden 100

Hidden Layer	K-Fold	Learning Rate	Evaluasi (%)		
			Akurasi	Sensitivitas	Spesifisitas
1	5	0.1	85.29	85.66	92.90
		0.2	82.94	83.23	91.76
		0.3	85.29	85.51	92.87
		0.4	87.65	87.98	94.07
		0.5	84.71	84.79	92.55
		0.6	83.53	83.56	91.99
		0.7	82.35	82.57	91.47
		0.8	86.47	86.67	93.43
		0.9	84.71	84.89	92.56
	10	0.1	83.53	83.22	91.89
		0.2	80.59	81.00	90.63
		0.3	81.76	82.22	91.26
		0.4	78.24	78.89	89.57
		0.5	82.35	82.33	91.39
		0.6	89.41	89.44	94.85
		0.7	87.06	87.11	93.69
		0.8	82.94	83.33	91.79
		0.9	80.59	80.67	90.58
2	5	0.1	84.71	84.84	92.55
		0.2	81.76	81.91	91.13
		0.3	84.71	84.73	92.54
		0.4	81.76	82.00	91.11
		0.5	85.88	86.00	93.13
		0.6	88.24	88.37	94.30
		0.7	83.53	83.46	91.94
		0.8	81.76	81.63	91.08
		0.9	88.82	88.99	94.56
	10	0.1	83.53	83.67	92.02
		0.2	82.94	83.00	91.69
		0.3	83.53	83.78	92.02
		0.4	85.29	85.33	92.83
		0.5	85.29	85.56	92.85
		0.6	83.53	83.56	91.94
		0.7	83.53	83.44	91.94
		0.8	84.12	84.11	92.22
		0.9	85.29	85.22	92.78

Hasil terbaik dari seluruh uji coba yang telah dilakukan adalah pada saat uji coba *k-fold cross validation* dengan nilai *k* sebesar 10, sudut 135°, jumlah *hidden layer* 1, jumlah *node* pada *hidden layer* 100, dan *learning rate* 0.6.

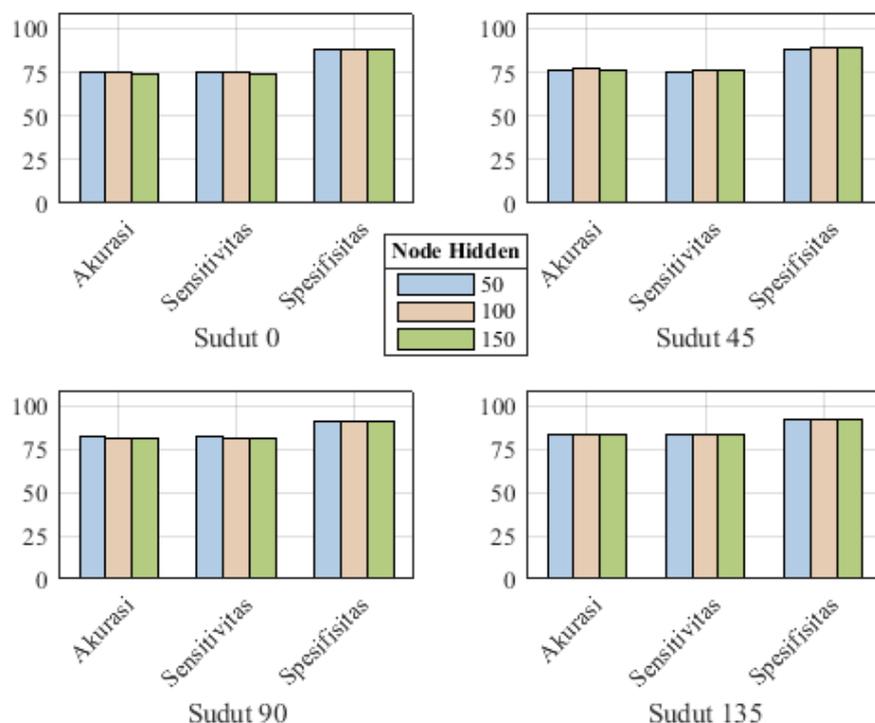
Pada penelitian ini uji coba yang dilakukan cukup banyak, sehingga untuk mempermudah dalam mengetahui model optimal dari seluruh uji coba akan dihitung

rata-rata yang akan ditampilkan pada grafik. Grafik rata-rata uji coba dapat dilihat pada Gambar 4.19, 4.20, 4.21, dan 4.22.



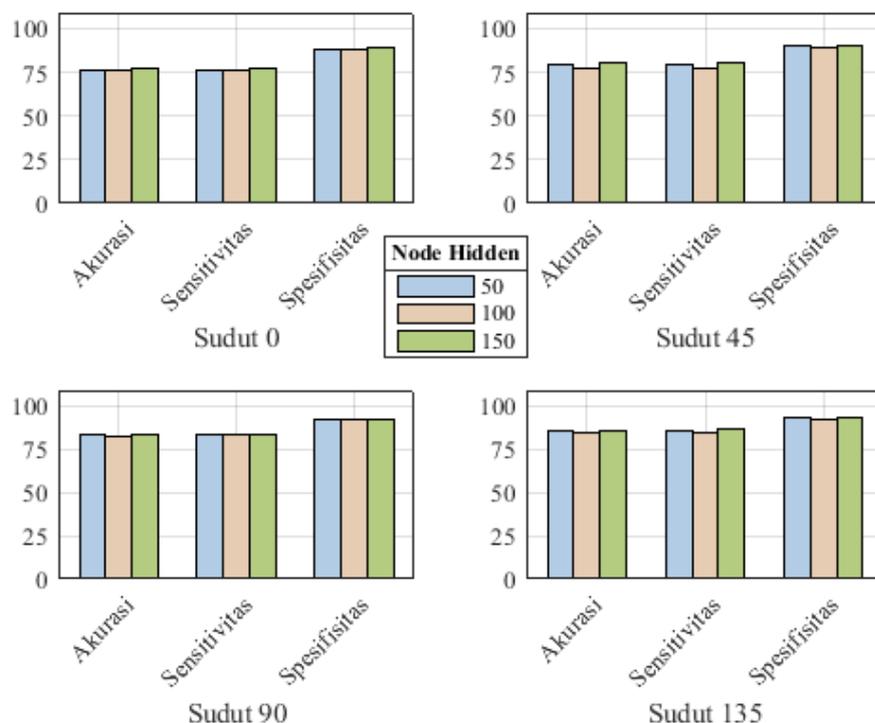
Gambar 4.19 Hasil Rata-Rata Perbandingan *Node Hidden* Pada *K-Fold 5 Hidden Layer 1*

Gambar 4.19 menunjukkan diagram batang dari hasil rata-rata nilai *learning rate* mulai dari 0.1 sampai dengan 0.9. Perhitungan rata-rata ini ditujukan untuk mencari model optimal dari *node hidden* yang stabil. Berdasarkan Gambar 4.19 pada sudut 0° *node hidden* 50 dan 100 memiliki nilai rata-rata yang sama yaitu 75.42% untuk sensitivitas dan 75.49% untuk akurasi. Begitu pula pada sudut 90° dan 135° yang mana pada sudut tersebut nilai rata-rata dari *node hidden* 50 dan 100 hampir sama sebesar 82.61% dan 82.57% untuk sensitivitas pada sudut 90° , serta 85.22% dan 84.98% untuk sensitivitas pada sudut 135° . Sedangkan pada sudut 45° nilai rata-rata yang hampir sama pada *node hidden* 100 dan 150, dengan nilai rata-rata sensitivitas sebesar 78.30% dan 78.26%.



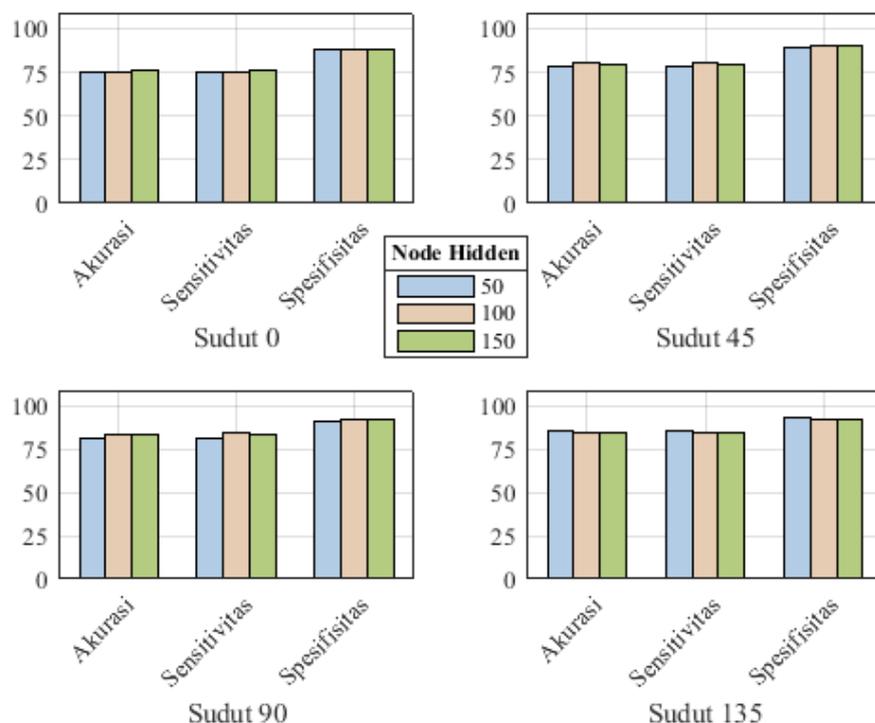
Gambar 4.20 Hasil Rata-Rata Perbandingan *Node Hidden* Pada *K-Fold 10 Hidden Layer 1*

Gambar 4.20 menunjukkan diagram batang dari hasil rata-rata nilai *learning rate* mulai dari 0.1 sampai dengan 0.9. Perhitungan rata-rata ini ditujukan untuk mencari model optimal dari *node hidden* yang stabil. Berdasarkan Gambar 4.20 pada sudut 0° ketiga *node hidden* memiliki nilai rata-rata yang hampir sama baik pada nilai akurasi, sensitivitas, dan spesifisitas. Nilai rata-rata sensitivitas pada sudut 0° masing-masing sebesar 74.80%, 74.81%, dan 74.25%. Sedangkan pada sudut 45° dan 135° *node hidden* 100 dan 150 memiliki nilai rata-rata yang hampir sama yaitu sebesar 76.60% dan 76.41% untuk sensitivitas pada sudut 45°, serta 83.14% dan 83.26% untuk sensitivitas pada sudut 135°. Adapun nilai rata-rata pada sudut 90° yang hampir sama yaitu pada *node hidden* 50 dan 100 dengan nilai sensitivitas sebesar 82.10% dan 81.58%.



Gambar 4.21 Hasil Rata-Rata Perbandingan *Node Hidden* Pada *K-Fold 5 Hidden Layer 2*

Gambar 4.21 menunjukkan diagram batang dari hasil rata-rata nilai *learning rate* mulai dari 0.1 sampai dengan 0.9. Perhitungan rata-rata ini ditujukan untuk mencari model optimal dari *node hidden* yang stabil. Berdasarkan Gambar 4.21 pada sudut 0° dan 135° *node hidden* 50 dan 100 memiliki nilai yang hampir sama sebesar 75.81% dan 75.96% untuk sensitivitas pada sudut 0° serta 85.42% dan 84.66% untuk sensitivitas pada sudut 135. Sedangkan pada sudut 45° *node hidden* yang memiliki nilai hampir sama adalah *node hidden* 50 dan 150 dengan nilai rata-rata sensitivitas sebesar 79.69% dan 80.53%. Adapun pada sudut 90° ketiga *node hidden* memiliki nilai yang hampir sama sebesar 83.31%, 82.96%, dan 83.00% untuk nilai sensitivitasnya.



Gambar 4.22 Hasil Rata-Rata Perbandingan *Node Hidden* Pada *K-Fold 10 Hidden Layer 2*

Gambar 4.22 menunjukkan diagram batang dari hasil rata-rata nilai *learning rate* mulai dari 0.1 sampai dengan 0.9. Perhitungan rata-rata ini ditujukan untuk mencari model optimal dari *node hidden* yang stabil. Berdasarkan Gambar 4.22 pada sudut 0° *node hidden* 50 dan 100 memiliki nilai rata-rata yang hampir sama sebesar 74.77% dan 74.58% untuk nilai sensitivitas. Sedangkan pada sudut 90° *node hidden* 100 memiliki nilai yang hampir sama dengan *node* 150 sebesar 84.01% dan 83.58% untuk nilai sensitivitas. Adapun pada sudut 45° dan 135° nilai rata-rata yang diperoleh bervariasi dalam artian *node hidden* memiliki selisih nilai lebih dari 1.

Informasi yang dapat diperoleh dari Gambar 4.19 sampai 4.20 adalah model terbaik pada saat uji coba *k-fold cross validation* dengan nilai $k = 5$ yaitu 11-50-1, sedangkan pada saat uji coba dengan nilai $k = 10$ model terbaik yaitu 11-100-1. Adapun informasi yang dapat diperoleh dari Gambar 4.21 sampai 4.22 adalah model

terbaik pada saat uji coba *k-fold cross validation* dengan nilai $k = 5$ yaitu 11-50-50-1, sedangkan pada saat uji coba dengan nilai $k = 10$ model terbaik yaitu 11-100-100-1.

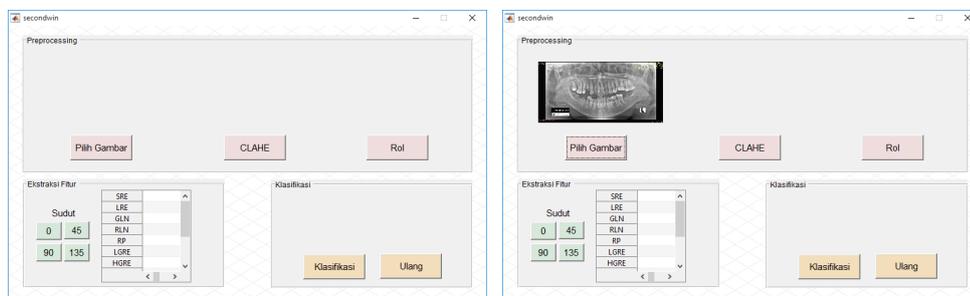
4.5. Aplikasi Deteksi Osteoporosis

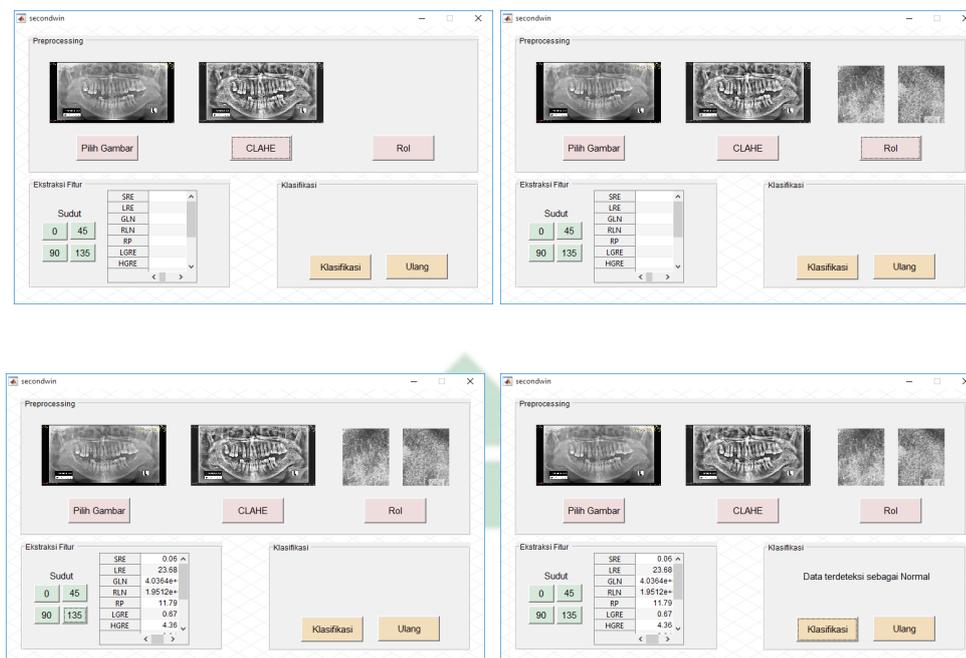
Pada tahap sebelumnya telah diperoleh model dengan parameter uji coba yang menghasilkan akurasi terbaik. Model tersebut akan digunakan untuk membuat aplikasi deteksi osteoporosis. Aplikasi ini diharapkan dapat mempermudah tenaga medis dalam mendeteksi osteoporosis. Tampilan awal dari aplikasi deteksi osteoporosis terlihat pada Gambar 4.23.



Gambar 4.23 Tampilan Awal Aplikasi

Selanjutnya dengan menekan tombol 'Mulai' maka akan muncul tampilan kedua, dimana pada *user* akan diperintahkan untuk memasukkan gambar citra DPR yang ingin dideteksi.





Gambar 4.25 Tampilan Kedua Aplikasi

Data yang telah dimasukkan akan dilakukan *preprocessing* terlebih dahulu dengan melakukan peningkatan kontras CLAHE dan pemfokusan area dengan ROI pada bagian kiri dan kanan. Tahap selanjutnya adalah ekstraksi fitur tekstur GLRLM dengan empat sudut, dimana user dipersilahkan memilih sudut yang diinginkan. Selanjutnya hasil ekstraksi fitur tekstur dengan 11 fitur akan ditampilkan pada tabel yang kemudian dapat digunakan untuk proses klasifikasi BPNN (*Backpropagation Neural Network*).

4.6. Integrasi Keislaman

Pada penelitian ini digunakan beberapa uji coba seperti sudut orientasi, *k-fold cross validation*, jumlah *node* pada *hidden layer*, jumlah *hidden layer*, dan uji coba *learning rate*. Uji coba tersebut ditujukan untuk memperoleh model yang paling optimal. Hal ini sesuai dengan QS. Al-Ankabut ayat 69 yang memerintahkan hambanya untuk bersungguh-sungguh dalam menjalankan segala sesuatu.

وَالَّذِينَ جَاهَدُوا فِينَا لَنَهْدِيَنَّهُمْ سُبُلَنَا وَإِنَّ اللَّهَ لَمَعَ الْمُحْسِنِينَ

Artinya: Dan orang-orang yang berjihad untuk (mencari keridhaan) Kami, benar-benar akan Kami tunjukkan kepada mereka jalan-jalan Kami. Dan sesungguhnya Allah benar-benar beserta orang-orang yang berbuat baik. (QS. Al-Ankabut: 69).

Selain pada ayat Al-Quran terdapat juga pepatah arab yang menjelaskan terkait kesungguhan serta harus maju terus pantang mundur.

مَنْ طَلَبَ شَيْئًا وَجَدَ وَجَدَ، وَمَنْ قَرَعَ الْبَابَ وَجَحَّ وَجَحَّ

Artinya: “Barangsiapa bersungguh-sungguh dalam mencari sesuatu maka pasti mendapatkan, dan barangsiapa yang mengetuk pintu dan maju pantang mundur, maka pasti dapat masuk.”

Islam tidak hanya memerintahkan umatnya agar bersungguh-sungguh dalam melaksanakan segala sesuatu akan tetapi juga memerintahkan umatnya agar senantiasa melakukan muhasabah sebagai bentuk perenungan diri atas apa saja yang telah dilakukan dengan tujuan untuk mengintrospeksi diri agar lebih baik lagi kedepannya. Salah satu hadis yang memerintahkan untuk melakukan muhasabah adalah hadis yang diriwayatkan oleh yang berbunyi:

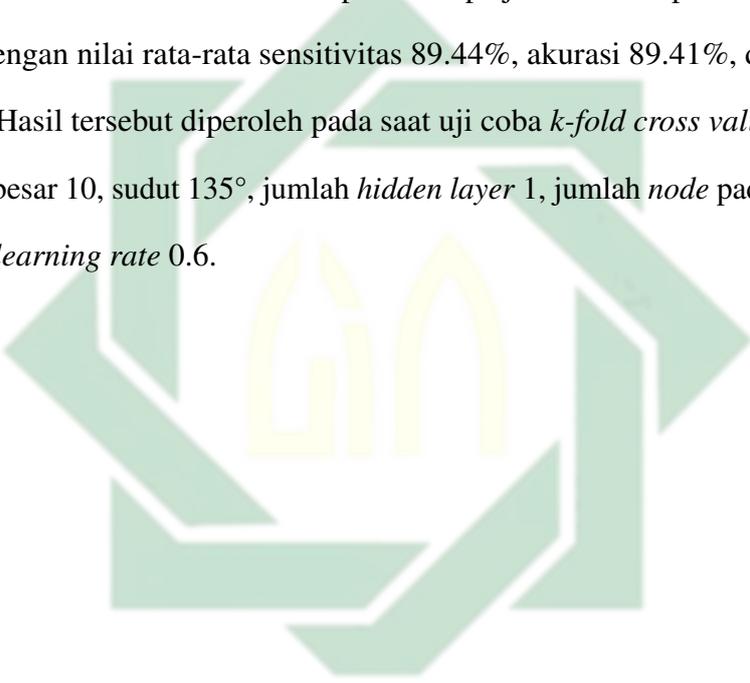
عَنْ أَنَسٍ قَالَ قَالَ رَسُولُ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ طُوبَى لِمَنْ شَغَلَهُ عَيْبُهُ عَنْ عَيْبِ النَّاسِ

artinya: “Bahagialah orang yang sibuk memperhatikan aib diri sendiri ketimbang memperhatikan aib-aib orang lain.” (HR Al-Tirmidzi dan Ibn Majah).

Pada penelitian ini uji coba dilakukan sebagai bentuk dari kesungguhan dalam menemukan model optimal atau model terbaik. Proses pencarian model optimal dilakukan dengan memperbaiki segala kekurangan sehingga dapat diperoleh hasil

yang baik. Setelah dilakukan beberapa uji coba seperti sudut orientasi 0° , 45° , 90° , dan 135° , *k-fold cross validation* dengan nilai *k* 5 dan 10, jumlah *node* pada *hidden layer* sebanyak 50, 100, dan 150, jumlah *hidden layer* sebanyak 1 dan 2, serta uji coba *learning rate* mulai dari 0.1-0.9 akan dilakukan evaluasi dengan menggunakan *confusion matrix multiclass*.

Proses evaluasi ini dilakukan pada setiap uji coba dan diperoleh hasil evaluasi terbaik dengan nilai rata-rata sensitivitas 89.44%, akurasi 89.41%, dan spesifisitas 94.84%. Hasil tersebut diperoleh pada saat uji coba *k-fold cross validation* dengan nilai *k* sebesar 10, sudut 135° , jumlah *hidden layer* 1, jumlah *node* pada *hidden layer* 100, dan *learning rate* 0.6.



UIN SUNAN AMPEL
S U R A B A Y A

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil penelitian dari Deteksi Osteoporosis Menggunakan *Neural Network* Berdasarkan Analisis Tekstur Citra *Dental Panoramic Radiography* (DPR) dapat diambil kesimpulan bahwa:

1. Ekstraksi fitur pada GLRLM menghasilkan 11 fitur diantaranya SRE, LRE, GLN, RLN, RP, LGRE, HGRE, SRLGE, SRHGE, LRLGE, dan LRHGE. Fitur-fitur pada GLRLM mampu merepresentasikan hasil dari citra DPR yang mana pada citra DPR normal cenderung memiliki tekstur lebih kasar dengan tingkat keabuan rendah, sedangkan pada citra DPR osteopenia cenderung memiliki tekstur lebih halus dan citra DPR osteoporosis cenderung memiliki tingkat keabuan tinggi.
2. Deteksi osteoporosis dengan menggunakan *Neural Network* metode *Backpropagation* menghasilkan rata-rata sensitivitas terbaik yaitu pada uji coba *k-fold cross validation* dengan nilai *k* sebesar 10, sudut 135° , jumlah *hidden layer* 1, jumlah *node* pada *hidden layer* 100, dan *learning rate* 0.6 dengan nilai rata-rata sensitivitas 89.44%, akurasi 89.41%, dan spesifisitas 94.84%.

5.2. Saran

Pada penelitian yang membahas terkait Deteksi Osteoporosis Menggunakan *Neural Network* Berdasarkan Analisis Tekstur Citra *Dental Panoramic Radiography* (DPR) ini masih terdapat banyak kekurangan. Sehingga terdapat beberapa saran yang diajukan oleh peneliti untuk penelitian mendatang diantaranya yaitu:

1. Pada penelitian ini augmentasi yang dilakukan hanya augmentasi warna berdasarkan *contrast*, sehingga dapat ditambahkan macam-macam augmentasi warna seperti augmentasi warna berdasarkan nilai *brighness*, *saturation*, dan *hue* serta dapat mengkombinasikan keempat augmentasi tersebut.
2. Pada penelitian ini ekstraksi fitur GLRLM memiliki sistem yang baik dalam proses deteksi osteoporosis, namun metode GLRLM ini memiliki dimensi yang tinggi sehingga perlu dilakukan reduksi fitur. Metode yang dapat digunakan untuk reduksi fitur yaitu *Principal Component Analysis* (PCA) dan *Linear Discriminant Analysis* (LDA).
3. Pada penelitian ini proses klasifikasi dengan BPNN (*Backpropagation Neural Network*) menggunakan fungsi aktivasi sigmoid biner dan fungsi aktivasi linear saja. Sehingga untuk penelitian selanjutnya dapat menggunakan fungsi aktivasi lain seperti sigmoid bipolar, serta menggabungkan ketiga fungsi aktivasi tersebut.

DAFTAR PUSTAKA

- Abood, L. K. (2018). Contrast enhancement of infrared images using Adaptive Histogram Equalization (AHE) with Contrast Limited Adaptive Histogram Equalization (CLAHE). *Iraqi J. Phys.*, 16(37):127–135.
- Adyanti, D. A. (2018). *Analisis citra Dental Panoramic Radiograph (DPR) pada tulang mandibula untuk deteksi osteoporosis menggunakan metode GLCM – SVM Multiclass (Gray Level Co- Occurrence Matrix – Support Vector Machine Multiclass)*. PhD thesis, Universitas Islam Negeri Sunan Ampel.
- Adyanti, D. A., Novitasari, D. C. R., and Fanani, A. (2020). Support Vector Machine Multiclass using Polynomial Kernel for Osteoporosis Detection. *Proc. Int. Conf. Math. Islam (ICMIs 2018)*, pages 384–390.
- Alaei, F., Alaei, A., Pal, U., and Blumenstein, M. (2019). A Comparative Study of Different Texture Features for Document Image Retrieval. *Expert Syst. Appl.*, pages 3–33.
- Aliaga, I., Vera, V., Vera, M., García, E., Pedrera, M., and Pajares, G. (2020). Automatic Computation of Mandibular Indices in Dental Panoramic Radiographs for Early Osteoporosis Detection. *Artif. Intell. Med.*, 103(June 2019):101816.
- Alzubaidi, M. A. and Ootom, M. (2020). A Comprehensive Study on Feature Types for Osteoporosis Classification in Dental Panoramic Radiographs. *Comput. Methods Programs Biomed.*, 188:105301.

- Andono, P. N., Sutojo, T., and Muljono (2017). *Pengolahan Citra Digital*. Penerbit ANDI, Yogyakarta.
- Ardhy, F. (2019). Implementasi Sistem Pakar Untuk Mendiagnosa Penyakit Tulang Pada Manusia Menggunakan Metode Forward Chaining. *J. Inf. dan Komput.*, 7(1):29–34.
- Arifin, E. N. N. and Rachmawati, A. S. (2022). Penerapan Senam Kaki dengan Menggunakan Koran Terhadap Penurunan Kadar Gula Darah Sewaktu pada Ny. E dengan Diabetes Melitus Tipe 2 di RT.04 RW.15 Perum Cisalak Kota Tasikmalaya. *Healthc. Nurs. J.*, 4(2b):53–58.
- Arsi, P. and Somantri, O. (2018). Deteksi Dini Penyakit Diabetes Menggunakan Algoritma Neural Network Berbasis Algoritma Genetika. *J. Inform. J. Pengemb. IT*, 3(3):290–294.
- Ayyappa, Y., Bekkanti, A., Krishna, A., Neelakanteswara, P., and Basha, C. Z. (2020). Enhanced and Effective Computerized Multi Layered Perceptron based Back Propagation Brain Tumor Detection with Gaussian Filtering. *Proc. 2nd Int. Conf. Inven. Res. Comput. Appl. ICIRCA 2020*, pages 58–62.
- Bakhshipour, A. (2021). Cascading feature filtering and boosting algorithm for plant type classification based on image features. *IEEE Access*, pages 82021–82030.
- Borkin, D., Némethová, A., Michal'čonok, G., and Maiorov, K. (2019). Impact of Data Normalization on Classification Model Accuracy. *Res. Pap. Fac. Mater. Sci. Technol. Slovak Univ. Technol.*, 27(45):79–84.
- Chandraprabha, K. and Akila, S. (2019). Texture Feature Extraction for Batik Images

- Using GLCM and GLRLM with Neural Network Classification. *Int. J. Sci. Res. Comput. Sci. Eng. Inf. Technol.*, pages 06–15.
- Chang, Y., Jung, C., Ke, P., Song, H., and Hwang, J. (2018). Automatic Contrast-Limited Adaptive Histogram Equalization with Dual Gamma Correction. *IEEE Access*, 6(c):11782–11792.
- Ding, N., Hao, Y., Wang, Z., Xuan, X., Kong, L., Xue, H., and Jin, Z. (2020). CT texture analysis predicts abdominal aortic aneurysm post-endovascular aortic aneurysm repair progression. *Sci. Rep.*, 10(1):1–10.
- Erwin and Ningsih, D. R. (2020). Improving Retinal Image Quality Using the Contrast Stretching, Histogram Equalization, and CLAHE Methods with Median Filters. *Int. J. Image, Graph. Signal Process.*, 12(2):30–41.
- Fan, H., Ren, J., Yang, J., Qin, Y.-X., and Ling, H. (2021). Osteoporosis Prescreening using Panoramic Radiographs through a Deep Convolutional Neural Network with Attention Mechanism. *arXiv Prepr.*
- Fatri, H. R. A. and Eviyanti, A. (2022). Sistem Pakar Penyakit Tulang Menggunakan Metode Certainty Factor. *SNESTIK*, pages 89–95.
- Fitri, Z. E., Baskara, A., Silvia, M., Madjid, A., and Imron, A. M. (2021). Application of backpropagation method for quality sorting classification system on white dragon fruit (*Hylocereus undatus*). *IOP Conf. Ser. Earth Environ. Sci.*, 672(1).
- Franciotti, R., Moharrami, M., Quaranta, A., Bizzoca, M. E., Piattelli, A., Aprile, G., and Perrotti, V. (2021). Use of Fractal Analysis in Dental Images for Osteoporosis Detection: A Systematic Review and Meta-Analysis. *Osteoporos. Int.*, 32(6):1041–1052.

- Gaillard, F. (2009). Mandibular Fractures.
- Genant, H. K., Cooper, C., Poor, G., Reid, I., Ehrlich, G., Kanis, J., Nordin, B. E., Barrett-Connor, E., Black, D., Bonjour, J. P., Dawson-Hughes, B., Delmas, P. D., Dequeker, J., Eis, S. R., Gennari, C., Johnell, O., Johnston, J., Lau, E. M., Liberman, U. A., Lindsay, R., Martin, T. J., Masri, B., Mautalen, C. A., Meunier, P. J., Miller, P. D., Mithal, A., Morii, H., Papapoulos, S., Woolf, A., Yu, W., and Khaltsev, N. (1999). Interim report and recommendations of the World Health Organization Task-Force for Osteoporosis. *Osteoporos. Int.*, 10(4):259–264.
- Ghazal, S., Qureshi, W. S., Khan, U. S., Iqbal, J., Rashid, N., and Tiwana, M. I. (2021). Analysis of visual features and classifiers for Fruit classification problem. *Comput. Electron. Agric.*, 187.
- Goyal, M., Yap, M. H., and Hassanpour, S. (2017). Deep Learning Methods and Applications for Region of Interest Detection in Dermoscopic Images. *Generic Color. J.*, pages 1–9.
- Hapsari, R. K., Utoyo, M. I., Rulaningtyas, R., and Suprajitno, H. (2020). Comparison of Histogram Based Image Enhancement Methods on Iris Images. *J. Phys. Conf. Ser.*, 1569(2).
- Henderi, Wahyuningsih, T., and Rahwanto, E. (2021). Comparison of Min-Max normalization and Z-Score Normalization in the K-nearest neighbor (kNN) Algorithm to Test the Accuracy of Types of Breast Cancer. *IJIIS Int. J. Informatics Inf. Syst.*, 4(1):13–20.
- Hendriyani, Y. (2020). Perbandingan Algoritma Backpropagation Dan Learning Vector Quantization (LVQ) dalam Pengenalan Pola Bangun Ruang Geometri. *INVOTEK J. Inov. Vokasional dan Teknol.*, 20(2):59–66.

- Herdiansah, A., Borman, R. I., Nurnaningsih, D., Sinlae, A. A. J., and Al Hakim, R. R. (2022). Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk. *JURIKOM (Jurnal Ris. Komputer)*, 9(2):388–395.
- Imron, M. A. and Prasetyo, B. (2020). Improving Algorithm Accuracy K-Nearest Neighbor Using Z-Score Normalization and Particle Swarm Optimization to Predict Customer Churn. *J. Soft Comput. Explor.*, 1(1):56–62.
- International Osteoporosis Foundation (2022). International Osteoporosis Foundation: Facts and Statistics.
- Iwaszkiewicz, C. and Leszczyński, P. (2019). Bone Densitometry by Radiofrequency Echographic Multi-Spectrometry (REMS) in the Diagnosis of Osteoporosis. *Forum Reum.*, 5(2):81–88.
- Kanis, J. A., Johnell, O., Oden, A., Johansson, H., De Laet, C., Eisman, J. A., Fujiwara, S., Kroger, H., McCloskey, E. V., Mellstrom, D., Melton, L. J., Pols, H., Reeve, J., Silman, A., and Tenenhouse, A. (2005). Smoking and fracture risk: A meta-analysis. *Osteoporos. Int.*, 16(2):155–162.
- Kathirvelu, D., Vinupritha, P., and Kalpana, V. (2019). A Computer Aided Diagnosis System for Measurement of Mandibular Cortical Thickness on Dental Panoramic Radiographs in Prediction of Women with Low Bone Mineral Density. *J. Med. Syst.*, 43(6):1–7.
- Kementerian Kesehatan Republik Indonesia (2015). Infodatin.
- Kiranti, D. I., Oktavini, D., Febrianti, I., Mariyam, S., and Fajrussalam, H. (2022).

- Solusi Permasalahan Kesehatan dengan Pengamalan Al-Qur'an dan Sunnah Rasulullah SAW. *CENDEKIA J. Stud. Keislam.*, 8(1).
- Koklu, M. and Ozkan, I. A. (2020). Multiclass Classification of Dry Beans using Computer Vision and Machine Learning Techniques. *Comput. Electron. Agric.*, 174:1–11.
- Krismantoro, E., Supriyanti, R., and Ramadhani, Y. (2021). Klasifikasi Objek Alzheimer Citra Otak Magnetic Resonance Image (MRI) Dengan Metode Backpropagation Neural Network Berdasarkan Clinical Dementia Rating (CDR).
- Kumbhar, M. M. and Godbole, B. B. (2020). Dehazing Effects on Image and Video using AHE, CLAHE and Dark Channel Prior. *Int. J. Eng. Adv. Technol.*, 9(3):119–125.
- Lee, K. S., Jung, S. K., Ryu, J. J., Shin, S. W., and Choi, J. (2020). Evaluation of Transfer Learning with Deep Convolutional Neural Networks for Screening Osteoporosis in Dental Panoramic Radiographs. *J. Clin. Med.*, 9(2).
- Lestari, S. and Utari, E. L. (2013). Metode Pengenalan Pola Trabekula Mandibula Pada Radiograf Periapikal Digital Untuk Deteksi Dini Risiko Osteoporosis. *J. Teknosains*, 3(1):66–73.
- Loc Vu-Quoc (2018). Neuron and Myelinated Axon.
- Manzini, B. M., Machado, L. M. R., Noritomi, P. Y., and da Silva, J. V. L. (2021). Advances in Bone tissue engineering: A fundamental review. *J. Biosci.*, 46(1).
- Melton, L. J., Chrischilles, E. A., Cooper, C., Lane, A. W., and Riggs, B. L. (1992). Perspective how many women have osteoporosis? *J. Bone Miner. Res.*, 7(9):1005–1010.

- Mishra, S., Majhi, B., and Sa, P. K. (2018). *GLRLM-based feature extraction for Acute Lymphoblastic Leukemia (ALL) detection*. Springer Singapore.
- Napoleon, D. and Kalaiarasi, I. (2022). Classifying Lung Cancer as Benign and Malignant Nodule Using ANN of Back-Propagation Algorithm and GLCM Feature Extraction on Chest X-Ray Images. *Wirel. Pers. Commun.*, 126(1):167–195.
- Nawawi, H. M., Purnama, J. J., and Hikmah, A. B. (2019). Komparasi Algoritma Neural Network Dan Naïve Bayes Untuk Memprediksi Penyakit Jantung. *J. Pilar Nusa Mandiri*, 15(2):189–194.
- Novitasari, D. C. R., Lubab, A., Sawiji, A., and Asyhar, A. H. (2019). Application of Feature Extraction for Breast Cancer Using One Order Statistic, GLCM, GLRLM, and GLDM. *Adv. Sci. Technol. Eng. Syst.*, 4(4):115–120.
- Öztürk, and Akdemir, B. (2018). Application of Feature Extraction and Classification Methods for Histopathological Image using GLCM, LBP, LBGLCM, GLRLM and SFTA. *Procedia Comput. Sci.*, 132(Iccids):40–46.
- Pal, K. and Patel, B. V. (2020). Data Classification with k-fold Cross Validation and Holdout Accuracy Estimation Methods with 5 Different Machine Learning Techniques. *Proc. 4th Int. Conf. Comput. Methodol. Commun. ICCMC 2020*, pages 83–87.
- Pandian, J. A., Kanchanadevi, K., Kumar, V. D., Jasińska, E., Goño, R., Leonowicz, Z., and Jasiński, M. (2022). A Five Convolutional Layer Deep Convolutional Neural Network for Plant Leaf Disease Detection. *Electron.*, 11(8).

- Pi, P. and Lima, D. (2021). Gray Level Co-Occurrence Matrix and Extreme Learning Machine for Covid-19 Diagnosis. *Int. J. Cogn. Comput. Eng.*, 2:93–103.
- Putri, R. N. (2020). Indonesia dalam Menghadapi Pandemi Covid-19. *J. Ilm. Univ. Batanghari Jambi*, 20(2):705–709.
- Rani, V. V. (2021). A Detailed Review on Image Augmentation and Segmentation of Brain MRI Images Using Deep Learning. *Paid. J.*, XIV(8):1–7.
- Sagar, A. (2021). Deep Covid - Coronavirus Diagnosis Using Deep Neural Networks and Transfer Learning. *medRxiv*.
- Said, Q., Ernawati, I., and Santoni, M. M. (2021). Identifikasi Tuberkulosis Paru Berdasarkan Foto Sinar-X Thorax Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Inform. J. Ilmu Komput.*, 17(1):27.
- Saifullah, S. (2020). Analisis Perbandingan HE Dan CLAHE Pada Image Enhancement Dalam Proses Segmenasi Citra Untuk Deteksi Fertilitas Telur. *J. Nas. Pendidik. Tek. Inform.*, 9(1):134.
- Sakinah, N., Badriyah, T., Syarif, I., Elektronika, P., Surabaya, N., Korespondensi, P., Regression, L., and Network, N. (2020). Analisis Kinerja Algoritma Mesin Pembelajaran untuk Klasifikasi Penyakit Stroke Menggunakan Citra CT Scan. *J. Teknol. Inf. dan Ilmu Komput.*, 7(4):833–844.
- Saud, S., Jamil, B., Upadhyay, Y., and Irshad, K. (2020). Performance improvement of empirical models for estimation of global solar radiation in India: A k-fold cross-validation approach. *Sustain. Energy Technol. Assessments*, 40(June):100768.
- Sela, E. I. (2021). Deteksi Osteoporosis pada Citra Radiograf Panaromik Dental

- Menggunakan Algoritme J48 dan Learning Vector Quantization. *J. Teknol. dan Sist. Komput.*, 9(4):211–217.
- Sela, E. I. and Pulungan, R. (2019). Osteoporosis Identification Based on the Validated Trabecular Area on Digital Dental Radiographic Images. *Procedia Comput. Sci.*, 157:282–289.
- Silverman, B. K. (1979). Consensus Development Conference: Diagnosis, Prophylaxis, and Treatment of Osteoporosis. *Clin. Pediatr. (Phila.)*, 18(8):454–462.
- Teng, Z., Zhu, Y., Yu, X., Liu, J., Long, Q., Zeng, Y., and Lu, S. (2021). An Analysis and Systematic Review of Sarcopenia Increasing Osteopenia Risk. *PLoS One*, 16(4):1–14.
- Venkatraman, S. K. and Swamiappan, S. (2020). Review on calcium- and magnesium-based silicates for bone tissue engineering applications. *J. Biomed. Mater. Res. - Part A*, 108(7):1546–1562.
- Wawrzyniak, A. and Balawender, K. (2022). Structural and Metabolic Changes in Bone. *Animals*, 12(15).
- Wisudawati, L. M., Madenda, S., Wibowo, E. P., and Abdullah, A. A. (2021). Benign and malignant breast tumors classification based on texture analysis and backpropagation neural network. *Comput. Opt.*, 45(2):227–234.
- Wulandari, W. R., Wibowo, S. A., and Oscandar, F. (2019). Klasifikasi Umur Berdasarkan Citra Dental Panoramic Radiograph dengan Metode Statistical Analysis of Structural Information dan Adaboosts. *e-Proceeding Eng.*, 6(2):4216–4222.

- Yamak, P. T., Yujian, L., and Gadosey, P. K. (2019). A comparison between ARIMA, LSTM, and GRU for time series forecasting. *ACM Int. Conf. Proceeding Ser.*, pages 49–55.
- Yeung, A. W. K. and Mozos, I. (2020). The Innovative and Sustainable Use of Dental Panoramic Radiographs for The Detection of Osteoporosis. *Int. J. Environ. Res. Public Health*, 17(7).
- Yu, S., Chu, P., Yang, J., Huang, B., Yang, F., Megalooikonomou, V., and Ling, H. (2019). Multi-task Osteoporosis Pre-screening Using Dental Panoramic Radiographs with Feature Learning. *Smart Heal.*, (June):10.
- Yunarto, Y., Pribadi, M. R., and Irsyad, H. (2020). Perbandingan Algoritma Backpropagation Dan Support Vector Machine Pada Pengenalan Jenis Biji Jagung. *J. Algoritm.*, 1(1):111–120.
- Yustiantara, N. C. P. W., Wulanningrum, R., and Rochana, S. (2021). Image Enhacement Pada Citra Gestur Tangan Menggunakan Contrast Limited Adaptive Histogram Equalization. *JOUTICA*, 6(2):454–460.
- Zakaria, F. and Emran, H. B. (2020). Stress Fracture Detection using Adaptive Histogram Equalization (AHE) and Contrast Limited Adaptive Histogram Equalization (CLAHE): A Comparative Study. pages 47–50.
- Zhang, F., Li, Z., Zhang, B., Du, H., Wang, B., and Zhang, X. (2019). Multi-Modal Deep Learning Model for Auxiliary Diagnosis of Alzheimer’s Disease. *Neurocomputing*, 361:185–195.
- Zhang, L. and Yang, K. (2014). Region-of-Interest Extraction Based on Frequency

Domain Analysis and Salient Region Detection for Remote Sensing Image. *IEEE Geosci. Remote Sens. Lett.*, 11(5):916–920.



UIN SUNAN AMPEL
S U R A B A Y A