

**SISTEM DIAGNOSIS KSSRM BERDASARKAN ANALISIS TEKSTUR
GLRLM CITRA HISTOPATOLOGI MENGGUNAKAN METODE
*BACKPROPAGATION***

SKRIPSI



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

Disusun Oleh
UNIX IZYAH ARFIANTI
H72218035

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

2022

PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : UNIX IZYAH ARFIANTI

NIM : H72218035

Program Studi : Matematika

Angkatan : 2018

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul "SISTEM DIAGNOSIS KSSRM BERDASARKAN ANALISIS TEKSTUR GLRLM CITRA HISTOPATOLOGI MENGGUNAKAN METODE BACKPROPAGATION". 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, 07 Januari 2022

Yang menyatakan,



UNIX IZYAH ARFIANTI

NIM. H72218035

LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

Nama : UNIX IZYAH ARFIANTI

NIM : H72218035

Judul Skripsi : SISTEM DIAGNOSIS KSSRM BERDASARKAN
ANALISIS TEKSTUR GLRLM CITRA
HISTOPATOLOGI MENGGUNAKAN METODE
BACKPROPAGATION

telah diperiksa dan disetujui untuk diujikan.

Pembimbing I

Dian Candra Rini Novitasari, M.Kom
NIP. 198511242014032001

Pembimbing II

Dr. Abduloh Hamid, M.Pd
NIP. 198508282014031003

Mengetahui,
Ketua Program Studi Matematika
UIN Sunan Ampel Surabaya

Aris Fanani, M.Kom
NIP. 198701272014031002

PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

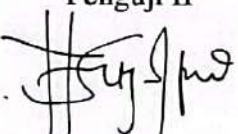
Nama : UNIX IZYAH ARFIANTI
NIM : H72218035
Judul Skripsi : SISTEM DIAGNOSIS KSSRM BERDASARKAN ANALISIS TEKSTUR GLRLM CITRA HISTOPATOLOGI MENGGUNAKAN METODE BACKPROPAGATION

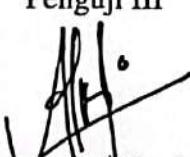
Telah dipertahankan di depan Tim Penguji
pada tanggal 11 Januari 2022

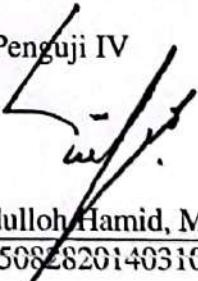
Mengesahkan,
Tim Penguji

Penguji I

Nurissaidah Ummuha, M.Kom
NIP. 199011022014032004

Penguji II

Yuniar Farida, M.T
NIP. 197905272014032002

Penguji III

Dian Canova Rini Novitasari, M.Kom
NIP. 198511242014032001

Penguji IV

Dr. Abdulloh Hamid, M.Pd
NIP. 198508282014031003

Mengetahui,

Dekan Fakultas Sains dan Teknologi
KEMENTERIAN UIN Sultan Ampel Surabaya



Dr. Hj. Fatimatur Rusydiyah, M.Ag
NIP. 197212272005012003



**KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN**

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpus@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 : UNIX IZYAH ARFIANTI
NIM : H72210035
Fakultas/Jurusan : SAINTEK / MATEMATIKA
E-mail address : unixizyah@gmail.com

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

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

SISTEM DIAGNOSIS KSSRM BERDASARKAN ANALISIS TEKSTUR GLRLM CITRA

HISTOPATOLOGI MENGGUNAKAN METODE BACKPROPAGATION.

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Ekslusif 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, 23 Januari 2022

Penulis


(Unix Izayah Arfianti)
nama lengkap dan tanda tangan

ABSTRAK

SISTEM DIAGNOSIS KSSRM BERDASARKAN ANALISIS TEKSTUR GLRLM CITRA HISTOPATOLOGI MENGGUNAKAN METODE *BACKPROPAGATION*

Kanker mulut terjadi lebih dari 370 ribu kasus dengan Asia menjadi wilayah dengan kasus kanker mulut terbanyak di dunia sebesar 65.8%. Kanker yang paling sering terjadi dalam rongga mulut adalah Karsinoma Sel Skuamosa Rongga Mulut (KSSRM). KSSRM terjadi sekitar 90% pada kanker mulut. Penelitian ini dilakukan untuk membuat sistem diagnosis KSSRM menggunakan metode *Backpropagation*. *Backpropagation* merupakan salah satu jenis Jaringan Saraf Tiruan (JST) yang konsep kerjanya terinspirasi dari jaringan saraf manusia. Tujuan dari penelitian ini adalah sebagai upaya pencegahan dengan melakukan pemeriksaan dini agar kanker mulut dapat terdeteksi sebelum kanker mulut bertambah parah dan dapat segera ditangani dan segera dilakukan pemulihian. Data yang digunakan adalah citra histopatologi rongga mulut dengan perbesaran lensa $100x$ dan $400x$. Data akan dilakukan *preprocessing* menggunakan CLAHE untuk memperbaiki citra kemudian diekstraksi menggunakan GLRLM untuk menjadi inputan pada *Backpropagation*. Dari hasil uji coba parameter yang telah dilakukan, diperoleh hasil akurasi maksimal sebesar 94.12%, sensitivitas 100%, dan spesifisitas 62.50% dengan parameter yang digunakan adalah data perbesaran $100\times$ pada arah sudut 135° , *k-fold* 10, *learning rate* 0.4, 2 *hidden layer* dengan jumlah *node* berturut-turut 100 dan 50 *node*.

Kata kunci: KSSRM, *Backpropagation*, CLAHE, GLRLM, *K-Fold-Cross Validation*

ABSTRACT

DIAGNOSIS SYSTEM OF OSCC BASED ON GLRLM TEXTURE ANALYSIS OF HISTOPATHOLOGICAL IMAGE USING BACKPROPAGATION METHOD

Oral cancer occurs in more than 370 thousand cases with Asia being the region with the most oral cancer cases in the world at 65.8%. OSCC occurs in about 90% of oral cancers. This research is conducted to make an OSCC diagnosis system using the Backpropagation method. Backpropagation is one type of Artificial Neural Network (ANN) whose working concept is inspired by human neural networks. The purpose of this study is as a prevention effort by conducting an early examination so that oral cancer can be detected before oral cancer gets worse and can be treated and recovered immediately. The data used are histopathological images of the oral cavity with $100\times$ and $400\times$ lens magnification. The data will be preprocessed using CLAHE to improve the image and then extracted using GLRLM to be input in Backpropagation. From the results of parameter trials, the maximum accuracy is 94.12%, 100% sensitivity, 62.50% specificity with $100\times$ data at 135° , 10 k-fold, 0.4 learning rate, 2 hidden layers with 100 and 50 nodes.

Keywords: OSCC, *Backpropagation*, CLAHE, GLRLM, *K-Fold-Cross Validation*

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	3
DAFTAR GAMBAR	4
I PENDAHULUAN	6
1.1. Latar Belakang Masalah	6
1.2. Rumusan Masalah	12
1.3. Tujuan Penelitian	12
1.4. Manfaat Penelitian	13
1.5. Batasan Masalah	13
1.6. Sistematika Penulisan	14
II TINJAUAN PUSTAKA	16
2.1. Karsinoma Sel Skuamosa Rongga Mulut (KSSRM)	16
2.2. Citra <i>Digital</i>	18
2.3. <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE)	21
2.4. <i>Gray Level Run Length Matrix</i> (GLRLM)	22
2.4.1. <i>Short Run Emphasis</i> (SRE)	24
2.4.2. <i>Long Run Emphasis</i> (LRE)	24
2.4.3. <i>Gray Level Nonuniformity</i> (GLN)	25
2.4.4. <i>Run Length Nonuniformity</i> (RLN)	25
2.4.5. <i>Run Percentage</i> (RP)	26

2.4.6. <i>Low Gray-level Run Emphasis</i> (LGRE)	26
2.4.7. <i>High Gray-level Run Emphasis</i> (HGRE)	27
2.4.8. <i>Short Run Low Gray-level Emphasis</i> (SRLGE)	27
2.4.9. <i>Short Run High Gray-level Emphasis</i> (SRHGE)	28
2.4.10. <i>Long Run Low Gray-level Emphasis</i> (LRLGE)	28
2.4.11. <i>Long Run High Gray-level Emphasis</i> (LRHGE)	29
2.5. <i>K-fold Cross Validation</i>	29
2.6. <i>Backpropagation</i>	31
2.7. <i>Binary Confusion Matrix</i>	37
2.8. Penyakit dalam Perspektif Islam	38
III METODE PENELITIAN	42
3.1. Jenis Penelitian	42
3.2. Jenis dan Sumber Data	42
3.3. Kerangka Penelitian	44
IV HASIL DAN PEMBAHASAN	46
4.1. <i>Preprocessing</i>	46
4.1.1. <i>Grayscale</i>	47
4.1.2. <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE) .	48
4.2. Ekstraksi Fitur	52
4.3. Klasifikasi	64
4.3.1. Proses <i>Training</i>	66
4.3.2. Proses <i>Testing</i>	71
4.4. Pengujian Model dan Evaluasi Sistem	73
4.5. Aplikasi Sistem Diagnosis KSSRM	75
4.6. Integrasi Keislaman	78
V PENUTUP	81
5.1. Kesimpulan	81
5.2. Saran	82
DAFTAR PUSTAKA	83

DAFTAR TABEL

3.1 Sampel Data Citra Histopatologi Rongga Mulut	43
4.1 Hasil GLRLM pada Arah Sudut 0°	57
4.2 Hasil GLRLM pada Arah Sudut 45°	57
4.3 Hasil GLRLM pada Arah Sudut 90°	57
4.4 Hasil GLRLM pada Arah Sudut 135°	58
4.5 Perbandingan Pembagian Jumlah Data Menggunakan <i>K-Fold</i>	64
4.6 Bobot dan Bias antara <i>Input Layer</i> dan <i>Hidden Layer</i>	67
4.7 Bobot dan Bias antara <i>Hidden Layer</i> dan <i>Output Layer</i>	67
4.8 Bobot dan Bias antara <i>Hidden Layer</i> dan <i>Output Layer</i>	69
4.9 Bobot dan Bias antara <i>Hidden Layer</i> dan <i>Output Layer</i>	70
4.10 Bobot dan Bias antara <i>Hidden Layer</i> dan <i>Output Layer</i>	71
4.11 Bobot dan Bias antara <i>Hidden Layer</i> dan <i>Output Layer</i>	71

DAFTAR GAMBAR

2.1	Ilustrasi Karsinoma Sel Skuamosa	16
2.2	Gambar Klinis KSSRM (a) KSSRM Tahap Awal <i>Leukoplakia</i> (b) KSSRM Tahap Awal <i>Erythroplakia</i> (c) KSSRM tahap lanjut	17
2.3	Citra Histopatologi KSSRM	18
2.4	Citra RGB	19
2.5	Citra <i>Grayscale</i>	20
2.6	Region CLAHE	21
2.7	Perubahan Citra Sebelum dan Sesudah CLAHE	22
2.8	Arah Sudut GLRLM	22
2.9	Matriks Contoh Nlai Piksel Citra	23
2.10	Matriks Contoh Nlai Piksel Citra	23
2.11	Pembagian Data Menggunakan Length dengan 5-fold	30
2.12	Perbandingan Konsep Jaringan Saraf Manusia dan JST (a) Jaringan Saraf Manusia (b) Jaringan Saraf Tiruan	31
2.13	Arsitektur <i>Backpropagation</i>	32
2.14	<i>Binary Confusion Matrix</i>	37
3.1	Diagram Alir Diagnosis KSSRM Menggunakan <i>Backpropagation</i>	44
4.1	Perbedaan Cahaya pada Data	46
4.2	Nilai R, G, dan B pada Sampel Citra KSSRM	47
4.3	Sampel Citra Hasil Grayscale	48
4.4	Sampel Citra Hasil CLAHE	49
4.5	Perbandingan Histogram Citra 100× Normal Sebelum dan Sesudah CLAHE	50
4.6	Perbandingan Histogram Citra 100× KSSRM Sebelum dan Sesudah CLAHE	51
4.7	Perbandingan Histogram Citra 400× Normal Sebelum dan Sesudah CLAHE	51

4.8	Perbandingan Histogram Citra 400×400 Sebelum dan Sesudah CLAHE	52
4.9	Cara Mencari Matriks <i>Run Length</i>	53
4.10	Visualisasi Nilai SRE pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	58
4.11	Visualisasi Nilai LRE pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	59
4.12	Visualisasi Nilai GLN pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	59
4.13	Visualisasi Nilai RLN pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	60
4.14	Visualisasi Nilai RP pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	60
4.15	Visualisasi Nilai LGRE pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	61
4.16	Visualisasi Nilai HGRE pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	61
4.17	Visualisasi Nilai SRLGE pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	62
4.18	Visualisasi Nilai SRHGE pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	62
4.19	Visualisasi Nilai LRLGE pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	63
4.20	Visualisasi Nilai LRHGE pada Perbesaran Lensa (a) 100×100 (b) 400×400 . . .	63
4.21	Arsitektur <i>Backpropagation</i> dengan 10 <i>node Hidden Layer</i>	66
4.22	Confusion Matrix Terbaik pada Satu Hidden Layer	74
4.23	Tampilan Awal Aplikasi Diagnosis KSSRM	75
4.24	Halaman Utama Aplikasi Diagnosis KSSRM	76
4.25	Halaman Utama Aplikasi Diagnosis KSSRM	77
4.26	Halaman Utama Aplikasi Diagnosis KSSRM	77

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Kanker adalah penyebab kematian kedua di dunia dengan jumlah kematian 9.6 juta jiwa pada tahun 2018 (Anugraha et al., 2021). Masalah penanganan kanker di Indonesia diawali karena kurangnya pengetahuan masyarakat mengenai gejala kanker sehingga menyebabkan hampir 75% penderita ditemukan dalam keadaan sudah stadium lanjut. Salah satu kanker yang mengancam jiwa adalah kanker mulut. Menurut data Globocan pada tahun 2020 kanker mulut terjadi lebih dari 370 ribu kasus dengan Asia menjadi wilayah dengan kasus kanker mulut terbanyak di dunia sebesar 65.8% (The Golbal Cancer Observatory, 2020). Kanker yang paling sering terjadi dalam rongga mulut adalah Karsinoma Sel Skuamosa Rongga Mulut (KSSRM). KSSRM terjadi sekitar 90% pada kanker mulut (Hu et al., 2016). Faktor resiko utama KSSRM adalah tembakau dan alkohol. Secara umum KSSRM paling sering terjadi pada laki-laki, orang yang berusia lebih tua, dan orang yang sering terkena paparan sinar UV (Janotha and Tamari, 2017).

Kanker merupakan penyakit yang tingkat pemulihannya termasuk susah dan merupakan penyakit nomor dua setelah penyakit jantung yang menyebabkan kematian. Tetapi, segala jenis penyakit dan tingkat pemulihannya yang sangat susah akan terasa mudah atas izin Allah Swt seperti kisah Nabi Ibrahim a.s. yang tertuang dalam Q.S asy-Syur'ara' ayat ke 80:

وَإِذَا مَرَضْتُ فَهُوَ يَشْفِيْنِ لَا

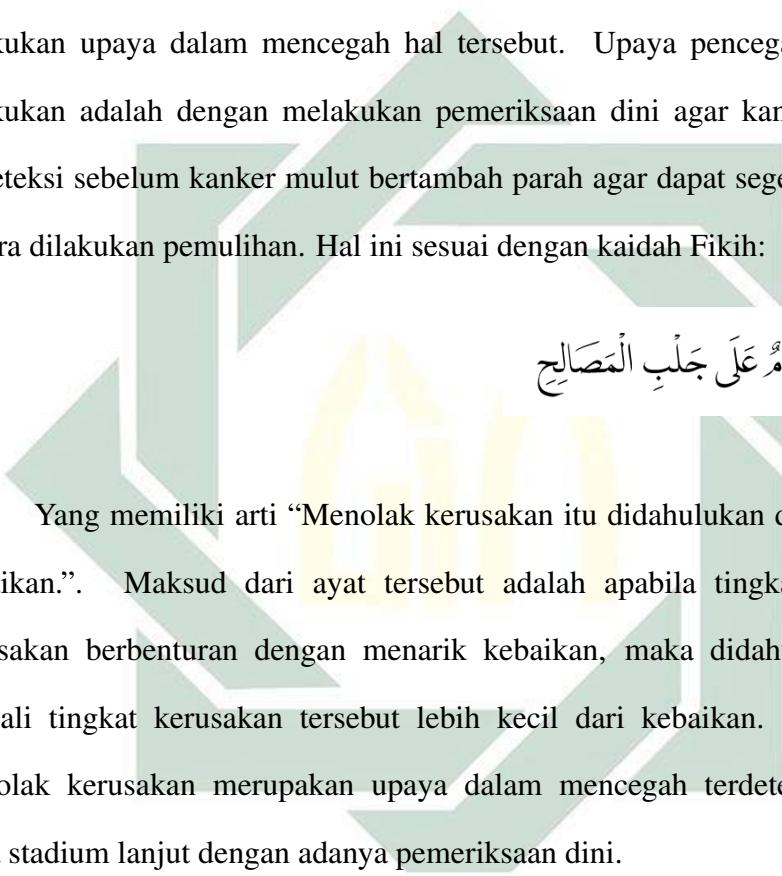
Artinya: “Apabila aku sakit, Dialah yang menyembuhkanku” (asy-Syu’ara’/26:80). Ayat tersebut menceritakan tentang Nabi Ibrahim a.s. yang yakin hanya Allah Swt yang dapat menyembuhkan ketika Nabi Ibrahim a.s. merasa sakit. Hal tersebut merupakan contoh sikap tawakkal seorang umat muslim kepada Allah Swt. Ayat tersebut sepadan dengan hadis yang diriwayatkan oleh Imam Muslim:

حدَثَنَا هَارُونَ بْنُ مَعْرُوفٍ وَأَبُو الطَّاهِرِ وَأَحْمَدُ بْنُ عَيْسَى قَالُوا حَدَّثَنَا أَبْنُ وَهْبٍ أَخْبَرَنِي عَنْ رُوَايَةِ أَبْنِ الْحَارِثِ عَنْ عَبْدِ رَبِّهِ بْنِ سَعِيدٍ عَنْ أَبِي الرَّيْبَرِ عَنْ جَابِرٍ عَنْ رَسُولِ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ أَنَّهُ قَالَ: لِكُلِّ دَاءٍ دَوَاءٌ فَإِذَا أَصَيبَ دَوَاءً بِرَأْيِيْنِ اللَّهِ عَزَّ وَجَلَّ (روايه مسلم)

Yang memiliki arti: 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 saw, beliau bersabda: "Setiap penyakit ada obatnya. Apabila ditemukan obat yang tepat untuk suatu penyakit, akan sembuhlah penyakit itu dengan izin Allah 'azza wajalla." (HR Muslim). Hadis tersebut menyatakan bahwa setiap penyakit ada obatnya. Obat merupakan sarana perantara untuk menyembuhkan suatu penyakit, tetapi kesembuhan hanya milik Allah Swt. Apabila Allah Swt menghendaki untuk sembuh, maka penyakit tersebut akan sembuh.

Meskipun rongga mulut mudah diakses, sebagian kanker mulut terdeteksi

pada stadium lanjut yang mengarah pada tingkat kelangsungan hidup yang rendah (Radhika et al., 2016). Selain itu, tingkat kekambuhan dan metastasis ditemukan pada 80% kasus pasien dalam 2 tahun pertama dan tingkat kelangsungan hidup 5 tahun masih lebih rendah dari 50% setelah pengobatan primer (Cristaldi et al., 2019). Sehingga ini menjadi masalah serius untuk kesehatan masyarakat, perlu dilakukan upaya dalam mencegah hal tersebut. Upaya pencegahan yang dapat dilakukan adalah dengan melakukan pemeriksaan dini agar kanker mulut dapat terdeteksi sebelum kanker mulut bertambah parah agar dapat segera ditangani dan segera dilakukan pemulihan. Hal ini sesuai dengan kaidah Fikih:



Yang memiliki arti “Menolak kerusakan itu didahuluikan daripada menarik kebaikan.”. Maksud dari ayat tersebut adalah apabila tingkat dari menolak kerusakan berbenturan dengan menarik kebaikan, maka didahuluikan kebaikan kecuali tingkat kerusakan tersebut lebih kecil dari kebaikan. Dalam hal ini, menolak kerusakan merupakan upaya dalam mencegah terdeteksinya KSSRM pada stadium lanjut dengan adanya pemeriksaan dini.

Pada bidang kesehatan terdapat beberapa cara dalam mendeteksi KSSRM. Terdapat cara *non invasive* -tindakan medis dalam melakukan diagnosis atau pengobatan tanpa memasukkan suatu alat ke dalam tubuh- menggunakan biopsi cair (Aro et al., 2017; Rapado-González et al., 2019). Cara lain dapat melakukan deteksi melalui biomarker saliva karena saliva merupakan biofluida yang mengandung sitokin, molekul DNA dan RNA, sel-sel yang bersirkulasi dan berasal dari jaringan, dan vesikel ekstraseluler (EVs) yang dapat digunakan sebagai *biomarker*. Informasi tersebut dapat digunakan untuk melakukan diagnosis dini

KSSRM dan meningkatkan prognosis (Cristaldi et al., 2019; Radhika et al., 2016).

Di era modern ini teknologi berkembang dengan pesat khususnya dalam bidang kesehatan (Yani, 2018). Selain pada bidang kesehatan, dalam bidang komputasi juga dapat mendiagnosis KSSRM menggunakan sistem *Computer Aided Diagnosis* (CAD) dengan bantuan *Artificial Intelligence*. CAD memiliki tiga tahap, yaitu *preprocessing*, ekstraksi fitur, dan tahap klasifikasi. Tahap *preprocessing* berguna untuk memperbaiki kualitas citra agar citra lebih mudah diidentifikasi. Salah satu metode yang digunakan untuk memperbaiki kualitas citra adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE). CLAHE merupakan metode yang dikembangkan dari metode *Adaptive Histogram Equalization* (AHE). Pada permasalahan lain terdapat penelitian yang membandingkan metode peningkatan kualitas berbasis histogram seperti HE, AHE, dan CLAHE pada citra iris. CLAHE menghasilkan MSE dan RMSE terbaik secara bertutut-turut sebesar 131.5763 dan 11.4360 (Hapsari et al., 2020). Selain itu, terdapat penelitian yang membandingkan metode dalam memperbaiki citra *X-ray* tulang belakang lumbar menggunakan metode HE, CLAHE, dan BPDFHE. Penelitian tersebut menyebutkan bahwa metode CLAHE dapat menunjukkan lebih detail dan informasi struktur daripada metode HE dan BPDFHE (Saenpaen et al., 2019). Kemudian penelitian yang dilakukan oleh Aditya Akbar Riadi dkk yang melakukan perbandingan metode dalam memperbaiki kontras citra medis. Penelitian tersebut menghasilkan nilai rata-rata MSE terbaik diperoleh menggunakan metode CLAHE sebesar 339.126, disusul dengan AHE sebesar 596.9%, dan HE sebesar 759.340% (Riadi et al., 2017).

Tahap ekstraksi fitur digunakan untuk mengambil nilai dari ciri suatu objek pada citra. Pada penelitian ini ekstraksi fitur yang digunakan adalah dengan

mengambil ciri tekstur dari suatu citra. Salah satu metode yang digunakan dalam ekstraksi tekstur adalah *Gray Level Run Length Matrix* (GLRLM). Pada permasalahan lain terdapat penelitian yang mengklasifikasikan citra mammogram kanker payudara dengan membandingkan empat metode ekstraksi tektur, diantaranya adalah *one order statistic*, GLCM, GLRLM, dan GLDM. Penelitian tersebut mendapatkan akurasi terbaik sebesar 93.9757% menggunakan ekstraksi tekstur GLRLM (Novitasari et al., 2019).

Tahap klasifikasi berguna untuk mendiagnosis apakah citra tersebut merupakan citra normal atau citra KSSRM. Salah satu metode AI yang dapat digunakan dalam klasifikasi adalah Backpropagation. *Backpropagation* merupakan salah satu jenis metode Jaringan Saraf Tiruan (JST). *Backpropagation* memiliki keunggulan yang terletak pada proses pembelajarannya. *Backpropagation* menggunakan sistem pembobotan dalam proses pembelajarannya, apabila bobot masih belum sesuai maka akan dilakukan pembelajaran kembali yang disebut dengan *adaptive learning* (Yudhistira, 2017). *Backpropagation* memiliki 3 tahap, yaitu: *feed forward*, *backward*, dan *update bobot*. Pada permasalahan lain terdapat beberapa penelitian yang menggunakan metode *Backpropagation* seperti penelitian yang dilakukan oleh Sigit Adinugroho dan Yuita Arum Sari yang membandingkan metode *Backpropagation* dan *Learning Vector Quantization* (LVQ) dalam mengklasifikasi tanaman berdasarkan karakteristik dari citra daun. Penelitian tersebut mendapatkan akurasi terbaik sebesar 0.952 menggunakan metode *Backpropagation*, sedangkan metode LVQ mendapatkan akurasi 0.420. Penelitian tersebut menggunakan 12 *node* pada *hidden layer* (Adinugroho and Sari, 2017). Kemudian, terdapat penelitian yang membandingkan metode Backpropagation dan *Extreme Learning Machine* (ELM) dalam mengklasifikasi

phishing website. Penelitian tersebut menunjukkan bahwa metode *Backpropagation* lebih baik dengan akurasi sebesar 91.85% dibandingkan metode ELM yang mendapatkan akurasi sebesar 84.07%. Penelitian tersebut menggunakan 30 *node* pada *hidden layer* (Barus and Ronaldo, 2019). Selain itu, terdapat penelitian yang membandingkan metode *Backpropagation* dengan 5 metode klasifikasi lainnya seperti *K-Nearest Neighbor* (KNN), *Linear Discriminant Analysis* (LDA), *Naives Bayes* (NB), *Decision Tree* (DT), dan *Support Vector Machine* (SVM) dalam mengklasifikasi 30 jenis buah. Metode *Backpropagation* mendapatkan akurasi terbaik sebesar 100% pada uji coba kombinasi dari fitur warna dan tekstur (Ghazal et al., 2021).

Pada data klasifikasi citra MRI pankreas, B. Aruna Devi dan M. Pallikonda Rajasekaran membandingkan metode *Backpropagation* dan ELM. Dari 2 metode tersebut, *Backpropagation* mendapatkan akurasi sebesar 96.67% lebih baik dibandingkan ELM yang mendapatkan akurasi sebesar 93.33%. Penelitian tersebut menggunakan 2 *hidden layer* dengan jumlah masing-masing *nodenya* 4 dan 2 (Devi and Rajasekaran, 2019). Berdasarkan beberapa pemaparan dari latar belakang masalah dan beberapa penelitian sebelumnya yang menjelaskan mengenai perbandingan metode pada perbaikan citra yang membandingkan metode CLAHE dan metode lainnya CLAHE selalu mendapatkan RMSE terbaik dibandingkan metode perbaikan citra lainnya, perbandingan metode ekstraksi fitur yang menggunakan ciri tekstur membandingkan metode GLRLM dengan metode lainnya GLRLM mendapatkan akurasi terbaik, dan perbandingan metode dalam klasifikasi yang membandingkan *Backpropagation* dengan metode lainnya menghasilkan akurasi terbaik bahkan dengan jenis data yang berbeda. Sehingga pada penelitian ini menggunakan metode *Backpropagation* berdasarkan analisis

tekstur GLRLM pada citra histopatologi rongga mulut yang diperbaiki menggunakan CLAHE dalam mendiagnosis KSSRM.

1.2. Rumusan Masalah

Berdasarkan uraian latar belakang masalah yang ada, sehingga pada penelitian ini didapatkan rumusan masalah sebagai berikut:

1. Bagaimana hasil dari perbaikan citra histopatologi rongga mulut menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE)?
 2. Bagaimana hasil dari ekstraksi tekstur *Gray Level Run Length Matrix* (GLRLM) pada citra histopatologi rongga mulut?
 3. Bagaimana kinerja yang dihasilkan dari metode *Backpropagation*?

1.3. Tujuan Penelitian

Berdasarkan beberapa rumusan masalah yang ada, sehingga tujuan penelitian ini adalah:

1. Menganalisis *contrast* dari citra histopatologi rongga mulut dan menerapkan metode CLAHE dalam memperbaiki citra histopatologi rongga mulut.
 2. Menerapkan metode GLRLM dalam mengekstraksi tekstur citra histopatologi rongga mulut.
 3. Menerapkan metode *Backpropagation* dalam mendiagnosa KSSRM berdasarkan ekstraksi tekstur GLRLM dan menganalisis hasil diagnosis KSSRM.

1.4. Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah sebagai berikut:

1. Manfaat Teoritis

Berdasarkan beberapa tujuan penelitian yang akan tercapai, diharapkan penelitian ini dapat menjadi acuan untuk penelitian selanjutnya yang berkaitan dengan sistem diagnosis KSSRM.

2. Manfaat Praktis

(a) Bagi Penulis

Penulis mendapatkan pengetahuan baru dalam mendiagnosis KSSRM menggunakan metode *Backpropagation*.

(b) Bagi ahli medis

Membantu dalam bidang medis dengan memberikan inovasi baru dalam mendiagnosis KSSRM dengan cara yang lebih mudah dan mendapatkan akurasi yang baik.

(c) Bagi masyarakat umum

Memberikan wawasan mengenai KSSRM dan cara dalam mendiagnosisnya menggunakan metode *Backpropagation*.

1.5. Batasan Masalah

Karena ruang lingkup permasalahan yang sangat luas, sehingga diberikan beberapa batasan masalah pada penelitian ini, di antaranya adalah:

1. Data yang digunakan merupakan data citra histopatologi pada rongga mulut dengan dua kelas, KSSRM dan rongga mulut normal.

2. Penelitian ini melakukan uji coba parameter *k-fold cross validation*, arah sudut GLRLM, jumlah *node* pada *hidden layer*, dan jumlah *hidden layer*.
 3. *Output* yang dihasilkan dari sistem ini berupa informasi apakah citra tersebut termasuk citra KSSRM atau citra normal.

1.6. Sistematika Penulisan

Bagian ini berisi mengenai penjelasan garis besar isi dari setiap bab.

1. BAB I PENDAHULUAN Berisi mengenai latar belakang masalah tentang KSSRM dan cara mendeteksi KSSRM, perumusan masalah penelitian, batasan masalah penelitian, tujuan dari penelitian, manfaat penelitian, dan sistematika penulisan.
 2. BAB II TINJAUAN PUSTAKA Berisi landasan teori mengenai KSSRM, citra *digital*, tahap *preprocessing* dalam memperbaiki citra histopatologi rongga mulut menggunakan metode *grayscale* dan CLAHE, penjelasan mengenai proses diagnosis metode *Backpropagation*, serta metode evaluasinya yaitu *confusion matrix*.
 3. BAB III METODE PENELITIAN Berisi mengenai jenis penelitian, sumber data KSSRM, dan alur penelitian yang dimulai dari pengumpulan data KSSRM, tahap *preprocessing*, tahap klasifikasi menggunakan *Backpropagation*, evaluasi hasil diagnosis, dan kesimpulan hasil penelitian.
 4. BAB IV HASIL DAN PEMBAHASAN Berisi mengenai hasil dan pembahasan dari rumusan masalah penelitian, pemaparan proses yang dilakukan oleh peneliti, analisis hasil yang didapatkan dan penarikan kesimpulan dari hasil penelitian.

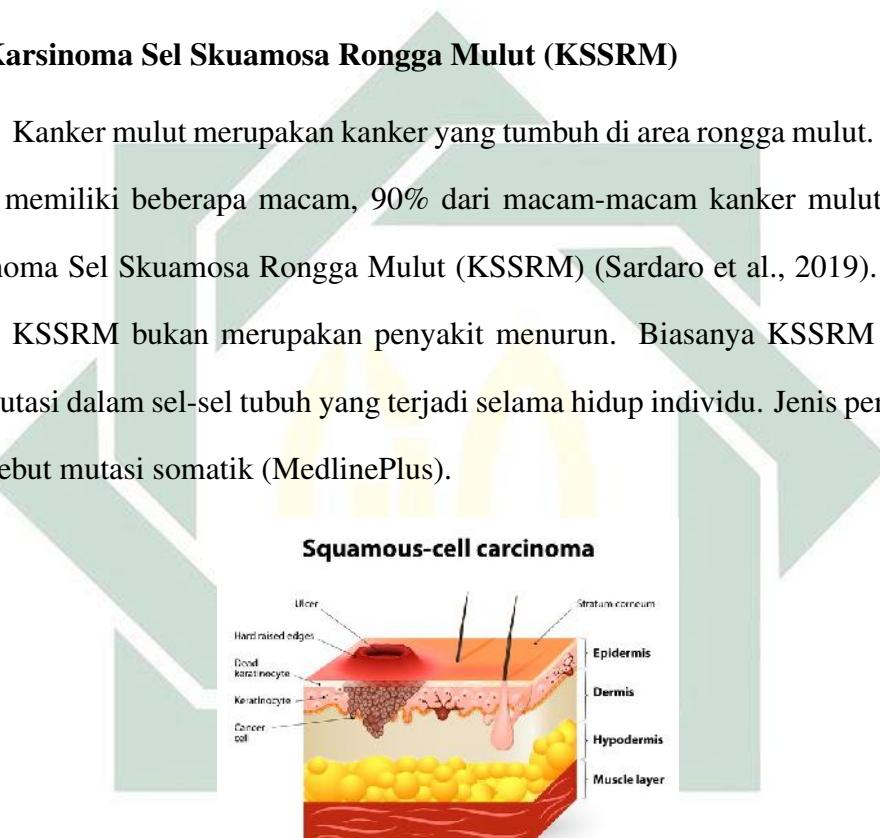
5. BAB V PENUTUP Berisi tentang kesimpulan hasil penelitian serta saran dari peneliti untuk penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA

2.1. Karsinoma Sel Skuamosa Rongga Mulut (KSSRM)

Kanker mulut merupakan kanker yang tumbuh di area rongga mulut. Kanker mulut memiliki beberapa macam, 90% dari macam-macam kanker mulut adalah Karsinoma Sel Skuamosa Rongga Mulut (KSSRM) (Sardaro et al., 2019). Secara umum KSSRM bukan merupakan penyakit menurun. Biasanya KSSRM berasal dari mutasi dalam sel-sel tubuh yang terjadi selama hidup individu. Jenis perubahan ini disebut mutasi somatik (MedlinePlus).



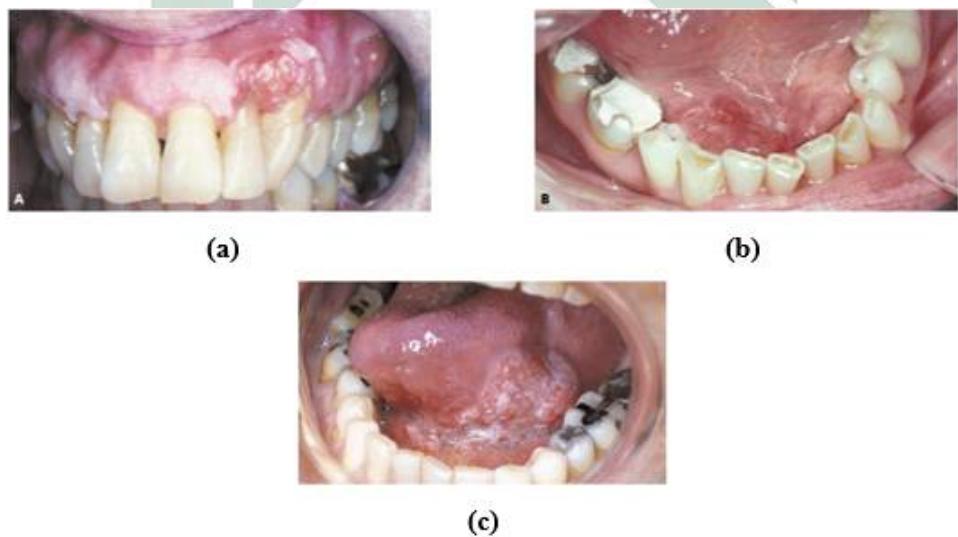
Gambar 2.1 Ilustrasi Karsinoma Sel Skuamosa

Sumber: (MedlinePlus)

Faktor resiko penyebab KSSRM terdiri dari 2 macam, yaitu: faktor lokal dan faktor umum. Pada faktor lokal meliputi kurangnya kebersihan rongga mulut dapat menjadi faktor penyebab KSSRM karena KSS sering ditemukan di sebelah pinggiran gigi atau protesa yang tajam. Selain itu, dengan mengonsumsi kombinasi alkohol dan tembakau dalam jangka panjang dapat meningkatkan resiko

terkena KSSRM hingga 15 kali lipat. Sedangkan pada faktor umum tumor sering ditemukan pada pasien lanjut usia, karena semakin bertambah usia maka daya tahan tubuh akan semakin menurun. Selain itu terdapat faktor lainnya seperti penyakit defisiensi, virus, dan bahan karsinogenik (Priyatna, 2017).

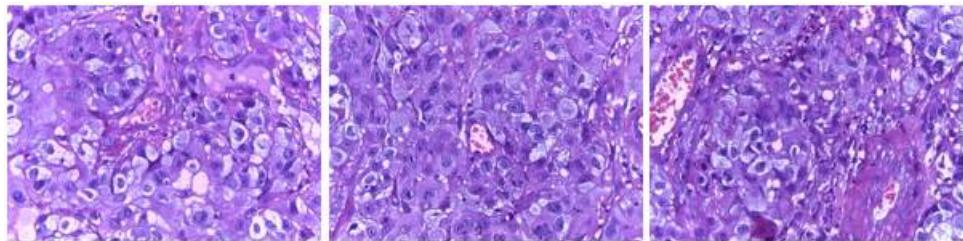
KSSRM memiliki berbagai macam gambaran klinis, di antaranya adalah: *Exophytic* (pembentukan massa), *Endophytic* (berlubang dan ulserasi), *Leukoplakia* (bercak putih), *Erythroplakia* (bercak merah), *Erythroleukoplakia* (kombinasi bercak merah dan putih) (Neville et al., 2015). Gambar 2.2 menunjukkan gambar klinis KSSRM pada tahap awal dan tahap lanjut.



Gambar 2.2 Gambar Klinis KSSRM (a) KSSRM Tahap Awal *Leukoplakia* (b) KSSRM Tahap Awal *Erythroplakia* (c) KSSRM tahap lanjut

Sumber: (Silverman et al., 2001)

Selain dari gambar klinis, KSSRM juga dapat dilihat melalui citra histopatologi. Gambar 2.3 menunjukkan citra histopatologi KSSRM.



Gambar 2.3 Citra Histopatologi KSSRM

Sumber: (Silverman et al., 2001)

Terapi KSSRM sendiri terdiri dari pembedahan, radioterapi, dan kemoterapi. Terapi yang digunakan dapat melibatkan 1 terapi maupun lebih atau terapi kombinasi bergantung pada letak dan ukuran lesi. Terapi KSSRM yang paling sering dilakukan adalah radioterapi (Sonis et al., 1995).

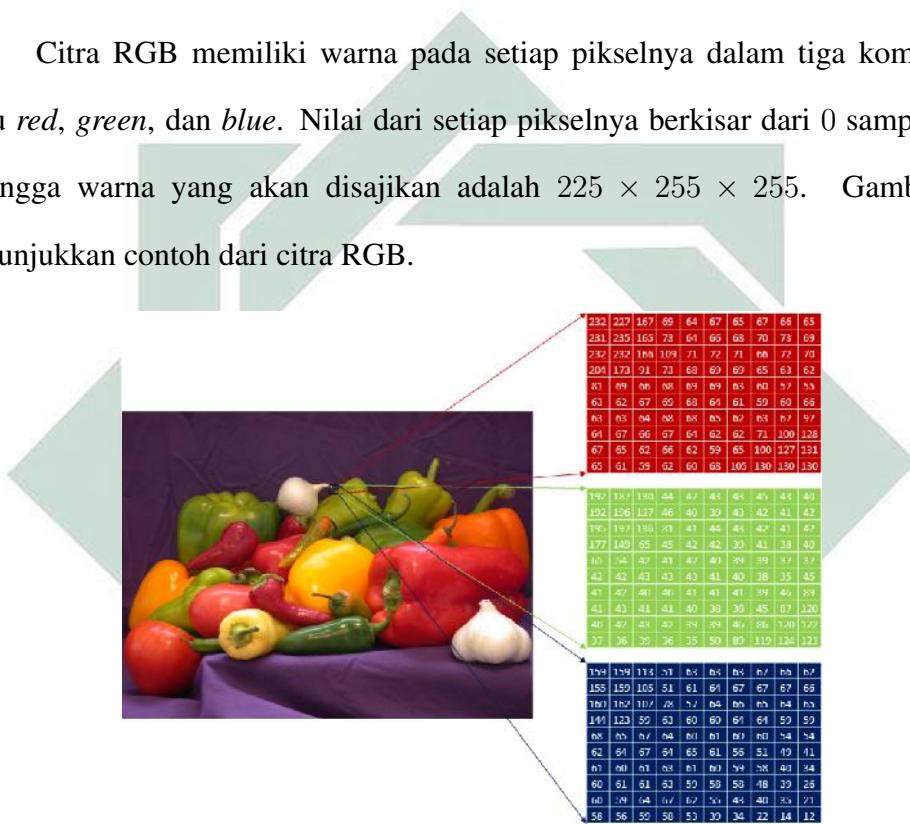
2.2. Citra Digital

Citra *digital* adalah suatu gambar dua dimensi yang terdiri dari piksel-piksel dengan nilai tertentu. Citra *digital* didefinisikan sebagai fungsi $f(x, y)$, dengan x dan y merupakan koordinat spasial dan amplitudo f di titik koordinat (x, y) yang merupakan intensitas atau tingkat keabuan dari suatu citra (Gonzalez and Woods, 2018). Citra yang berukuran $M \times N$ piksel dapat dituliskan sebagai matriks yang berukuran M baris dan N kolom. Persamaan menunjukkan citra yang direpresentasikan dalam bentuk matriks seperti yang ditunjukkan pada Persamaan 2.1.

$$f(x, y) = \begin{bmatrix} f(1, 1) & f(1, 2) & \cdots & f(1, N) \\ f(1, 0) & f(1, 1) & \cdots & f(2, N) \\ \vdots & \vdots & & \vdots \\ f(M, 1) & f(M, 2) & \cdots & f(M, N) \end{bmatrix} \quad (2.1)$$

Citra *digital* merupakan ilmu yang mempelajari pengolahan citra menggunakan komputer. Komputer hanya dapat mengolah data numerik, sehingga citra diubah ke bentuk matriks yang bernilai numerik dan diskrit agar dapat diolah menggunakan komputer. Citra *digital* dibagi menjadi 3 jenis berdasarkan tingkat warnanya, diantaranya adalah: citra RGB, citra *grayscale*, dan citra biner.

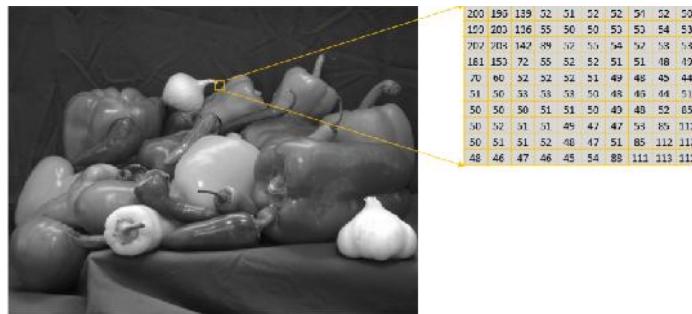
Citra RGB memiliki warna pada setiap pikselnya dalam tiga komponen, yaitu *red*, *green*, dan *blue*. Nilai dari setiap pikselnya berkisar dari 0 sampai 255. Sehingga warna yang akan disajikan adalah $225 \times 255 \times 255$. Gambar 2.4 menunjukkan contoh dari citra RGB.



Gambar 2.4 Citra RGB

Sumber: (MathWorks)

Citra *grayscale* adalah citra yang memiliki warna dari putih yang bergradasi hingga menjadi hitam. Nilai dari setiap pikselnya berkisar dari 0 yang berwarna hitam hingga 255 yang berwarna putih. Gambar 2.5 menunjukkan contoh dari citra *grayscale*.



Gambar 2.5 Citra *Grayscale*

Sumber: (MathWorks)

Citra grayscale dapat dibentuk melalui citra RGB menggunakan Persamaan 2.2.

$$gray = (0.2989 \times R) + (0.5870 \times G) + (0.1440 \times B) \quad (2.2)$$

Di mana, $gray$ merupakan hasil citra *grayscale*, R merupakan komponen *red* dari citra RGB, G merupakan komponen *green* dari citra RGB, dan B merupakan komponen *blue* dari citra RGB.

Citra biner merupakan citra yang setiap pikselnya hanya berwarna hitam atau putih. Sehingga, setiap pikselnya hanya memiliki dua nilai, yaitu 1 untuk warna putih dan 0 untuk warna hitam seperti yang ditunjukkan pada Persamaan 2.3.

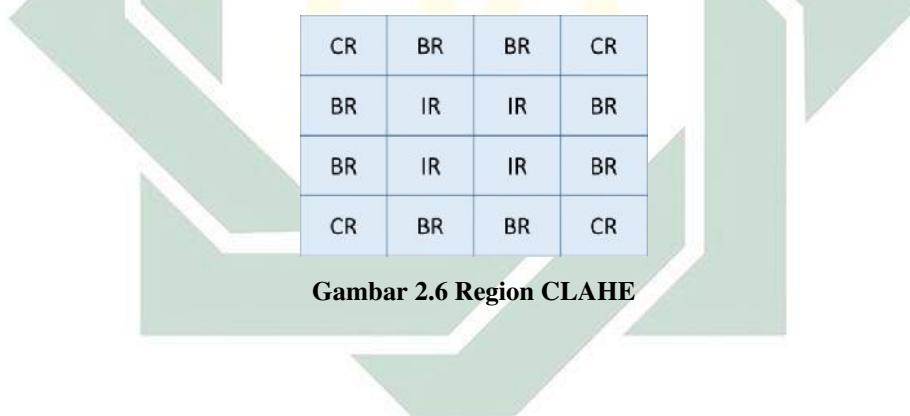
$$I_{Bin} = \begin{cases} 0; & \text{gray} < T \\ 1; & \text{gray} > T \end{cases} \quad (2.3)$$

Di mana, I_{Bin} merupakan nilai dari piksel citra biner, $gray$ merupakan nilai dari piksel citra *grayscale*, dan T merupakan nilai *threshold*.

2.3. Contrast Limited Adaptive Histogram Equalization (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan salah satu metode yang digunakan untuk meningkatkan kualitas dari suatu citra atau yang biasa disebut *image enhancement* (Saputra et al., 2021). CLAHE merupakan metode yang dikembangkan dari metode *Adaptive Histogram Equalization* (AHE) (Miranda et al., 2020). Sistem kerja CLAHE yaitu meratakan histogram pada setiap nilai piksel dari suatu citra pada setiap *region* menggunakan distribusi nilai keabuan, sehingga dapat memperlihatkan fitur yang tersembunyi dari suatu citra. CLAHE memiliki 3 *region* yang berbeda, di antaranya yaitu *Inner Region* (IR), *Boarder Region* (BR), dan *Conner Region* (CR) (Mu'jizah, 2021a).

Gambar 2.6 menunjukkan *region size* CLAHE.

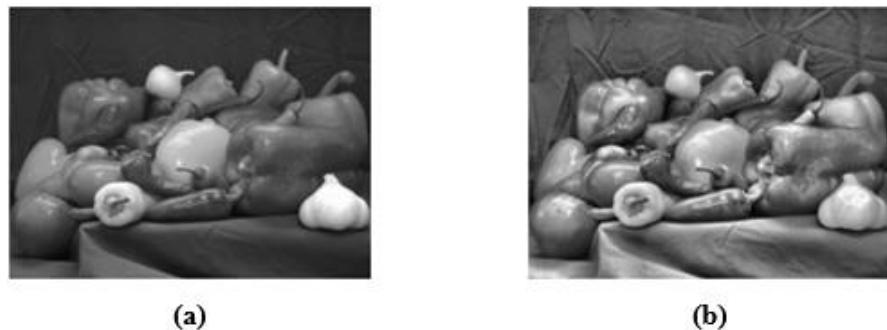


Persamaan 2.4 menunjukkan perhitungan dalam menghitung nilai *clip limit* (Zakiya and Novamizanti, 2021).

$$\beta = \frac{M}{N} \left(1 + \frac{\alpha}{100} (S_{max} - 1) \right) \quad (2.4)$$

Di mana, β merupakan nilai *clip limit*, M merupakan luas dari *region size*, N merupakan nilai piksel dari citra *grayscale* (256), dan α merupakan nilai *clip factor* yang merepresentasikan penambahan batas histogram dengan *range* nilai antara 0

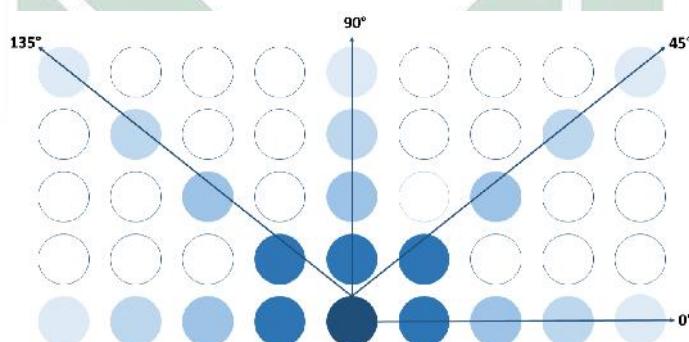
sampai 100. Perbandingan citra *grayscale* sebelum dilakukan CLAHE dan sesudah dilakukan CLAHE ditunjukkan pada Gambar 2.7.



Gambar 2.7 Perubahan Citra Sebelum dan Sesudah CLAHE

2.4. Gray Level Run Length Matrix (GLRLM)

Gray Level Run Length Matrix (GLRLM) merupakan salah satu metode ekstraksi fitur berdasarkan analisis tekstur pada suatu citra. Arah sudut yang digunakan dalam mencari nilai GLRLM adalah 0° , 45° , 90° , dan 135° seperti yang ditunjukkan pada Gambar 2.8 (Purwandari et al., 2018).



Gambar 2.8 Arah Sudut GLRLM

GLRLM menggunakan *Run Length Matrix* dalam mengamati jumlah piksel yang muncul sepanjang y pada tingkat keabuan x dengan arah sudut tertentu. Misalkan terdapat citra *grayscale* dengan nilai piksel citra yang ditunjukkan pada Gambar 2.9.

1	1	2	2	5
1	1	2	2	2
1	3	3	3	3
3	5	5	4	4
3	3	4	4	4

Gambar 2.9 Matriks Contoh Nlai Piksel Citra

Misalkan pada arah sudut 90° , dapat diketahui nilai piksel 1 pada Gambar 2.9 dengan *run length* 3 sebanyak 1 yang terletak sebelah kiri pada Gambar 2.10, maksudnya adalah nilai piksel 1 tersebut muncul sebanyak 3 kali dengan arah sesuai pada Gambar 2.8 apabila arah sudutnya 90° maka arahnya dari bawah ke atas.

0°	1	2	3	4	5
1	1	2	0	0	0
2	0	1	1	0	0
3	1	1	0	1	0
4	0	1	1	0	0
5	1	1	0	0	0

45°	1	2	3	4	5
1	1	2	0	0	0
2	3	1	0	0	0
3	5	1	0	0	0
4	1	2	0	0	0
5	3	0	0	0	0

(a) 0° (b) 45°

90°	1	2	3	4	5
1	0	1	1	0	0
2	1	2	0	0	0
3	5	1	0	0	0
4	1	2	0	0	0
5	3	0	0	0	0

(c) 90°

135°	1	2	3	4	5
1	3	1	0	0	0
2	1	2	0	0	0
3	5	1	0	0	0
4	3	1	0	0	0
5	3	0	0	0	0

(d) 135°

Gambar 2.10 Matriks Contoh Nlai Piksel Citra

GLRLM memiliki beberapa fitur menurut beberapa peneliti. Berdasarkan GalLoway terdapat lima fitur GLRLM yaitu: *Short Run Emphasis* (SRE), *Run Length Nonuniformity* (RLN), *Long Run Emphasis* (LRE), *Run Percentage* (RP), dan *Gray Level Nonuniformity* (GLN) (Galloway, 1975). Selanjutnya berdasarkan

Chu dkk terdapat 2 fitur GLLM, di antaranya adalah: *High Gray-level Run Emphasis* (HGRE) dan *Low Gray-level Run Emphasis* (LGRE) (Chu et al., 1990). Kemudian menurut Dasarathy dan Holder, GLRLM memiliki empat fitur GLRLM, di antaranya adalah: *Short Run High Gray-level Emphasis* (SRHGE), *Short Run Low Gray-level Emphasis* (SRLGE), *Long Run Low Gray-level Emphasis* (LRLGE), *Long Run High Gray-level Emphasis* (LRHGE) (Dasarathy and Holder, 1991).

2.4.1. Short Run Emphasis (SRE)

Short Run Emphasis (SRE) menunjukkan distribusi *short run*. SRE menunjukkan berapa banyak tekstur yang terdiri dari *short run* dalam arah sudut tertentu. Semakin kasar tekstur dari suatu citra maka semakin kecil nilai SRE. Rumus yang digunakan dalam menghitung SRE ditunjukkan pada Persamaan 2.5.

$$SRE = \frac{1}{r} \sum_{x=1}^M \sum_{y=1}^N \frac{P(x,y)}{y^2} \quad (2.5)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.2. Long Run Emphasis (LRE)

Long Run Emphasis (LRE) menunjukkan distribusi *long run*. LRE menunjukkan berapa banyak tekstur yang terdiri dari *long run* dalam arah sudut tertentu. Semakin besar nilai LRE maka tekstur suatu citra semakin kasar. Rumus

yang digunakan dalam menghitung LRE ditunjukkan pada Persamaan 2.6.

$$LRE = \frac{1}{r} \sum_{x=1}^M \sum_{y=1}^N y^2 P(x, y) \quad (2.6)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.3. Gray Level Nonuniformity (GLN)

Gray Level Nonuniformity (GLN) menunjukkan kesamaan nilai piksel pada seluruh citra dalam arah sudut tertentu. Nilai GLN akan semakin kecil apabila nilai tingkat keabuan pada seluruh citra sama. Rumus yang digunakan dalam menghitung GLN ditunjukkan pada Persamaan 2.7.

$$GLN = \frac{1}{r} \sum_{x=1}^M \left(\sum_{y=1}^N P(x, y) \right)^2 \quad (2.7)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.4. Run Length Nonuniformity (RLN)

Run Length Nonuniformity (RLN) menunjukkan kesamaan panjang lintasan pada seluruh citra dalam arah sudut tertentu. Nilai RLN akan semakin kecil jika pada seluruh citra memiliki run length yang sama. Rumus yang digunakan dalam

menghitung RLN ditunjukkan pada Persamaan 2.8.

$$RLN = \frac{1}{r} \sum_{y=1}^N \left(\sum_{x=1}^M P(x,y) \right)^2 \quad (2.8)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.5. Run Percentage (RP)

Run Percentage (RP) digunakan untuk mengukur kesamaan dan pembagian run pada arah sudut tertentu dari suatu citra. Rumus yang digunakan dalam menghitung RP ditunjukkan pada Persamaan 2.9.

$$RP = \frac{r}{\sum_{x=1}^M \sum_{y=1}^N y P(x, y)} \quad (2.9)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.6. Low Gray-level Run Emphasis (LGRE)

Low Gray-level Run Emphasis (LGRE) menunjukkan distribusi relatif dari nilai tingkat keabuan yang rendah. Rumus yang digunakan dalam menghitung

LGRE ditunjukkan pada Persamaan 2.10.

$$LGRE = \frac{1}{r} \sum_{x=1}^M \sum_{y=1}^N \frac{P(x,y)}{x^2} \quad (2.10)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.7. High Gray-level Run Emphasis (HGRE)

High Gray-level Run Emphasis (HGRE) menunjukkan distribusi relatif dari nilai tingkat keabuan yang tinggi. Rumus yang digunakan dalam menghitung HGRE ditunjukkan pada Persamaan 2.11.

$$HGRE == \frac{1}{r} \sum_{x=1}^M \sum_{y=1}^N x^2 P(x, y) \quad (2.11)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.8. Short Run Low Gray-level Emphasis (SRLGE)

Short Run Low Gray-level Emphasis (SRLGE) menunjukkan distribusi relatif dari *short run* dan nilai tingkat keabuan yang rendah. Rumus yang

digunakan dalam menghitung SLRGE ditunjukkan pada Persamaan 2.12.

$$SRLGE == \frac{1}{r} \sum_{x=1}^M \sum_{y=1}^N \frac{P(x,y)}{x^2 y^2} \quad (2.12)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.9. Short Run High Gray-level Emphasis (SRHGE)

Short Run High Gray-level Emphasis (SRHGE) menunjukkan distribusi relatif dari *short run* dan nilai tingkat keabuan tinggi. Rumus yang digunakan dalam menghitung SRHGE ditunjukkan pada Persamaan 2.13.

$$SRHGE == \frac{1}{r} \sum_{x=1}^M \sum_{y=1}^N \frac{P(x,y)x^2}{y^2} \quad (2.13)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.10. Long Run Low Gray-level Emphasis (LRLGE)

Long Run Low Gray-level Emphasis (LRLGE) menunjukkan distribusi relatif dari Long run dan nilai tingkat keabuan yang rendah. Rumus yang

digunakan dalam menghitung LRLGE ditunjukkan pada Persamaan 2.14.

$$LRLGE == \frac{1}{r} \sum_{x=1}^M \sum_{y=1}^N \frac{P(x,y)y^2}{x^2} \quad (2.14)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.4.11. Long Run High Gray-level Emphasis (LRHGE)

Long Run High Gray-level Emphasis (LRHGE) menunjukkan distribusi relatif dari Long run dan nilai tingkat keabuan yang tinggi. Rumus yang digunakan dalam menghitung LRHGE ditunjukkan pada Persamaan 2.15.

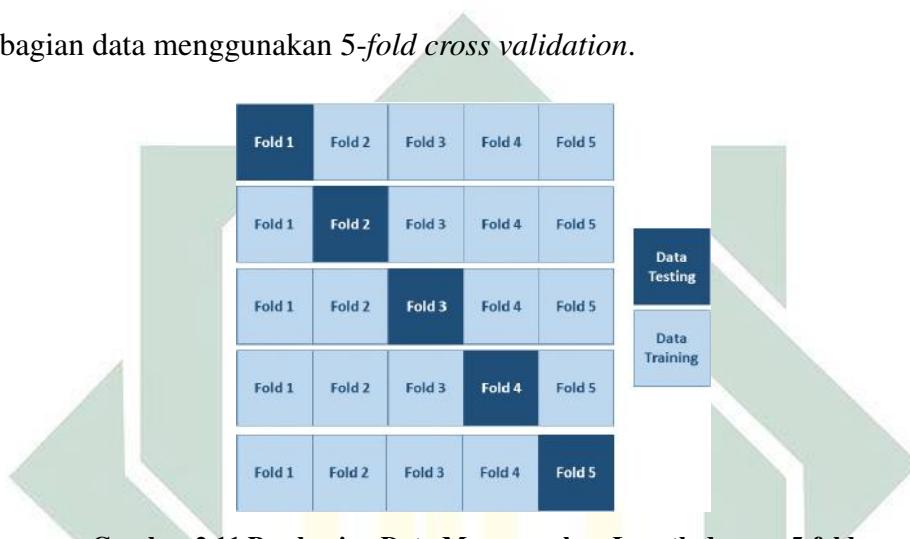
$$LRHGE = \frac{1}{r} \sum_{x=1}^M \sum_{y=1}^N P(x,y) x^2 y^2 \quad (2.15)$$

Di mana, r merupakan jumlah nilai piksel *run length matrix*, x merupakan baris, y merupakan kolom, M merupakan nilai piksel keabuan suatu citra, N merupakan jumlah piksel yang berurutan suatu citra, dan $P(x, y)$ merupakan nilai matriks *run length* pada baris x dan kolom y .

2.5. K-fold Cross Validation

K-fold Cross Validation merupakan suatu metode yang digunakan untuk melakukan validasi model untuk menilai akurasi hasil analisis sehingga diketahui bahwa hasil klasifikasi tidak hanya memiliki akurasi yang tinggi tetapi juga valid (Tempola et al., 2018). Data dilakukan pembagian data untuk proses *training* dan *testing* (Nasution et al., 2019). Pembagian data dilakukan sebanyak jumlah k yang

diinginkan kemudian dibagi dengan jumlah yang sama pada setiap lapisannya. Pada setiap proses yang dilakukan data *testing* yang digunakan merupakan data pada lapisan ke k , sedangkan sisanya merupakan data *training* (Cahyanti et al., 2020). Biasanya, nilai k dilakukan uji coba untuk mengetahui nilai k yang mendapatkan hasil terbaik (Mutiara, 2015). Gambar 2.11 menunjukkan proses pembagian data menggunakan *5-fold cross validation*.



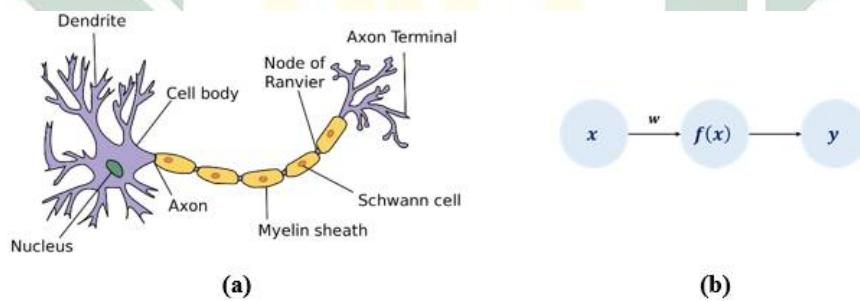
Gambar 2.11 Pembagian Data Menggunakan Length dengan 5-fold

Langkah-langkah dalam melakukan pembagian data menggunakan *K-fold Cross Validation* (Mu'jizah, 2021b):

1. Menentukan jumlah k yang diinginkan
 2. Membagi dataset sebanyak k yang telah ditentukan secara acak pada setiap kelas.
 3. Melakukan pengujian pada setiap *layer* proses pengelompokan.
 4. Langkah ketiga dilakukan sebanyak k yang telah ditentukan dan melakukan perhitungan rata-rata seluruh evaluasi *cross validation*.

2.6. Backpropagation

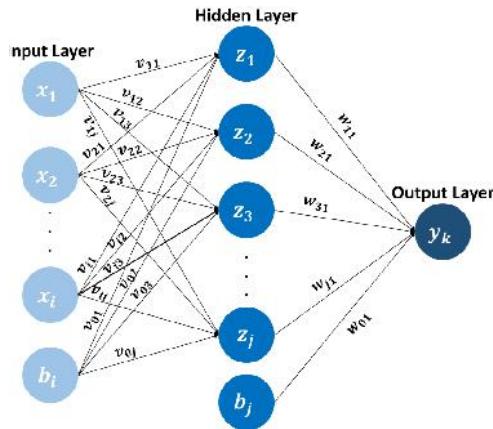
Backpropagation merupakan salah satu jenis Jaringan Saraf Tiruan (JST). Konsep JST berasal dari jaringan saraf manusia (Suhartanto et al., 2017). Seperti yang terlihat pada Gambar 2.12(a), pada jaringan saraf manusia terdapat dendrit, badan sel, akson, dan sinapsis. Dendrit berfungsi untuk menerima dan mengantarkan rangsangan ke badan sel, pada JST input x memiliki konsep yang sama dengan dendrit. Badan sel berfungsi untuk menerima rangsangan dari dendrit dan meneruskan ke akson, pada JST fungsi akstivasi $f(x)$ memiliki konsep yang sama dengan badan sel. Akson berfungsi untuk mengirimkan implus dari badan sel ke jaringan lain, pada JST *output y* memiliki konsep yang sama dengan akson. Sedangkan sinapsis berfungsi sebagai penghubung antara dua sel saraf, pada JST bobot memiliki konsep yang sama dengan sinapsis (Ariana, 2011).



Gambar 2.12 Perbandingan Konsep Jaringan Saraf Manusia dan JST (a) Jaringan Saraf Manusia (b) Jaringan Saraf Tiruan

Sumber: 2.12(a)(Wikipedia)

Secara umum, *Backpropagation* terdiri dari 3 layer, yaitu: *input layer*, *hidden layer*, dan *output layer* seperti yang ditunjukkan pada Gambar 2.13 (Sakinah et al., 2018). Arsitektur *Backpropagation* dapat diubah dengan menambahkan *hidden layer* dan jumlah node pada setiap *layer*.



Gambar 2.13 Arsitektur *Backpropagation*

Perhitungan pada metode *Backpropagation* terdiri dari 3 tahap, yaitu: Tahap pertama adalah *feed forward* atau yang biasa disebut dengan propagasi maju, pada tahap ini data inputan dihitung bersama dengan bobot yang telah ditentukan hingga mendapatkan *output*. Tahap kedua adalah *backward* atau yang biasa disebut dengan propagasi mundur, pada tahap ini menghitung *error* dari hasil klasifikasi dengan menghitung selisih antara target dan *output*. *Error* tersebut digunakan untuk menghitung *error* pada setiap *layer* sebelumnya. Tahap ketiga adalah *update* bobot berdasarkan *error* yang telah dihitung pada tahap kedua (Rosiani et al., 2021). *Backpropagation* terbagi menjadi 2 proses, yaitu proses *training* dan *testing*. Sehingga data yang digunakan dibagi menjadi 2, untuk proses *training* dan *testing*. Pada tahap *training* menggunakan data *training* untuk memperoleh model optimal. Langkah-langkah proses *training* menggunakan metode *Backpropagation* adalah (Solikhun et al., 2017):

1. Proses *training* diawali dengan inisialisasi bobot bilangan acak kecil dan parameter yang digunakan.
 2. Menghitung semua *output* di *hidden layer* (Z_{inj}) menggunakan Persamaan

2.16.

$$Z_{inj} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2.16)$$

Di mana, v_{0j} merupakan bobot bias pada *hidden layer node* ke- j , x_i merupakan data *training* ke- i , dan v_{ij} merupakan bobot data ke- i pada *hidden layer node* ke- j .

3. Menghitung Z_j menggunakan salah satu fungsi aktivasi menggunakan Persamaan 2.17.

$$Z_j = f(Z_{inj}) \quad (2.17)$$

Di mana, $f(Z_{inj})$ merupakan fungsi aktivasi pada *hidden layer*.

4. Menghitung semua jaringan di *unit output* (y_{ink}) menggunakan Persamaan 2.18.

$$y_{ink} = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (2.18)$$

Di mana, w_{0k} merupakan bobot bias pada *node output* ke- k , Z_j merupakan *node hidden layer* ke- j , w_{jk} merupakan bobot *node hidden layer* ke- j *node output* ke- k .

5. Kemudian menghitung (y_k) menggunakan salah satu fungsi aktivasi menggunakan Persamaan 2.19.

$$y_k = f(y_{ink}) \quad (2.19)$$

Di mana, $f(y_{ink})$ merupakan fungsi aktivasi pada *output layer*.

6. Menghitung selisih target dan *output* menggunakan Persamaan 2.20.

$$Error = t_k - y_k \quad (2.20)$$

Di mana, t_k merupakan target pada *node* ke- k dan y_k merupakan hasil diagnosis pada *output layer node* ke- k

7. Menghitung nilai kesalahan di setiap *unit output* menggunakan Persamaan 2.21.

$$\delta_k = Error f'(y_k) \quad (2.21)$$

Di mana, t_k merupakan target pada *node* ke- k , y_k merupakan hasil diagnosis pada *output layer node* ke- k , dan $f'(y_k)$ merupakan turunan dari fungsi aktivasi pada *output layer*.

8. Menghitung koreksi bobot yang akan digunakan untuk memperbarui bobot w_{jk} dan w_{0k} menggunakan Persamaan 2.22 dan 2.23.

$$\Delta w_{jk} = \alpha \delta_k Z_j \quad (2.22)$$

$$\Delta w_{0k} = \alpha \delta_k \quad (2.23)$$

Di mana, α merupakan *learning rate*, δ_k nilai kesalahan pada *output layer* node ke- k , Z_j merupakan *output* pada *hidden layer* node ke- j .

9. Menghitung nilai kesalahan di setiap *unit hidden* menggunakan Persamaan 2.24.

$$\delta_{inj} = \sum_{j=1}^p \delta_k w_{jk} \quad (2.24)$$

Di mana, δ_k nilai kesalahan pada *output layer node* ke- k dan w_{jk} merupakan bobot *node hidden layer* ke- j *node output* ke- k .

10. Menghitung informasi error menggunakan Persamaan 2.25.

$$\delta_j = \delta_{inj} f'(z_j) \quad (2.25)$$

Di mana, δ_{inj} nilai kesalahan pada *hidden layer node* ke- j dan $f'(z_j)$ merupakan turunan dari fungsi aktivasi pada *hidden layer*.

11. Menghitung koreksi bobot yang akan digunakan untuk memperbarui bobot v_{ij} dan v_{0j} menggunakan Persamaan 2.26 dan 2.27.

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (2.26)$$

$$\Delta v_{0j} = \alpha \delta_j \quad (2.27)$$

Di mana, α merupakan *learning rate*, δ_{inj} nilai kesalahan pada *hidden layer node* ke- j , dan x_i merupakan data *training* ke- i .

12. Update bobot menggunakan Persamaan 2.28 dan 2.29.

$$w_{baru} = w_{lama} + \Delta w \quad (2.28)$$

$$v_{baru} = v_{lama} + \Delta v \quad (2.29)$$

Di mana, w merupakan bobot *hidden layer* pada *output layer*. w_{baru} dan w_{lama} meliputi w_{jk} dan w_{0k} . v merupakan bobot *input layer* pada *hidden layer*. v_{baru} dan v_{lama} meliputi v_{ij} dan v_{0j} .

13. Setelah mendapatkan bobot w_{baru} dan v_{baru} baru kemudian dilanjutkan ke iterasi selanjutnya kembali ke langkah 2. Iterasi akan berhenti apabila nilai $error$ sudah memenuhi batas toleransi $error$.

Dari proses *training* didapatkan model yang optimal yang akan digunakan pada proses *testing*. Langkah-langkah proses *testing* menggunakan *Backpropagation* (Solikhun et al., 2017):

1. Menghitung semua *output* di *hidden layer* (Z_{inj}) menggunakan Persamaan 2.30.

$$Z_{inj} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2.30)$$

Di mana, v_{0j} merupakan bobot bias pada *hidden layer node* ke- j , x_i merupakan data *training* ke- i , dan v_{ij} merupakan bobot data ke- i pada *hidden layer node* ke- j .

2. Menghitung Z_j menggunakan salah satu fungsi aktivasi menggunakan Persamaan 2.31.

$$Z_j = f(Z_{inj}) \quad (2.31)$$

Di mana, $f(Z_{inj})$ merupakan fungsi aktivasi pada *hidden layer*.

3. Menghitung semua jaringan di *unit output* (y_{ink}) menggunakan Persamaan 2.32.

$$y_{ink} = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (2.32)$$

Di mana, w_{0k} merupakan bobot bias pada *node output* ke- k , Z_j merupakan *node hidden layer* ke- j , w_{jk} merupakan bobot *node hidden layer* ke- j *node output* ke- k .

4. Kemudian menghitung (y_k) menggunakan salah satu fungsi aktivasi menggunakan Persamaan 2.33.

$$y_k = f(y_{ink}) \quad (2.33)$$

Di mana, $f(y_{ink})$ merupakan fungsi aktivasi pada *output layer*.

2.7. Binary Confusion Matrix

Confusion matrix merupakan perhitungan yang digunakan untuk mengukur performa klasifikasi (Ruuska et al., 2018). Sedangkan *binary confusion matrix* merupakan *confusion matrix* yang digunakan untuk evaluasi sistem klasifikasi yang terdiri dari 2 kelas. Metode ini dapat menghitung nilai akurasi, sensitivitas, dan spesifisitas dengan mencari nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) yang terdapat pada tabel *confusion matrix* (Tzeng et al., 2020). TP merupakan data citra KSSRM yang terklasifikasi benar KSSRM, sedangkan TN merupakan data citra rongga mulut normal yang terklasifikasi benar rongga mulut normal. FN merupakan data KSSRM yang terklasifikasi salah sebagai citra rongga mulut normal, sedangkan FP merupakan data citra rongga mulut normal yang terklasifikasi salah sebagai KSSRM. Tabel *binary confusion matrix* ditunjukkan pada Gambar 2.14.

Hasil Klasifikasi	Data Aktual	
	+	-
+	TP	FP
-	FN	TN

Gambar 2.14 Binary Confusion Matrix

1. Akurasi, merupakan tingkat kesuksesan dalam performa klasifikasi. Rumus menghitung akurasi ditunjukkan pada Persamaan 2.34.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.34)$$

2. Sensitivitas, merupakan data KSSRM yang terklasifikasi benar KSSRM.

Rumus menghitung sensitivitas ditunjukkan pada Persamaan 2.35.

$$Sensitivitas = \frac{TP}{TP + FN} \quad (2.35)$$

3. Spesifisitas, merupakan data citra rongga mulut normal yang terklasifikasi benar rongga mulut normal. Rumus menghitung spesifisitas ditunjukkan pada Persamaan 2.36.

$$Spesifisitas = \frac{TN}{TN + FP} \quad (2.36)$$

2.8. Penyakit dalam Perspektif Islam

Manusia merupakan makhluk yang tercipta memiliki akal pikiran dan hawa nafsu, sehingga manusia tak luput dari melakukan kesalahan (Untari, 2012; Rusdiana et al., 2019). Allah Swt akan menegur manusia yang melakukan kesalahan agar manusia sadar akan kesalahannya dan segera bertaubat kepada Allah Swt (Fatimah, 2021). Salah satu teguran yang diberikan Allah Swt yaitu berupa cobaan penyakit sebagaimana firman Allah Swt pada Q.S Sad ayat 34:

وَلَقَدْ فَتَنَّا سُلَيْمَنَ وَالْقِينَى عَلَى كُرْسِيِّهِ جَسَداً ثُمَّ أَنَابَ

Artinya: "Sungguh, Kami benar-benar telah menguji Sulaiman dan Kami menggeletakkannya di atas kursinya sebagai tubuh (yang lemah karena sakit), kemudian dia bertobat." (Q.S. Sad/38:34). Ayat tersebut menjelaskan tentang Allah Swt yang memberikan cobaan kepada Nabi Sulaiman a.s. dengan menimpa penyakit keras hingga tergeletak di kursinya karena tidak memiliki kekuatan. Ketika Nabi Sulaiman a.s. mendapatkan cobaan tersebut, Nabi Sulaiman a.s. bertaubat kepada Allah Swt meminta maaf atas kesalahannya dan berserah diri

kepada Allah Swt. Dengan bertaubat dan bertawakkal kepada Allah Swt, Allah Swt akan menghilangkan cobaan yang diberikan bagi yang dikehendaki-Nya. Sebagaimana firman Allah Swt pada Q.S al-An'am ayat 17:

وَإِنْ يَمْسِسْكَ اللَّهُ بِضُرٍّ فَلَا كَاشِفَ لَهُ إِلَّا هُوَ وَإِنْ يَمْسِسْكَ بِخَيْرٍ فَهُوَ عَلَىٰ كُلِّ شَيْءٍ قَدِيرٌ

Artinya: “ Jika Allah Swt menimpakan kemudaratan kepadamu, tidak ada yang dapat menghilangkannya selain Dia; dan jika Dia memberikan kebaikan kepadamu, Dia Maha kuasa atas segala sesuatu” (Q.S al-An’am/6:17). Ayat tersebut menjelaskan Allah Swt yang Maha kuasa. Hanya Allah Swt yang dapat menghilangkan kemudaratan (seperti sakit, kemiskinan, duka cita, dll) yang telah diberikan Allah Swt kepada seseorang. Apabila terkena suatu penyakit tidak dapat hanya berdoa agar Allah Swt mengangkat penyakit yang telah diberikan, tetapi perlu melakukan ikhtiar dengan berobat sebagaimana pada hadis Imam Abu Daud:

حَتَّىٰ مُحَمَّدُ بْنُ عَبَادَةَ الْوَاسِطِيِّ حَدَّثَنَا يَرِيدُ بْنُ هَارُونَ أَخْبَرَنَا إِسْمَاعِيلُ بْنُ عَيَّاشَ عَنْ شَعْلَبَةَ بْنِ مُسْلِمٍ عَنْ أَبِي عِمْرَانَ الْأَنْصَارِيِّ عَنْ أُمِّ الدَّرَدَاءِ عَنْ أَبِي الدَّرَدَاءِ قَالَ رَسُولُ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ إِنَّ اللَّهَ أَنْزَلَ الدَّاءَ وَالدُّوَاءَ وَجَعَلَ لِكُلِّ دَاءٍ دَوَاءً فَتَدَوَّفُوا وَلَا تَدَوَّفُوا بِحَرَاجٍ (رواه أبو داود)

Artinya: Telah menceritakan kepada kami Muhammad bin 'Ubada 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 saw bersabda: "Sesungguhnya Allah Swt telah menurunkan penyakit, dan obat, dan menjadikan bagi setiap penyakit terdapat obatnya, maka berobatlah dan jangan

berobat dengan sesuatu yang haram!”. Hadis tersebut menjelaskan bahwa Allah Swt menurunkan suatu penyakit dan obatnya, sehingga apabila terkena penyakit harus berobat tetapi tidak dengan sesuatu yang diharamkan oleh Allah Swt.

Menurut ilmu *Maqashid al-syari'ah*, bidang kesehatan termasuk ke dalam bagian *Dharuriyyat* yang berarti kepentingan hidup dalam sub bagian *Hifdz an-Nafs* yang berarti memelihara jiwa (Qotadah, 2020). *Hifdz an-Nafs* merupakan dasar dari *Maqashid al-syari'ah*, apabila kita tidak melakukan *Hifdz an-Nafs* maka kita tidak bisa menjalani bagian dari *Maqashid al-syari'ah* yang lainnya. Hal tersebut menunjukkan bahwa menjaga tubuh dari suatu penyakit merupakan hal yang sangat penting, salah satunya adalah kanker mulut. Kanker mulut merupakan urutan keenam kanker yang paling umum di dunia (Müller, 2017). Salah satu faktor penyebab kanker mulut adalah kebersihan mulut yang tidak terjaga (Audiawati et al., 2021). Kebersihan mulut sangat penting untuk dijaga sebagaimana pada hadis Imam Bukhari:

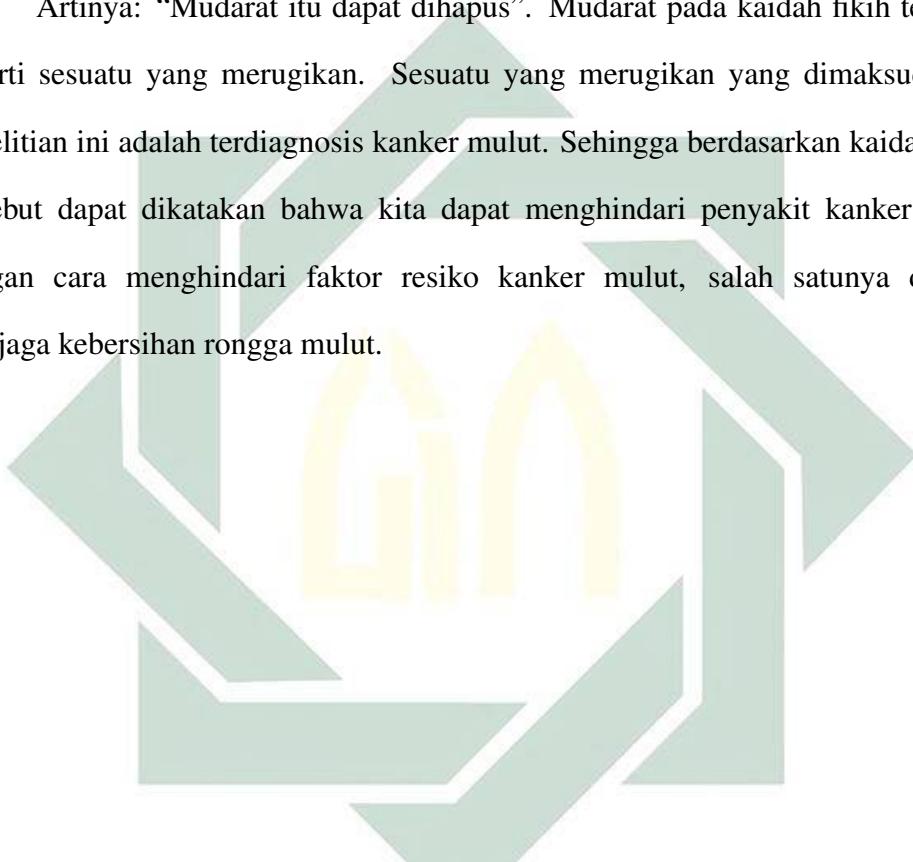
قَالَ رَسُولُ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ أَكْثَرُكُمْ فِي السِّوَاكِ (رواه البخاري)

Artinya: Telah menceritakan kepada kami Abu Ma'mar berkata, telah menceritakan kepada kami 'Abdul Warits berkata, telah menceritakan kepada kami Syu'aib bn Al Habhab telah menceritakan kepada kami Anas berkata, "Rasulullah saw bersabda: "Aku telah terlalu sering memperingatkan kalian untuk selalu bersiwak." Hadis tersebut menjelaskan bahwa Nabi Muhammad saw sering memerintahkan untuk menjaga kebersihan mulut dengan bersiwak. Bersiwak yang dimaksud pada hadis tersebut merupakan menggosok gigi. Dengan menjaga

kebersihan mulut berarti telah mengurangi resiko terdiagnosis kanker mulut sebagaimana dengan kaidah fikih berikut:

الضرر يزال

Artinya: “Mudarat itu dapat dihapus”. Mudarat pada kaidah fikih tersebut berarti sesuatu yang merugikan. Sesuatu yang merugikan yang dimaksud pada penelitian ini adalah terdiagnosis kanker mulut. Sehingga berdasarkan kaidah fikih tersebut dapat dikatakan bahwa kita dapat menghindari penyakit kanker mulut dengan cara menghindari faktor resiko kanker mulut, salah satunya dengan menjaga kebersihan rongga mulut.



BAB III

METODE PENELITIAN

3.1. Jenis Penelitian

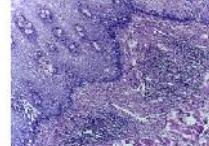
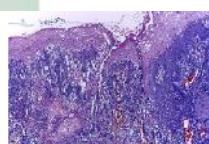
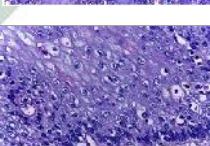
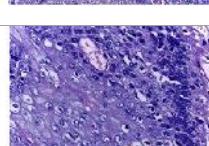
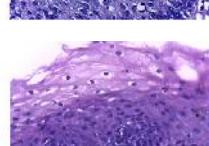
Penelitian ini merupakan penelitian kuantitatif karena data yang digunakan dalam mendiagnosis Karsinoma Sel Skuamosa Rongga Mulut (KSSRM) merupakan data citra histopatologi yang akan ditransformasikan menjadi data numerik sehingga penelitian ini terdapat perhitungan dan analisis hasil yang diperoleh.

3.2. Jenis dan Sumber Data

Data yang digunakan pada penelitian ini merupakan data sekunder yang dapat diunduh melalui website Mendeley Data (Rahman, 2019). Data yang digunakan adalah citra histopatologi rongga mulut dengan perbesaran 100x (10× lensa objektif dan 10× lensa mata) dan 400x (40× lensa objektif dan 10× lensa mata). Slide biopsi dikumpulkan dari *Ayursundra Healthcare Pvt. Ltd* dan *Dr. B. Borooah Cancer Institute* dari 230 pasien yang direkomendasikan untuk tes biopsi rongga mulut. Pengumpulan data dilakukan dari Oktober 2016 hingga November 2017. Citra diambil menggunakan mikroskop Leica DM 750 model ICC50 HD yang terhubung ke kamera dan komputer. Citra dengan perbesaran 100× digunakan untuk menganalisis tingkat arsitektur atau jaringan. Ini juga dapat digunakan dalam ekstraksi fitur seperti ekstraksi fitur bentuk, tekstur atau warna, segmentasi lapisan epitel, invasi tumor ke membran basal, atau dalam mengkategorikan gambar dalam kategori normal dan KKSRM dengan

mempertimbangkan keseluruhan arsitektur gambar. Sedangkan citra dengan perbesaran $400\times$ dapat digunakan untuk menganalisis tingkat jaringan, seperti dalam mendiagnosis otomatis penyakit berdasarkan fitur tekstur. Penelitian ini menggunakan 89 citra normal dan 439 citra KSSRM pada perbesaran $100\times$, sedangkan pada perbesaran $400\times$ terdapat 201 citra normal dan 495 citra KSSRM. Sehingga jumlah semua citra adalah 1224 citra. Citra yang digunakan berukuran $2048 \times 1536\ pixels$ (Rahman et al., 2020). Sampel data citra histopatologi rongga mulut normal dan KSSRM pada perbesaran $100\times$ dan $400\times$ ditunjukkan pada Tabel 3.1.

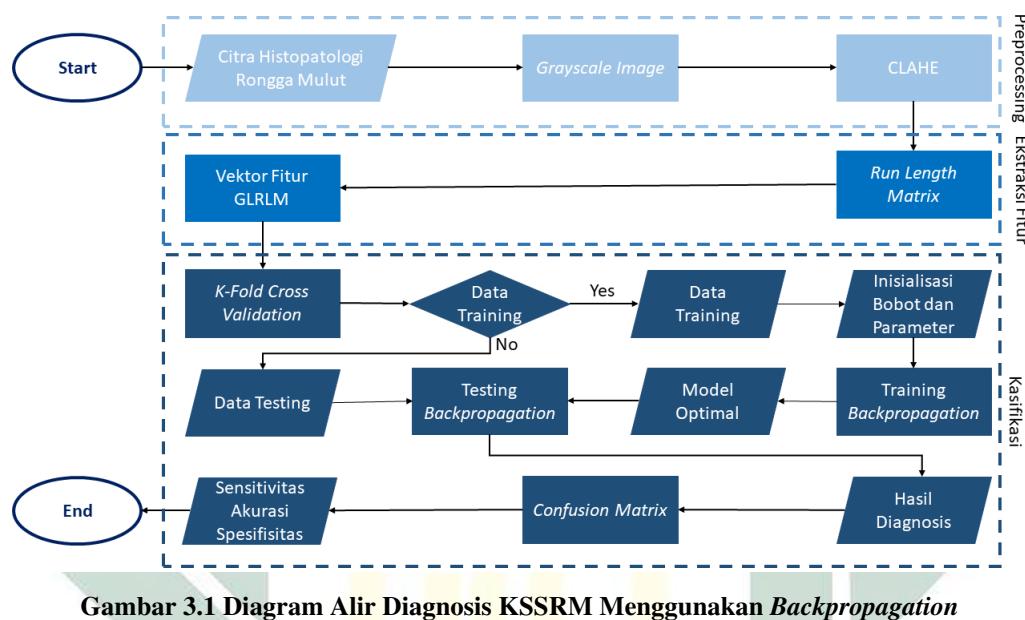
Tabel 3.1 Sampel Data Citra Histopatologi Rongga Mulut

Perbesaran Lensa	Kelas	Sampel Citra	
100×	Normal		
	KSSRM		
400×	Normal		
	KSSRM		

Sumber: (Rahman, 2019)

3.3. Kerangka Penelitian

Penelitian ini memiliki beberapa tahapan, di antaranya adalah tahap *preprocessing* data, ekstraksi fitur, tahap *training*, tahap *testing*, dan tahap evaluasi.



Berdasarkan Gambar 3.1 tahap-tahap dalam penelitian ini adalah:

1. Mengumpulkan data citra histopatologi rongga mulut normal dan KSSRM.
Mengubah data citra yang semula RGB menjadi *grayscale* menggunakan Persamaan 2.2.
 2. Menerapkan metode CLAHE dalam memperbaiki kualitas citra dengan menggunakan Persamaan 2.4.
 3. Menerapkan metode GLRLM untuk mendapatkan fitur-fitur yang ada pada suatu citra berdasarkan ciri tekstur dengan arah sudut 0° , 45° , 90° , dan 135° menggunakan Persamaan 2.5 hingga Persamaan 2.15. Arah sudut tersebut akan dilakukan uji coba untuk mengetahui sudut mana yang dapat mendiagnosis citra histopatologi rongga mulut.

4. Membagi data untuk proses *training* dan *testing* menggunakan metode *K-fold Cross Validation* dengan melakukan uji coba pada nilai k sebesar 5 dan 10 *fold*.
 5. Menginisialisasi bobot dan parameter yang akan dilakukan uji coba untuk mengetahui parameter yang menghasilkan akurasi terbaik dari model yang didapatkan. Parameter yang dilakukan uji coba di antaranya adalah jumlah *hidden layer* sebanyak 1 dan 2, jumlah *node* pada setiap *hidden layer* sebanyak 10, 50, dan 100, dan *learning rate* sebesar 0.1 hingga 0.5. Sedangkan parameter tetap yang digunakan adalah 5000 *epoch*, 1000 *performance goal*, dan $\theta = 0.5$.
 6. Melakukan proses *training* berdasarkan 3 tahap metode *Backpropagation* (*feed forward*, *backward*, dan *update bobot*) menggunakan Persamaan 2.16 hingga Persamaan 2.29 untuk mendapatkan model optimal yang akan digunakan pada proses *testing*.
 7. Melakukan proses *testing* berdasarkan Persamaan 2.30 hingga Persamaan 2.33 (tahap *feed forward*) menggunakan model yang telah didapatkan dari proses *training* untuk mendapatkan hasil diagnosis apakah citra tersebut termasuk citra histopatologi rongga mulut normal atau KSSRM.
 8. Mengevaluasi hasil diagnosis dengan menghitung sensitivitas, akurasi, dan spesifisitas berdasarkan *confusion matrix* yang didapatkan dari jumlah TP, TN, FP, dan FN menggunakan Persamaan 2.34 hingga Persamaan 2.36.

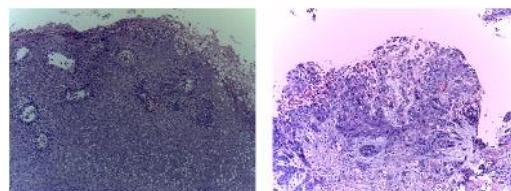
BAB IV

HASIL DAN PEMBAHASAN

Pada bagian ini akan membahas mengenai hasil perhitungan dan analisis pada penelitian ini pada setiap tahap. Penelitian ini terdiri dari 4 tahap, yaitu *preprocessing*, ekstraksi fitur, klasifikasi, dan evaluasi. Penelitian ini membuat sistem diagnosis KSSRM menggunakan citra histopatologi rongga mulut yang diperoleh melalui *website* Mendeley Data dengan perbesaran lensa $100\times$ dan $400\times$. Data citra yang digunakan memiliki ukuran 2048×1536 dengan tipe RGB.

4.1. Preprocessing

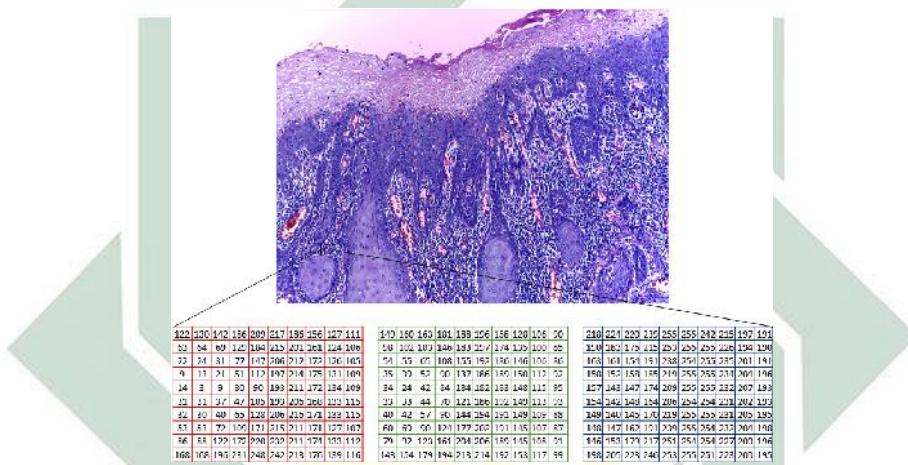
Tahap awal yang dilakukan pada penelitian ini adalah tahap *preprocessing*. *Preprocessing* digunakan untuk memperbaiki data yang akan digunakan sebelum melakukan ekstraksi fitur. Karena pada data citra yang digunakan memiliki intensitas yang berbeda sehingga pencahayaannya tidak merata seperti yang terlihat pada Gambar 4.1. Pada tahap *perprocessing* penelitian ini akan melakukan proses mengubah citra RGB menjadi grayscale dan meningkatkan kualitas citra menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE).



Gambar 4.1 Perbedaan Cahaya pada Data

4.1.1. *Grayscale*

Grayscale merupakan teknik yang digunakan untuk mengubah citra RGB menjadi citra keabuan, sehingga dapat memudahkan dalam proses pengolahan. Penelitian ini menggunakan data yang memiliki 3 *channel*, yaitu: *Red*, *Green*, dan *Blue*. Gambar 4.2 menunjukkan sampel citra histopatologi rongga mulut dan nilai pada setiap *channelnya*.



Gambar 4.2 Nilai R, G, dan B pada Sampel Citra KSSRM

Berdasarkan Gambar 4.2 terlihat bahwa nilai *Red*, *Green*, dan *Blue* berupa matriks dengan ukuran 2048×1536 sesuai ukuran pada citra. Dalam mengubah citra RGB menjadi grayscale dapat dihitung menggunakan Persamaan 2.2 pada setiap koordinat piksel citra.

$$gray(1,1) = (0.2989 \times 255) + (0.5870 \times 255) + (0.1440 \times 255) = 255$$

$$gray(1536, 1) = (0.2989 \times 50) + (0.5870 \times 60) + (0.1440 \times 181) = 71$$

$$gray(2048, 1) = (0.2989 \times 251) + (0.5870 \times 240) + (0.1440 \times 254) = 245$$

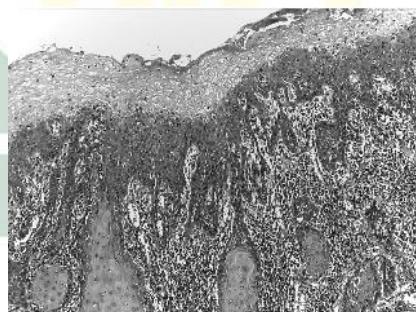
$$gray(1536, 2048) = (0.2989 \times 157) + (0.5870 \times 139) + (0.1440 \times 249) = 157$$

Dari hasil proses perhitungan akan menghasilkan sebuah matriks citra *grayscale*

sebagai berikut:

$gray =$	255	255	255	255	\cdots	253	251	252	245
	255	255	255	255	\cdots	252	251	251	248
	255	255	255	255	\cdots	252	250	243	247
	255	255	255	255	\cdots	252	251	238	238
	:	:	:	:	\ddots	:	:	:	:
	69	48	41	63	\cdots	173	177	175	168
	68	53	46	65	\cdots	166	171	168	164
	70	62	52	68	\cdots	154	158	159	162
	71	65	51	67	\cdots	140	138	148	157

Matriks tersebut berukuran 2048×1536 dan terdapat sebanyak 1224 citra sesuai dengan jumlah citra keseluruhan baik pada perbesaran $100\times$ maupun $400\times$. Sampel citra hasil proses grayscale ditunjukkan pada Gambar 4.3.



Gambar 4.3 Sampel Citra Hasil Grayscale

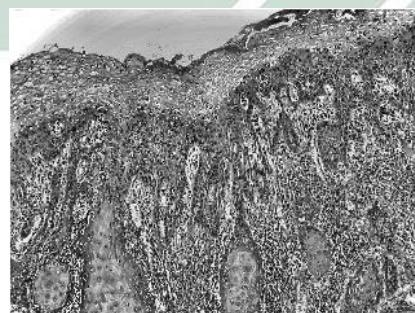
4.1.2. Contrast Limited Adaptive Histogram Equalization (CLAHE)

Data citra yang digunakan pada penelitian ini memiliki tingkat kecerahan yang berbeda. Hal itu dapat mempengaruhi hasil diagnosis. Sehingga pada penelitian ini menggunakan CLAHE untuk mengatasi permasalahan tersebut. CLAHE dapat meningkatkan kontras suatu citra sehingga membuat suatu citra

menjadi lebih tajam. Cara kerja CLAHE yaitu dengan membagi citra menjadi beberapa *region*. Apabila terdapat *region* yang memiliki kontras berlebihan dapat diatasi dengan memberikan nilai batas pada histogram atau yang disebut dengan *crip limit*. Nilai *crip limit* digunakan pada penelitian ini adalah 0.02. Proses ini menghasilkan matriks baru yang memiliki ukuran 2048×1536 seperti matriks di bawah ini.

CLAHE =	255	255	255	255	...	237	220	226	199
	255	255	255	255	...	226	220	220	248
	255	255	255	255	...	226	214	196	204
	255	255	255	255	...	226	220	180	173
	:	:	:	:	..	:	:	:	:
	43	25	19	37	...	150	152	151	146
	42	29	24	39	...	144	148	146	143
	44	36	28	42	...	134	137	138	141
	45	39	27	41	...	121	120	129	137

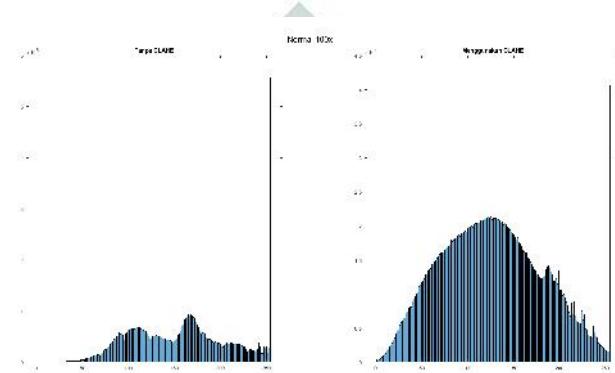
Sampel citra hasil CLAHE ditunjukkan pada Gambar 4.4.



Gambar 4.4 Sampel Citra Hasil CLAHE

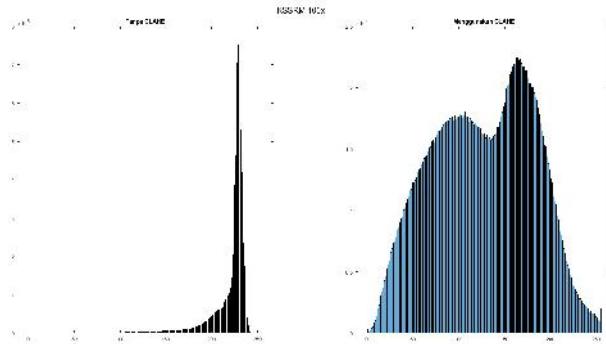
Perbandingan histogram citra normal pada perbesaran lensa $100\times$ sebelum dan sesudah CLAHE ditunjukkan pada Gambar 4.5. Dapat dilihat pada Gambar 4.5, citra sebelum CLAHE memiliki *contrast* yang rendah karena histogram

mengarah ke tengah, di mana tengah merupakan warna antara hitam dan putih, sehingga citra memiliki *contrast* yang lemah. Pada histogram citra sesudah dilakukan CLAHE, histogram citra merata dari 0 sampai 255. Sebelum dilakukan CLAHE citra memiliki rata-rata 143.22 setelah dilakukan CLAHE citra memiliki rata-rata sebesar 126.50.



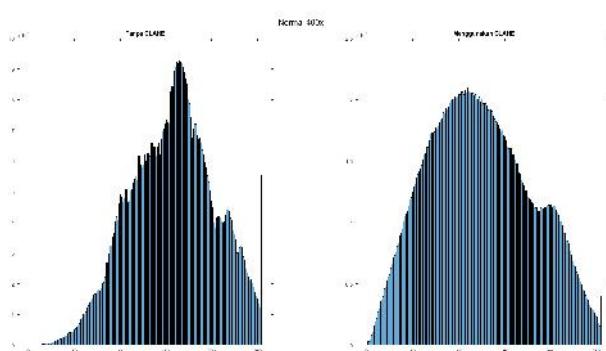
Gambar 4.5 Perbandingan Histogram Citra 100× Normal Sebelum dan Sesudah CLAHE

Perbandingan histogram citra KSSRM pada perbesaran lensa $100\times$ sebelum dan sesudah CLAHE ditunjukkan pada Gambar 4.6. Dapat dilihat pada Gambar 4.6, citra sebelum CLAHE memiliki histogram yang tidak merata, histogram lebih cenderung ke arah kanan saja. Hal tersebut dapat mengakibatkan melemahnya *contrast*. Pada histogram citra sesudah dilakukan CLAHE, histogram citra merata dari 0 sampai 255. Sebelum dilakukan CLAHE citra memiliki rata-rata 218.30 setelah dilakukan CLAHE citra memiliki rata-rata sebesar 126.70.



Gambar 4.6 Perbandingan Histogram Citra 100× KSSRM Sebelum dan Sesudah CLAHE

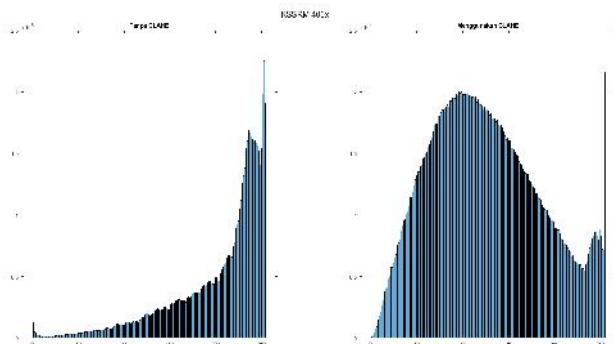
Perbandingan histogram citra normal pada perbesaran lensa $400\times$ sebelum dan sesudah CLAHE ditunjukkan pada Gambar 4.7. Dapat dilihat pada Gambar 4.7, citra sebelum CLAHE memiliki histogram yang tidak rata. Pada histogram citra sesudah dilakukan CLAHE, histogram citra merata dari 0 sampai 255. Sebelum dilakukan CLAHE citra memiliki rata-rata 145.84 setelah dilakukan CLAHE citra memiliki rata-rata sebesar 123.198.



Gambar 4.7 Perbandingan Histogram Citra $400 \times$ Normal Sebelum dan Sesudah CLAHE

Perbandingan histogram citra KSSRM pada perbesaran lensa $400\times$ sebelum dan sesudah CLAHE ditunjukkan pada Gambar 4.8. Dapat dilihat pada Gambar 4.8, citra sebelum CLAHE memiliki histogram yang tidak merata dan cenderung

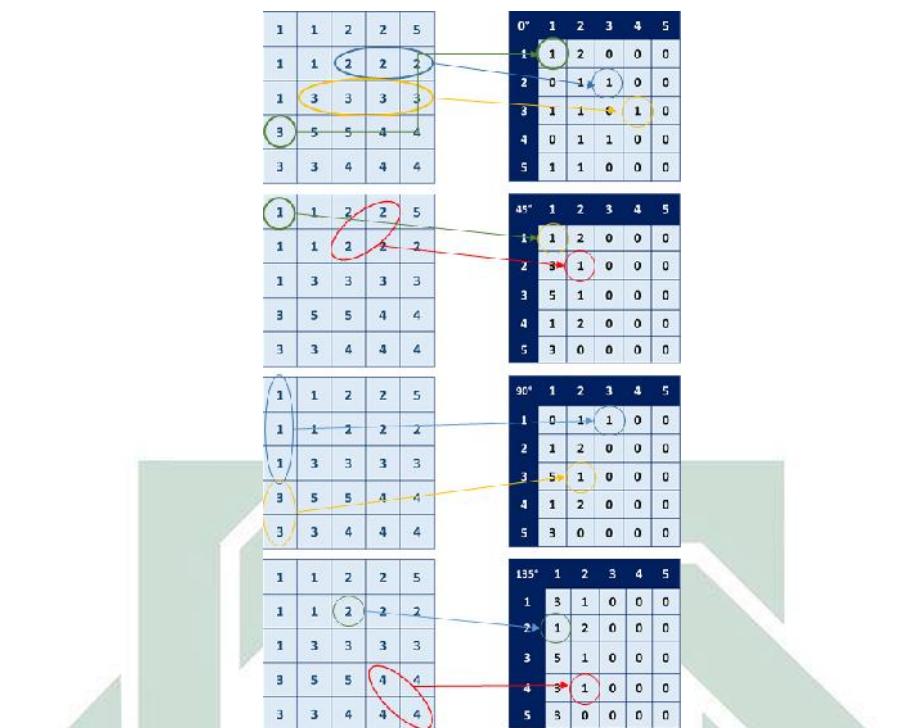
ke arah kanan saja. Hal tersebut dapat mengakibatkan melemahnya *contrast*. Pada histogram citra sesudah dilakukan CLAHE, histogram citra merata dari 0 sampai 255. Sebelum dilakukan CLAHE citra memiliki rata-rata 189.07 setelah dilakukan CLAHE citra memiliki rata-rata sebesar 125.01.



Gambar 4.8 Perbandingan Histogram Citra 400× KSSRM Sebelum dan Sesudah CLAHE

4.2. Ekstraksi Fitur

Ekstraksi fitur merupakan proses yang digunakan untuk mengambil ciri pada suatu data. Pada penelitian ini mengambil nilai ciri tekstur pada citra. Metode yang digunakan adalah *Gray Level Run Length Matrix (GLRLM)*. Cara kerja GLRLM adalah dengan mencari matriks *run length* yang menunjukkan jumlah keseluruhan munculnya *run* dengan panjang dari tingkat keabuan dalam sebuah arah sudut berdasarkan citra hasil CLAHE. Sudut orientasi yang digunakan pada penelitian ini adalah 0° , 45° , 90° , dan 135° sehingga akan menghasilkan 4 matriks *run length* pada setiap citra. Cara mencari matriks *run length* ditunjukkan pada Gambar 4.9.

Gambar 4.9 Cara Mencari Matriks *Run Length*

Berdasarkan Gambar 4.9 terlihat bahwa matriks sebelah kiri merupakan contoh matriks yang merepresentasikan sebagai citra dan matriks sebelah kanan merupakan matriks *run length* pada arah sudut tertentu. Pada arah sudut 0° , mengarah dari kiri ke kanan, pada sudut 45° mengarah dari kiri ke kanan atas, pada arah sudut 90° mengarah dari bawah ke atas, sedangkan pada arah sudut 135° mengarah dari kanan ke kiri atas. Baris pada matriks *run length* menyatakan nilai *grayscale* sedangkan kolom pada matriks *run length* menyatakan jumlah *run lengthnya*. Berikut merupakan matriks *run length* pada arah sudut 0° .

$$RunLength0^\circ = \begin{bmatrix} 5 & 0 & 0 & 0 & \cdots & 0 & 0 & 0 & 0 \\ 131 & 3 & 0 & 0 & \cdots & 0 & 0 & 0 & 0 \\ 284 & 21 & 2 & 0 & \cdots & 0 & 0 & 0 & 0 \\ 451 & 42 & 1 & 0 & \cdots & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots \\ 2459 & 193 & 26 & 1 & \cdots & 0 & 0 & 0 & 0 \\ 2283 & 136 & 20 & 1 & \cdots & 0 & 0 & 0 & 0 \\ 2034 & 144 & 7 & 3 & \cdots & 0 & 0 & 0 & 0 \\ 1547 & 185 & 49 & 15 & \cdots & 0 & 0 & 0 & 0 \end{bmatrix}$$

Dari matriks *run length* yang dihasilkan kemudian melakukan perhitungan ekstraksi fitur menggunakan Persamaan 2.5 hingga Persamaan 2.15. Pada penelitian ini menggunakan 11 fitur GLRLM, yaitu: SRE, LRE, GLN, RLN, RP, LGRE, HGRE, SRLGE, SRHGE, LRLGE, dan LRHGE. Sehingga setiap matriks *run length* memiliki 11 fitur. Berikut merupakan perhitungan pada setiap fitur GLRLM. Sebelum menghitung setiap fiturnya, terlebih dahulu menghitung nilai r . Nilai r merupakan jumlah nilai dari setiap elemen matriks *run length*. Nilai r akan digunakan pada semua fitur GLRLM.

$$\begin{aligned} r &= (5 + 0 + 0 + \cdots + 131) + (3 + 0 + \cdots + 1547) + \cdots + (185 + 49 + \cdots + 0) \\ &= 2788879 \end{aligned}$$

$$\begin{aligned} SRE &= \frac{1}{2788879} \left[\left(\frac{5}{1^2} + \frac{0}{2^2} + \cdots + \frac{0}{2048^2} \right) + \left(\frac{131}{1^2} + \frac{3}{2^2} + \cdots + \frac{0}{2048^2} \right) + \cdots \right. \\ &\quad \left. + \left(\frac{1547}{1^2} + \frac{185}{2^2} + \cdots + \frac{0}{2048^2} \right) \right] \\ &= 8.96 \times 10^{-2} \end{aligned}$$

$$\begin{aligned}
LRE &= \frac{1}{2788879} \left[(1^2 \cdot 5 + 2^2 \cdot 0 + \dots + 2048^2 \cdot 0) + (1^2 \cdot 131 + 2^2 \cdot 3 + \dots \right. \\
&\quad \left. + 2048^2 \cdot 0) + \dots (1^2 \cdot 1547 + 2^2 \cdot 185 + \dots + 2048^2 \cdot 0) \right] \\
&= 8.96 \times 10
\end{aligned}$$

$$\begin{aligned}
GLN &= \frac{1}{2788879} \left[(5 + 0 + \dots + 0) + (131 + 3 + \dots + 0) + \dots + (1547 + 185 + \right. \\
&\quad \left. \dots + 0) \right] \\
&= 3.20 \times 10^5
\end{aligned}$$

$$\begin{aligned}
RLN &= \frac{1}{2788879} \left[(5 + 131 + \dots + 1547) + (0 + 3 + \dots + 185) + \dots (0 + 0 + \right. \\
&\quad \left. \dots + 0) \right] \\
&= 1.94 \times 10^5
\end{aligned}$$

$$\begin{aligned}
RP &= \frac{2788879}{\left[(1 \cdot 5 + 2 \cdot 0 + \dots + 2048 \cdot 0) + (1 \cdot 131 + 2 \cdot 3 + \dots + 2048 \cdot 0) + \dots \right.} \\
&\quad \left. (1 \cdot 1547 + 2 \cdot 185 + \dots + 2048 \cdot 0) \right]} \\
&= 6.88 \times 10
\end{aligned}$$

$$\begin{aligned}
LGRE &= \frac{1}{2788879} \left[\left(\frac{5}{1^2} + \frac{0}{1^2} + \dots + \frac{0}{1^2} \right) + \left(\frac{131}{2^2} + \frac{3}{2^2} + \dots + \frac{0}{2^2} \right) + \dots \right. \\
&\quad \left. \left(\frac{1547}{256^2} + \frac{185}{256^2} + \dots + \frac{0}{256^2} \right) \right] \\
&= 5.40 \times 10^{-1}
\end{aligned}$$

$$\begin{aligned}
HGRE &= \frac{1}{2788879} \left[(1^2 \cdot 5 + 1^2 \cdot 0 + \dots + 1^2 \cdot 0) + (2^2 \cdot 131 + 2^2 \cdot 3 + \dots + 2^2 \cdot 0) + \right. \\
&\quad \left. \dots (256^2 \cdot 1547 + 256^2 \cdot 0 + \dots + 256^2 \cdot 0) \right] \\
&= 1.12 \times 10^2
\end{aligned}$$

$$\begin{aligned}
SRLGE &= \frac{1}{2788879} \left[\left(\frac{5}{1^2 \cdot 1^2} + \frac{0}{1^2 \cdot 2^2} + \dots + \frac{0}{1^2 \cdot 2048^2} \right) + \left(\frac{131}{2^2 \cdot 1^2} + \frac{3}{2^2 \cdot 2^2} + \right. \right. \\
&\quad \left. \left. \dots + \frac{0}{2^2 \cdot 2048^2} \right) + \dots + \left(\frac{1547}{256^2 \cdot 1^2} + \frac{185}{256^2 \cdot 2^2} + \dots + \frac{0}{256^2 \cdot 2048^2} \right) \right] \\
&= 1.24 \times 10^1
\end{aligned}$$

$$\begin{aligned}
SRHGE &= \frac{1}{2788879} \left[\left(\frac{1^2 \cdot 5}{1^2} + \frac{1^2 \cdot 0}{2^2} + \dots + \frac{1^2 \cdot 0}{2048^2} \right) + \left(\frac{2^2 \cdot 131}{1^2} + \frac{2^2 \cdot 3}{2^2} + \dots \right. \right. \\
&\quad \left. \left. + \frac{2^2 \cdot 0}{2048^2} \right) + \dots + \left(\frac{256^2 \cdot 1547}{1^2} + \frac{256^2 \cdot 185}{2^2} + \dots + \frac{256^2 \cdot 0}{2048^2} \right) \right] \\
&= 3.81
\end{aligned}$$

$$\begin{aligned}
LRLGE &= \frac{1}{2788879} \left[\left(\frac{1^2 \cdot 5}{1^2} + \frac{1^2 \cdot 0}{2^2} + \dots + \frac{1^2 \cdot 0}{2048^2} \right) + \left(\frac{2^2 \cdot 131}{1^2} + \frac{2^2 \cdot 3}{2^2} + \dots + \right. \right. \\
&\quad \left. \left. 2^2 \cdot 0 \right) + \dots + \left(\frac{256^2 \cdot 1547}{1^2} + \frac{256^2 \cdot 185}{2^2} + \dots + \frac{256^2 \cdot 0}{2048^2} \right) \right] \\
&= 1.24 \times 10
\end{aligned}$$

$$\begin{aligned}
LRHGE &= \frac{1}{2788879} \left[(5 \cdot 1^2 \cdot 1^2 + 0 \cdot 1^2 \cdot 2^2 + \dots + 0 \cdot 1^2 \cdot 2048^2) + (131 \cdot 2^2 \cdot 2^2 + \right. \\
&\quad 3 \cdot 2^2 \cdot 2^2 + \dots + 0 \cdot 2^2 \cdot 2048^2) + \dots (1547 \cdot 256^2 \cdot 1^2 + 185 \cdot 256^2 \cdot 2048^2 \\
&\quad \left. + \dots + 0 \cdot 256^2 \cdot 2048^2) \right] \\
&= 4.22 \times 10^3
\end{aligned}$$

Perhitungan tersebut merupakan fitur untuk satu citra pada satu arah sudut. Sehingga perhitungan tersebut diulang sebanyak jumlah data dan pada setiap arah sudut. Nilai fitur tersebut akan digunakan sebagai inputan pada tahap klasifikasi. Tabel hasil perhitungan ekstraksi fitur pada setiap arah sudut ditunjukkan pada Tabel 4.1 hingga Tabel 4.4.

Tabel 4.1 Hasil GLRLM pada Arah Sudut 0°

SRE	LRE	GLN	RLN	RP	LGRE	HGRE	SRLGE	SRHGE	LRLGE	LRHGE	Kelas
0.08	23.09	159659.12	135573.59	47.02	0.45	308.00	0.04	10.33	10.89	11306.83	Normal
0.05	25.09	190224.60	230788.80	59.00	0.41	22.52	0.02	1.44	10.76	555.13	
0.06	25.17	201604.88	237690.58	59.38	0.43	23.06	0.02	1.41	11.17	565.95	
0.08	23.86	222576.24	159749.63	56.49	0.49	70.42	0.04	3.10	12.34	2532.12	
0.05	24.98	183618.67	233586.36	57.54	0.41	23.26	0.02	1.43	10.63	554.20	
0.07	28.01	250703.60	181862.13	62.77	0.49	26.28	0.03	1.32	13.62	910.40	KSSRM
0.08	21.90	140802.08	152929.37	48.56	0.40	44.67	0.03	2.94	8.99	1035.96	
0.09	22.67	154775.24	150124.17	51.65	0.40	34.09	0.03	2.47	9.45	879.84	
0.08	23.20	94026.69	121089.47	38.12	0.35	138.21	0.03	7.63	8.39	3269.93	
0.09	22.36	185539.61	162814.20	56.97	0.43	23.66	0.04	2.04	9.92	519.67	

Tabel 4.2 Hasil GLRLM pada Arah Sudut 45°

SRE	LRE	GLN	RLN	RP	LGRE	HGRE	SRLGE	SRHGE	LRLGE	LRHGE	Kelas
0.08	23.01	240849.95	168530.65	77.60	0.51	86.57	0.04	3.51	12.14	3054.38	Normal
0.05	25.00	374108.65	308507.54	105.18	0.54	11.82	0.03	0.76	14.00	287.22	
0.06	24.94	387445.75	316518.40	106.12	0.55	11.56	0.03	0.68	14.09	285.58	
0.08	23.62	358903.30	202810.53	95.63	0.56	35.39	0.04	1.63	13.95	1228.35	
0.05	24.96	347409.24	305050.19	100.74	0.53	13.04	0.03	0.81	13.72	303.58	
0.07	28.11	398421.13	227022.42	103.73	0.57	15.26	0.04	0.78	16.18	528.08	
0.08	21.93	245275.49	197501.66	83.43	0.49	25.72	0.04	1.68	11.11	600.54	
0.09	22.68	265511.06	192187.83	88.61	0.49	18.83	0.04	1.39	11.44	480.08	
0.07	23.49	152295.38	150456.22	62.80	0.44	77.83	0.03	4.42	10.63	1826.88	
0.09	22.26	320504.94	209132.47	97.74	0.52	13.24	0.04	1.15	11.87	291.24	

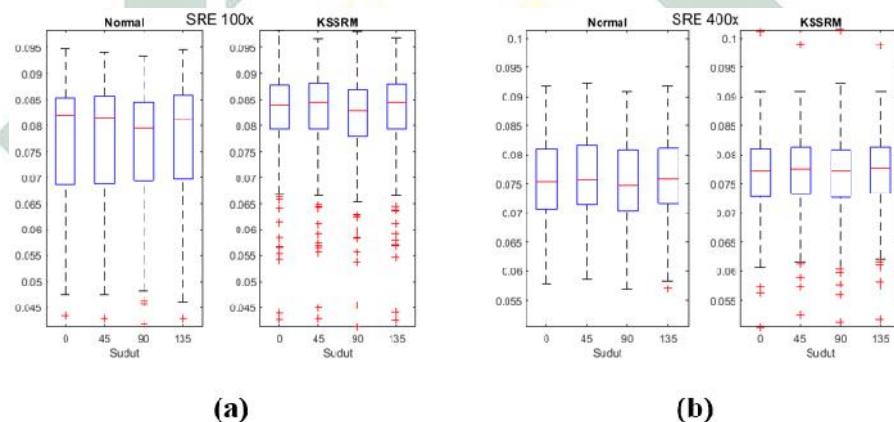
Tabel 4.3 Hasil GLRLM pada Arah Sudut 90°

SRE	LRE	GLN	RLN	RP	LGRE	HGRE	SRLGE	SRHGE	LRLGE	LRHGE	Kelas
0.08	23.32	154726.12	137225.52	62.54	0.44	108.51	0.03	4.84	10.81	3709.83	Normal
0.05	25.17	275629.39	270879.41	91.09	0.49	17.40	0.03	1.17	12.72	420.61	
0.06	24.99	288626.26	279619.54	92.84	0.50	15.96	0.03	0.95	12.77	395.59	
0.08	23.84	219901.49	157275.33	73.95	0.49	110.57	0.04	4.31	12.33	4108.46	
0.05	25.08	255727.69	269086.78	87.69	0.48	18.17	0.02	1.15	12.42	429.33	
0.07	27.91	276144.58	190453.03	87.58	0.51	23.11	0.04	1.18	14.01	800.67	
0.08	21.99	149574.13	157793.89	66.45	0.41	42.94	0.03	2.84	9.33	993.49	
0.08	22.99	140805.12	145214.15	66.52	0.39	34.88	0.03	2.65	9.27	875.99	
0.07	23.95	88560.41	118524.79	48.84	0.36	125.86	0.02	7.48	9.12	2918.30	
0.09	22.41	178962.02	162241.28	75.07	0.42	24.06	0.03	2.10	9.75	530.48	

Tabel 4.4 Hasil GLRLM pada Arah Sudut 135°

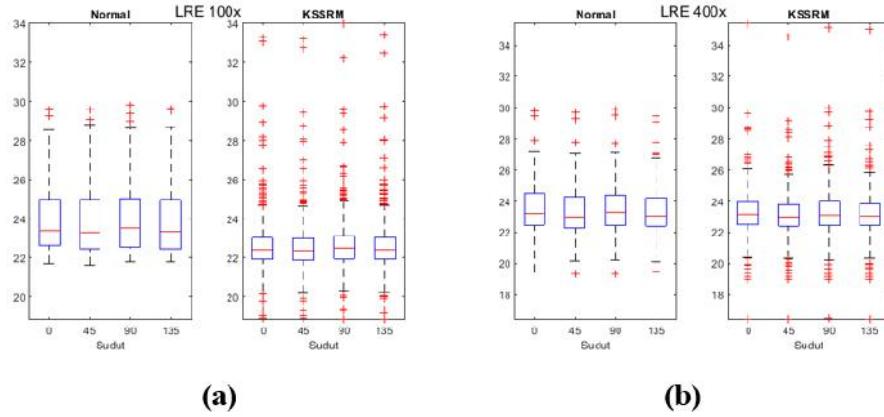
SRE	LRE	GLN	RLN	RP	LGRE	HGRE	SRLGE	SRHGE	LRLGE	LRHGE	Kelas
0.08	23.13	242782.84	168593.47	77.80	0.51	69.76	0.04	3.06	12.24	2341.38	Normal
0.05	24.98	371614.22	307540.96	105.02	0.54	11.82	0.03	0.78	13.93	280.32	
0.06	24.99	375872.36	312261.05	104.44	0.55	11.87	0.03	0.71	14.02	289.42	
0.08	23.80	277269.83	175226.17	82.95	0.53	71.35	0.04	3.00	13.18	2537.16	
0.05	24.87	349740.62	307298.86	101.68	0.53	12.39	0.03	0.75	13.64	295.73	
0.07	28.07	411434.46	228766.87	104.80	0.58	15.25	0.04	0.77	16.36	528.60	
0.08	21.93	244292.41	197605.18	83.58	0.48	24.90	0.04	1.65	11.06	574.93	
0.09	22.64	253738.22	187956.96	86.69	0.48	19.90	0.04	1.46	11.26	504.92	
0.07	23.21	169938.47	160589.11	66.91	0.45	70.50	0.03	3.90	10.71	1672.67	KSSRM
0.09	22.17	304981.19	204397.19	95.66	0.51	13.84	0.04	1.19	11.60	306.27	

Perbandingan karakteristik data normal dan KSSRM pada setiap fitur data ditunjukkan pada Gambar 4.10 hingga Gambar 4.20.



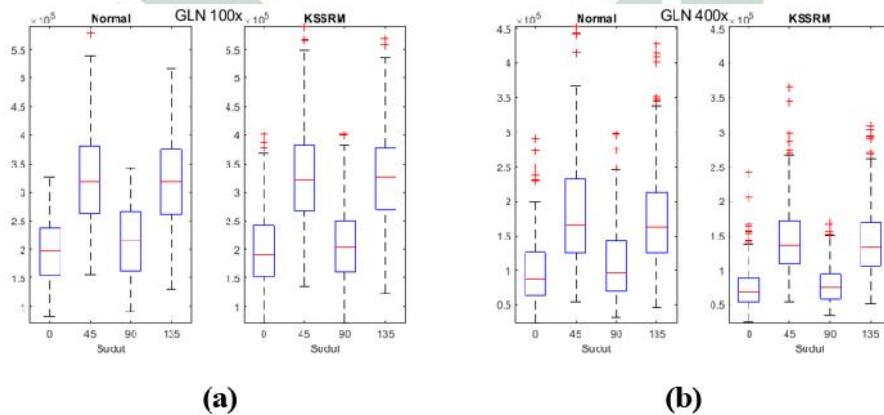
Gambar 4.10 Visualisasi Nilai SRE pada Perbesaran Lensa (a) 100× (b) 400×

Gambar 4.10 menunjukkan sebaran data pada fitur SRE. Berdasarkan Gambar 4.10 terlihat bahwa citra KSSRM memiliki *range* angka yang lebih tinggi dibandingkan citra normal. Semakin tinggi nilai SRE, maka semakin halus tekstur citra tersebut, berarti citra normal memiliki tekstur lebih kasar dibandingkan dengan tekstur pada citra KSSRM.



Gambar 4.11 Visualisasi Nilai LRE pada Perbesaran Lensa (a) 100× (b) 400×

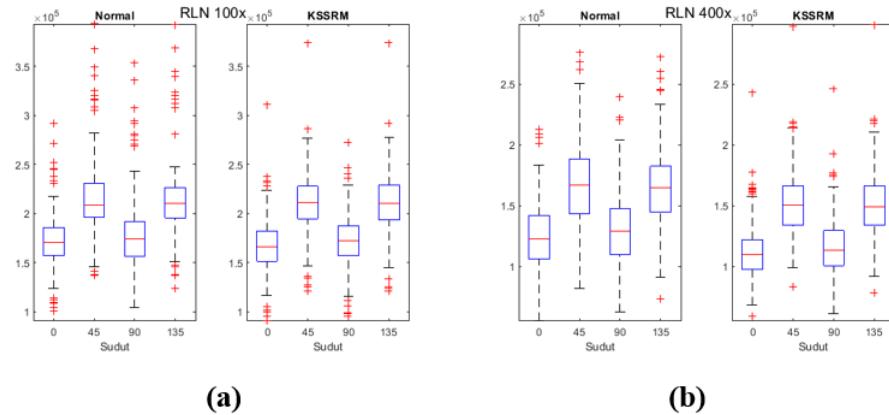
Gambar 4.11 menunjukkan sebaran data pada fitur LRE. Berdasarkan Gambar 4.11 terlihat bahwa citra normal memiliki *range* angka yang relatif lebih tinggi dibandingkan dengan citra KSSRM. Semakin tinggi nilai LRE, maka semakin kasar tekstur citra tersebut, berarti citra normal memiliki tekstur lebih kasar dibandingkan dengan tekstur pada citra KSSRM.



Gambar 4.12 Visualisasi Nilai GLN pada Perbesaran Lensa (a) 100× (b) 400×

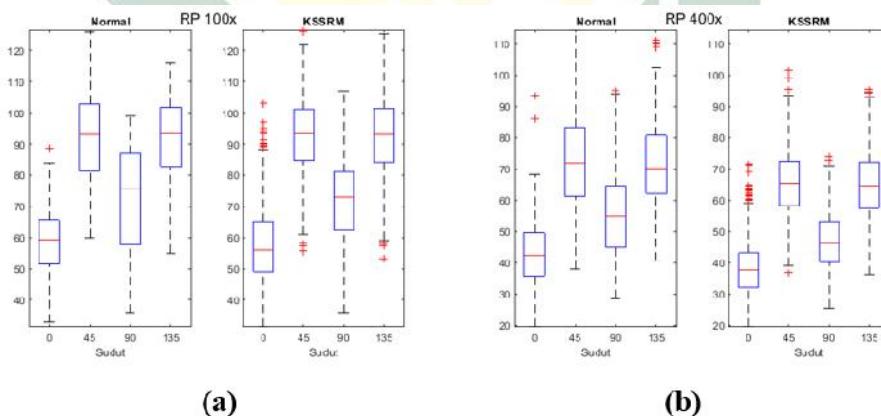
Gambar 4.12 menunjukkan sebaran data pada fitur GLN. Berdasarkan Gambar 4.12 terlihat bahwa pada arah sudut 0° dan 90° baik pada kelas normal maupun KSSRM dan pada perbesaran lensa $100\times$ dan $400\times$ memiliki *range* nilai

yang lebih tinggi dibandingkan dengan sudut 45° dan 135° .



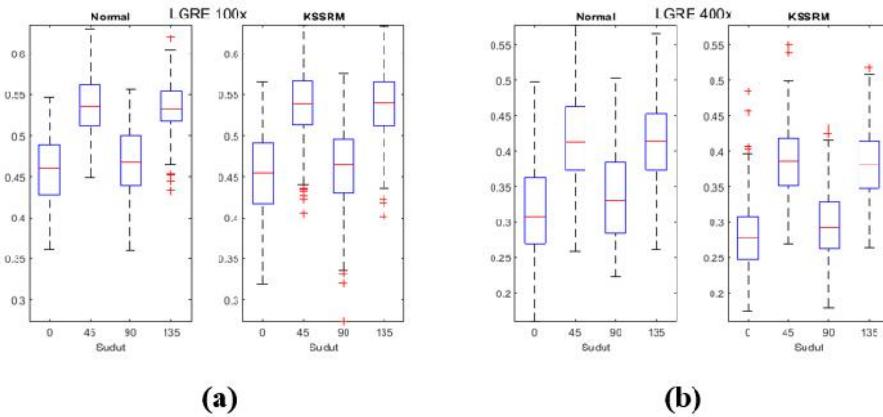
Gambar 4.13 Visualisasi Nilai RLN pada Perbesaran Lensa (a) 100× (b) 400×

Gambar 4.13 menunjukkan sebaran data pada fitur RLN. Berdasarkan Gambar 4.13 terlihat bahwa pada arah sudut 0° dan 90° baik pada kelas normal maupun KSSRM dan pada perbesaran lensa $100\times$ dan $400\times$ memiliki *range* nilai yang lebih tinggi dibandingkan dengan sudut 45° dan 135° .



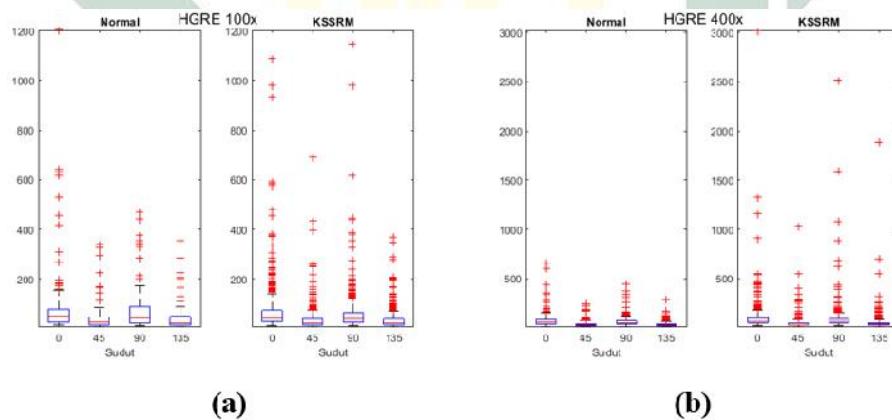
Gambar 4.14 Visualisasi Nilai RP pada Perbesaran Lensa (a) 100× (b) 400×

Gambar 4.14 menunjukkan sebaran data pada fitur RP. Berdasarkan Gambar 4.14 terlihat bahwa pada arah sudut 0° dan 90° baik pada kelas normal maupun KSSRM dan pada perbesaran lensa $100\times$ dan $400\times$ memiliki *range* nilai yang lebih tinggi dibandingkan dengan sudut 45° dan 135° .



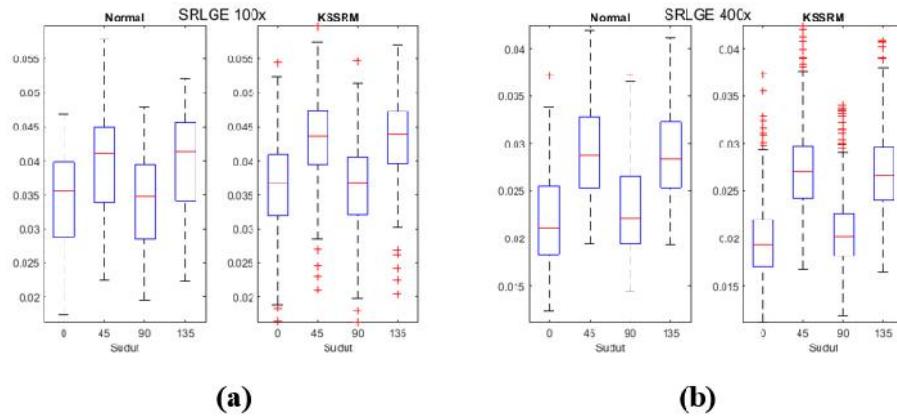
Gambar 4.15 Visualisasi Nilai LGRE pada Perbesaran Lensa (a) 100× (b) 400×

Gambar 4.15 menunjukkan sebaran data pada fitur LGRE. Berdasarkan Gambar 4.15 terlihat bahwa citra normal dan KSSRM pada perbesaran lensa $100\times$ memiliki nilai median yang hampir sama. Sedangkan pada perbesaran lensa $400\times$ kelas normal memiliki range nilai yang lebih tinggi dibandingkan kelas KSSRM.



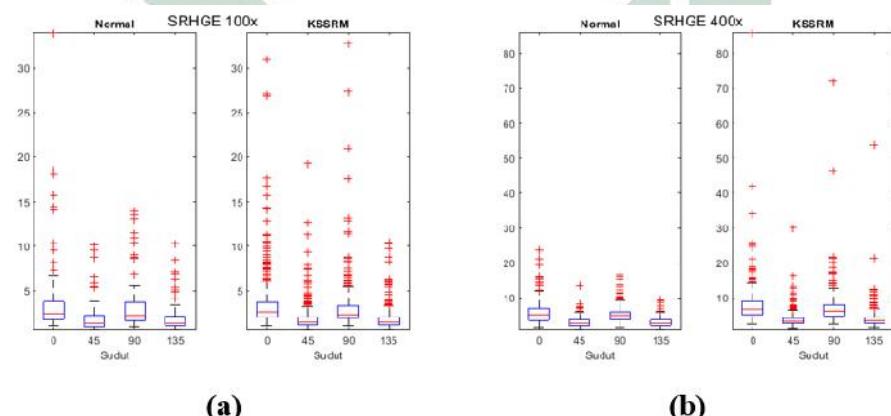
Gambar 4.16 Visualisasi Nilai HGRE pada Perbesaran Lensa (a) 100× (b) 400×

Gambar 4.16 menunjukkan sebaran data pada fitur HGRE. Berdasarkan Gambar 4.16 terlihat bahwa citra KSSRM memiliki *range* angka lebih panjang dibandingkan dengan citra normal.



Gambar 4.17 Visualisasi Nilai SRLGE pada Perbesaran Lensa (a) 100× (b) 400×

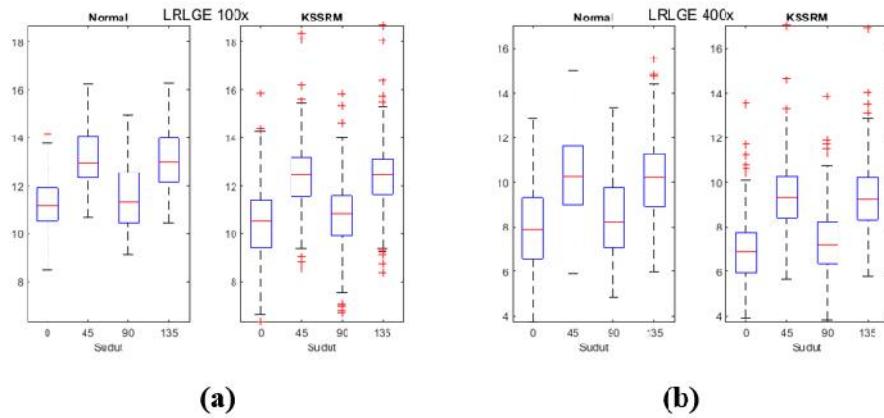
Gambar 4.17 menunjukkan sebaran data pada fitur SRLGE. Berdasarkan Gambar 4.17 terlihat bahwa citra KSSRM pada perbesaran lensa $100\times$ memiliki *range* nilai lebih tinggi dibandingkan dengan citra normal. Sedangkan pada perbesaran lensa $400\times$ citra normal memiliki *range* nilai lebih tinggi dibandingkan dengan citra KSSRM.



Gambar 4.18 Visualisasi Nilai SRHGE pada Perbesaran Lensa (a) 100× (b) 400×

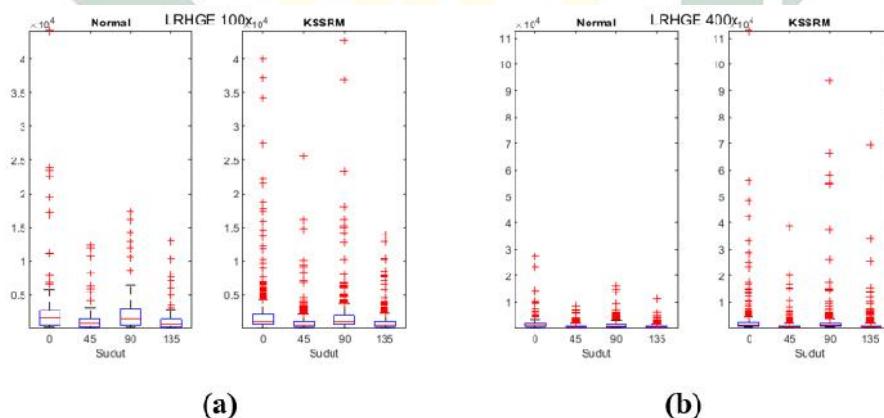
Gambar 4.18 menunjukkan sebaran data pada fitur SRHGE. Berdasarkan Gambar 4.18 terlihat bahwa citra normal dan KSSRM memiliki nilai median hampir sama dengan citra KSSRM. Tetapi citra KSSRM memiliki *range* nilai yang lebih

tinggi.



Gambar 4.19 Visualisasi Nilai LRLGE pada Perbesaran Lensa (a) 100× (b) 400×

Gambar 4.19 menunjukkan sebaran data pada fitur LRLGE. Berdasarkan Gambar 4.19 terlihat bahwa citra KSSRM memiliki range nilai yang lebih rendah dibandingkan dengan citra normal, baik pada perbesaran lensa $100\times$ maupun $400\times$.



Gambar 4.20 Visualisasi Nilai LRHGE pada Perbesaran Lensa (a) 100× (b) 400×

Gambar 4.20 menunjukkan sebaran data pada fitur LRHGE. Berdasarkan Gambar 4.20 terlihat bahwa citra normal dan KSSRM memiliki nilai median hampir sama dengan citra KSSRM. Tetapi citra KSSRM memiliki *range* nilai yang lebih tinggi.

4.3. Klasifikasi

Tahap klasifikasi pada penelitian ini menggunakan metode *Backpropagation* untuk mengklasifikasi hasil ekstraksi fitur yang menjadi inputan. Pada tahap klasifikasi terdapat 2 proses, yaitu proses *training* dan proses *testing* sehingga data hasil ekstraksi fitur yang digunakan sebagai inputan dibagi untuk proses *training* dan *testing*.

Pembagian data pada penelitian ini menggunakan metode *K-fold Cross Validation* dengan uji coba nilai k sebesar 5 dan 10. Perbandingan jumlah pembagian data pada $k = 5$ dan 10 ditunjukkan pada Tabel 4.5. Berdasarkan Tabel 4.5 data yang digunakan sebagai inputan berupa matriks $M \times N$, dengan M merupakan jumlah data dan N yang berjumlah 11 merupakan jumlah fitur GLRLM. Pada $k = 5$ dan perbesaran lensa $100 \times$ data *training* berjumlah 422 hingga 423 data *testing* berjumlah 105 hingga 106 data. Sedangkan pada perbesaran lensa $400 \times$ data *training* berjumlah 556 hingga 557 data *testing* berjumlah 139 hingga 140 data. Pada $k = 10$ dan perbesaran lensa $100 \times$ data *training* berjumlah 475 hingga 476 data *testing* berjumlah 52 hingga 53 data. Sedangkan pada perbesaran lensa $400 \times$ data *training* berjumlah 625 hingga 627 data *testing* berjumlah 69 hingga 71 data. Semakin besar nilai k maka semakin banyak data untuk proses *training* dan semakin sedikit data untuk proses *testing*.

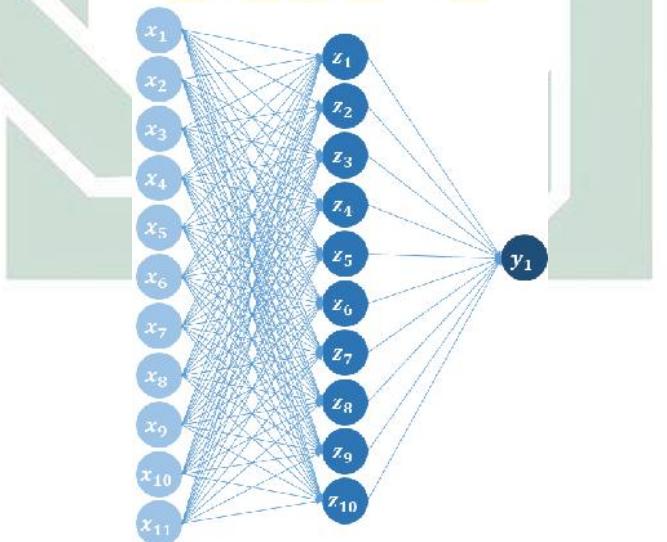
Tabel 4.5 Perbandingan Pembagian Jumlah Data Menggunakan *K-Fold*

K-Fold	Proses	Training	Testing
5	100×	423×11	105×11
		423×11	105×11
		422×11	106×11
		422×11	106×11

		422 × 11	106 × 11
400×	557 × 11	139 × 11	
		140 × 11	
		139 × 11	
		139 × 11	
		139 × 11	
10	100×	475 × 11	53 × 11
		475 × 11	53 × 11
		476 × 11	52 × 11
		475 × 11	53 × 11
		475 × 11	53 × 11
		476 × 11	52 × 11
		475 × 11	53 × 11
		475 × 11	53 × 11
		475 × 11	53 × 11
		475 × 11	53 × 11
400×	627 × 11	69 × 11	
		70 × 11	
		71 × 11	
		70 × 11	
		69 × 11	
		69 × 11	
		69 × 11	
		70 × 11	

627×11 69×11

Setelah melakukan pembagian data untuk proses *training* dan *testing* kemudian memasuki proses *training*. Pada tahap ini akan memperlihatkan perhitungan pada data perbesaran lensa $100\times$, arah sudut GLRLM 0° , uji coba satu *hidden layer* dengan 10 *node*, dan $\alpha = 0.1$. Gambar 4.21 menunjukkan arsitektur *Backpropagation* 11-10-1, yaitu 11 *node input layer* karena ekstraksi fitur yang digunakan memiliki 11 fitur, 10 merupakan jumlah *node* pada *hidden layer*, dan 1 *node* pada *output layer*. Karena pada penelitian ini memiliki 2 kelas (normal dan KSSRM), maka *output* yang dihasilkan diberi batas atau *threshold* (θ) yang bernilai 0.5. Data akan terdiagnosis KSSRM (1) apabila $\text{output} \geq 0.5$ dan data akan terdiagnosis normal (0) apabila $\text{output} < 0.5$.



Gambar 4.21 Arsitektur *Backpropagation* dengan 10 node *Hidden Layer*

4.3.1. Proses *Training*

Proses *training* digunakan untuk mencari model terbaik yang akan digunakan pada proses *testing*. Cara kerja pada proses *training* adalah

menginputkan inisialisasi parameter yang akan dilakukan uji coba kemudian dihitung menggunakan Persamaan 2.16 hingga Persamaan 2.29. Langkah pertama yang dilakukan adalah melakukan inisialisasi bobot dan bias secara random dan parameter seperti *learning rate*, jumlah *hidden layer*, *node*, dll. Bobot dan bias awal ditunjukkan pada Tabel 4.6 dan Tabel 4.7.

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

	b	x_1	x_2	x_3	\dots	x_{11}
v_1	0.542143	-2.04079	1.513432	0.16638	\dots	0.505886
v_2	-0.49394	0.154826	0.537818	0.528012	\dots	0.187967
v_3	0.445278	0.966132	0.966132	-1.47289	\dots	-0.18464
v_4	0.385417	-1.57241	-1.57241	0.486976	\dots	0.603942
\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
v_{10}	-0.49902	1.757103	0.150405	0.638725	\dots	0.070971

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

	b	z_1	z_2	z_3	\dots	z_{10}
w_1	0.047428	0.063438	-0.4382	0.304955	\dots	0.038778

Setelah menginputkan bobot, bias, dan parameter yang akan digunakan kemudian menghitung masukan pada *hidden layer* menggunakan Persamaan 2.16. Pehitungan dilakukan sebanyak jumlah *node* pada *hidden layer*.

$$Z_{in1} = 0.54 + [(5.53 \times 10^{-2} \cdot -2.04) + (2.52 \times 10^1 \cdot 1.51) + (2.02 \times 10^5 \cdot 0.17) + \\ \cdots + (5.66 \times 10^2 \cdot 0.50)] \\ = 40223.20$$

Kemudian menghitung nilai pada *hidden layer* menggunakan Persamaan 2.17. Fungsi aktivasi yang digunakan pada penelitian ini adalah fungsi aktivasi tanh. Perhitungan dilakukan sebanyak jumlah *node* pada *hidden layer*.

$$Z_1 = \frac{e^{2 \cdot 40223.20} - 1}{e^{2 \cdot 40223.20} + 1} = 1$$

Setelah mendapatkan nilai pada *hidden layer*, menghitung masukan pada *output layer* menggunakan Persamaan 2.18.

$$y_{in1} = 0.05 + [(1 \cdot 0.06) + (1 \cdot -0.44) + (-1 \cdot 0.30) + \dots + (1 \cdot 0.04)] \\ = 1.52$$

Kemudian menghitung nilai pada *output layer* menggunakan Persamaan 2.19. Fungsi aktivasi yang digunakan pada penelitian ini adalah fungsi aktivasi sigmoid.

$$y_1 = \frac{1}{(1 + e^{-1.52})} = 0.85$$

Karena $0.85 \geq \theta$, maka $y_1 = 1$. 1 merupakan kelas KSSRM sedangkan data *input* yang digunakan adalah data dengan kelas rongga mulut normal sehingga hasil diagnosis masih belum sesuai. Kemudian menghitung selisih antara kelas aktual dan hasil diagnosis menggunakan Persamaan 2.20.

$$Error = 0 - 1 = -1$$

Setelah itu, memasuki tahap *backward*. Tahap *backward* digunakan untuk menghitung kesalahan pada setiap *layer*. Sesuai dengan namanya, pada tahap *backward* ini berjalan mundur dari *output layer* ke *input layer*. Sehingga langkah

awal pada tahap *backward* adalah menghitung kesalahan pada *output layer* menggunakan Persamaan 2.21.

$$\delta_1 = -1 \times \left[\frac{1}{(1 + e^{-0.85})} \left(1 - \frac{1}{(1 + e^{-0.85})} \right) \right] = -0.21$$

Kemudian menghitung koreksi bobot w antara *hidden layer* dan *output layer* menggunakan Persamaan 2.22.

$$\Delta w_{11} = 0.1 \times -0.21 \times 1 = 1$$

Perhitungan tersebut dilakukan sebanyak jumlah *node output layer* \times (jumlah *node hidden layer* + bias). Tabel 4.8 menunjukkan koreksi bobot w antara *hidden layer* dan *output layer*.

Tabel 4.8 Bobot dan Bias antara *Hidden Layer* dan *Output Layer*

	b	z1	z2	z3	...	z10
w1	-0.02123	0.042211	-0.45943	0.326182	...	0.017551

Kemudian menghitung kesalahan pada masukan *hidden layer* menggunakan Persamaan 2.24. Perhitungan ini dilakukan sebanyak jumlah *node hidden layer*.

$$\delta in_1 = - 0.21 \times 0.06 = -0.01$$

Menghitung kesalahan pada *hidden layer* menggunakan Persamaan 2.24. Perhitungan ini dilakukan sebanyak jumlah *node hidden layer*.

$$\delta_1 = -0.01 \times \left(1 - \frac{e^{1^2} - 1}{e^{1^2} + 1} \right) = -0.0032$$

Menghitung koreksi bobot v antara *input layer* dan *hidden layer* menggunakan Persamaan 2.25.

$$\Delta v_{11} = 0.1 \cdot -0.0032 \cdot 5.35 \times 10^{-2} = -1.78 \times 10^{-5}$$

Perhitungan ini dilakukan sebanyak (jumlah *node input layer* + bias) \times jumlah *node hidden layer*. Tabel 4.9 menunjukkan koreksi bobot v antara *hidden layer* dan *output layer*.

Tabel 4.9 Bobot dan Bias antara *Hidden Layer* dan *Output Layer*

	b	x_1	x_2	x_3	\dots	x_{11}
v_1	0.54	-2.04	1.50	-310.97	\dots	0.32
v_2	-0.49	0.15	0.59	447.62	\dots	1.44
v_3	0.44	0.97	0.93	-312.61	\dots	-1.06
v_4	0.38	-1.57	-1.69	-952.98	\dots	-2.07
\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
v_{10}	-0.499	1.76	0.15	-38.93	\dots	-0.04

Setelah mendapatkan nilai koreksi bobot v dan w , kemudian memasuki tahap *update* bobot dengan menjumlahkan bobot lama dengan koreksi bobot yang diperoleh pada tahap *backward* menggunakan Persamaan 2.28 dan Persamaan 2.29.

$$v_{baru} = -2.04 + -1.78 \times 10^{-5} = -2.04$$

$$w_{baru} = 0.06 + -0.02 = 0.04$$

Proses *training* dilanjutkan ke tahap *feed forward* dengan menggunakan bobot baru yang telah diperbarui. *Training* akan berhenti hingga bobot yang didapatkan konvergen atau tidak mengalami perubahan.

4.3.2. Proses *Testing*

Proses *testing* mengklasifikasikan data ke kelas KSSRM dan rongga mulut normal menggunakan model yang telah didapatkan pada proses *training*. Berbeda dengan *training*, langkah awal pada proses *testing* adalah menginisialisasi bobot yang telah didapatkan pada proses *training*. Bobot optimal yang didapatkan ditunjukkan pada Tabel 4.8 dan Tabel 4.9.

Tabel 4.10 Bobot dan Bias antara Hidden Layer dan Output Layer

	b	x_1	x_2	x_3	...	x_{11}
v_1	1.39	-2.04	1.51	0.17	...	0.48
v_2	-1.598	0.15	0.54	0.53	...	0.35
v_3	-1.16	0.97	-0.45	-1.47	...	-0.22
v_4	0.98	-1.57	1.16	0.49	...	-0.47
\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
v_{10}	1.39	1.76	0.15	0.64	...	0.59

Tabel 4.11 Bobot dan Bias antara Hidden Layer dan Output Layer

	b	z_1	z_2	z_3	...	z_{10}
w	0.24	-2.83	-0.40	-2.61	...	1.20

Setelah menginisialisasi bobot kemudian menghitung masukan pada *hidden layer* menggunakan Persamaan 2.30. Perhitungan dilakukan sebanyak jumlah *node*

pada *hidden layer*.

$$Z_{in1} = 1.39 + [(8.22 \times 10^{-2} \cdot -2.04) + (2.31 \times 10^1 \cdot 1.51) + (1.60 \times 10^5 \cdot 0.17) + \\ \cdots + (1.13 \times 10^4 \cdot 0.48)] \\ = -63447.80$$

Kemudian menghitung nilai pada hidden layer menggunakan Persamaan 2.31. Fungsi aktivasi yang digunakan adalah fungsi aktivasi tanh. Perhitungan dilakukan sebanyak jumlah *node* pada *hidden layer*.

$$Z_1 = \frac{e^{2 \cdot -63447.80} - 1}{e^{2 \cdot -63447.80} + 1} = -1$$

Menghitung masukan pada *output layer* menggunakan Persamaan 2.32.

$$y_{in1} = 0.24 + [(-1 \cdot -2.83) + (1 \cdot -0.40) + (-1 \cdot -2.61) + \dots + (-1 \cdot 1.20)] \\ = -3.39$$

Kemudian menghitung nilai pada *output layer* menggunakan Persamaan 2.33.

Fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid.

$$y_1 = \frac{1}{(1 + e^{-3.39})} = 0.03$$

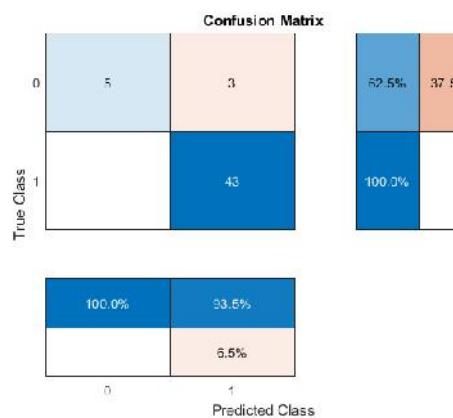
Karena $0.03 < \theta$, maka $y_1 = 0$. 0 merupakan kelas normal sedangkan data *input* yang digunakan adalah data dengan kelas rongga mulut normal sehingga hasil diagnosis sudah sesuai. Pada proses *testing* hanya terdiri dari *feed forward* saja tanpa *backward* dan *update* bobot.

4.4. Pengujian Model dan Evaluasi Sistem

Proses diagnosis KSSRM menggunakan metode *Backpropagation* dipengaruhi oleh beberapa hal, seperti pembagian data, *learning rate*, dll. Pada penelitian ini melakukan uji coba berdasarkan perbesaran lensa citra histopatologi, pembagian data, arah sudut GLRLM, jumlah *hidden layer*, jumlah *node*, dan *learning rate*. Perbesaran lensa yang diuji coba adalah $100\times$ dan $400\times$, pembagian data yang diuji coba adalah nilai k sebesar 5 dan 10 pada *k-fold cross validation*, arah sudut GLRLM yang diuji coba adalah 0° , 45° , 90° , dan 135° , jumlah *hidden layer* yang diuji coba adalah 1 *hidden layer* dan 2 *hidden layer*, jumlah *node* yang diuji coba adalah 10, 50, dan 100, dan *learning rate* yang diuji coba adalah dari 0.1 hingga 0.5. Hasil dari beberapa uji coba tersebut akan dievaluasi berdasarkan nilai akurasi, sensitivitas, dan spesifikasi yang didapatkan dari *confusion matrix*.

Dari hasil uji coba diperoleh citra dengan perbesaran lensa $100\times$ lebih unggul dibandingkan dengan perbesaran lensa $400\times$ baik menggunakan 1 *hidden layer* maupun 2 *hidden layer*. Perbesaran lensa $100\times$ menghasilkan akurasi maksimal pada 1 *hidden layer* 94.12%, sedangkan pada 2 *hidden layer* menghasilkan akurasi maksimal sebesar 94.12%. Perbesaran lensa $400\times$ menghasilkan akurasi maksimal pada 1 *hidden layer* 86.43%, sedangkan pada 2 *hidden layer* menghasilkan akurasi maksimal sebesar 88.41%. Pada uji coba 1 *hidden layer* dan 2 *hidden layer* menghasilkan akurasi yang sama tetapi pada uji coba 2 *hidden layer* memiliki rata-rata akurasi 87.5% pada 1 *hidden layer* dan 87.24% pada 2 *hidden layer*. Sehingga pada penelitian ini menggunakan data dengan perbesaran lensa $100\times$ dan 2 *hidden layer*. Akurasi terbaik diperoleh berdasarkan uji coba perbesaran lensa $100\times$, arah sudut GLRLM 135° , 2 *hidden layer* dengan *node*

pada *layer* pertama 100 dan pada *layer* kedua 50. *Confusion matrix* yang diperoleh berdasarkan uji coba tersebut terlihat pada Gambar 4.22.



Gambar 4.22 Confusion Matrix Terbaik pada Satu Hidden Layer

Berdasarkan Gambar 4.22 terlihat bahwa data rongga mulut normal yang terdiagnosis benar rongga mulut normal (TN) berjumlah 5 data, data rongga mulut normal yang terdiagnosis salah KSSRM (FP) berjumlah 3 data, sedangkan data KSSRM yang terdiagnosis benar KSSRM (TP) berjumlah 43 data, dan tidak ada data KSSRM yang terdiagnosis salah rongga mulut normal (FN). Kelas 0 pada Gambar 4.22 merupakan kelas rongga mulut normal sedangkan kelas 1 merupakan kelas KSSRM. Dari confusion matrix yang diperoleh kemudian menghitung akurasi, sensitivitas, dan spesifisitas seperti pada perhitungan di bawah ini.

$$Akurasi = \frac{5 + 43}{5 + 3 + 0 + 43} \times 100\% = 94.12\%$$

$$Sensitivitas = \frac{43}{43+0} \times 100\% = 100\%$$

$$Spesifisitas = \frac{5}{5+3} \times 100\% = 62.50$$

Dari hasil uji coba parameter nilai spesifisitas cenderung rendah. Spesifisitas menghitung jumlah data normal yang terdiagnosis benar normal. Hal tersebut terjadi dikarenakan jumlah data normal dan KSSRM yang cenderung jauh atau yang biasa disebut dengan *imbalanced data*. Data KSSRM lebih banyak dibandingkan normal. Sehingga model lebih mengenali data KSSRM dibandingkan data normal.

4.5. Aplikasi Sistem Diagnosis KSSRM

Model dengan parameter uji coba yang menghasilkan akurasi terbaik yang diperoleh pada tahap sebelumnya akan digunakan untuk aplikasi sistem diagnosis KSSRM. Aplikasi ini akan sangat membantu tenaga medis mendiagnosis KSSRM dengan mudah dan dalam waktu yang singkat. Aplikasi tersebut akan mendiagnosis citra histopatologi rongga mulut yang diinputkan masuk ke kelas normal atau KSSRM. Tampilan awal dari aplikasi sistem diagnosis KSSRM terlihat pada Gambar 4.23.



Gambar 4.23 Tampilan Awal Aplikasi Diagnosis KSSRM

Pada halaman awal terdapat tombol *Start* yang akan menuju ke halaman utama. Gambar 4.24 menunjukkan halaman utama sebelum menginputkan citra yang akan dilakukan diagnosis.



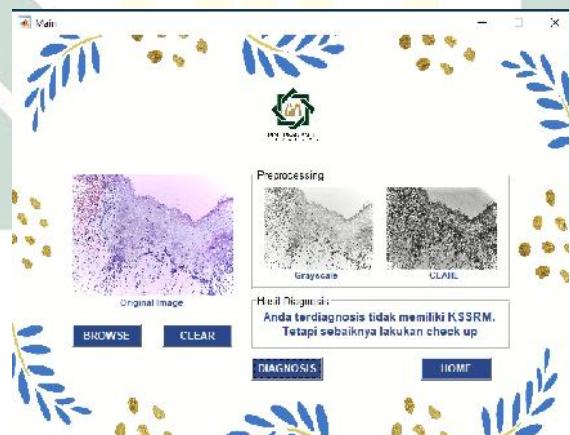
Gambar 4.24 Halaman Utama Aplikasi Diagnosis KSSRM

Pada halaman utama terdapat tombol *Browse* yang digunakan untuk mencari dan memilih citra yang akan dilakukan diagnosis. Apabila citra sudah terlihat kemudian klik tombol Diagnosis sehingga akan muncul hasil *preprocessing* citra menggunakan metode *grayscale* dan **CLAHE** dan hasil diagnosinya apakah citra tersebut termasuk citra rongga mulut normal atau KSSRM. Gambar 4.25 dan 4.26 menunjukkan halaman utama yang telah menginputkan citra histopatologi rongga mulut dan melakukan diagnosis dari citra tersebut.



Gambar 4.25 Halaman Utama Aplikasi Diagnosis KSSRM

Gambar 4.25 menunjukkan hasil diagnosis rongga mulut KSSRM. Sehingga akan terlihat pesan bahwa citra tersebut merupakan citra KSSRM dan perintah untuk segera lakukan *check up* ke rumah sakit untuk segera dilakukan pemeriksaan dan penanganan lebih lanjut.



Gambar 4.26 Halaman Utama Aplikasi Diagnosis KSSRM

Gambar 4.26 menunjukkan hasil diagnosis rongga mulut normal. Sehingga akan terlihat pesan bahwa citra tersebut tidak memiliki KSSRM dan perintah untuk tetap melakukan *check up* ke rumah sakit secara rutin. Apabila ingin menghapus citra dan hasil diagnosisnya maka klik tombol *Clear* sehingga tampilanya akan kembali

menjadi seperti Gambar 4.24. Pada halaman utama juga terdapat tombol *Home* untuk kembali pada halaman awal seperti pada Gambar 4.23.

4.6. Integrasi Keislaman

Penelitian ini bertujuan untuk membuat sistem diagnosis KSSRM. Tingkat akurasi pada sistem diagnosis memiliki peran yang sangat penting. Karena tingkat akurasi menunjukkan seberapa baik sistem diagnosis. Semakin besar akurasi yang dihasilkan maka akan semakin sistem tersebut. Untuk mendapatkan akurasi yang maksimal penelitian ini melakukan usaha dengan uji coba parameter. Hal ini terinspirasi dari Q.S al-'Ankabut ayat ke 6 yang berbunyi:

وَمَنْ جَاهَدَ فَإِنَّمَا يُجَاهِدُ لِنَفْسِهِ إِنَّ اللَّهَ لَغَنِيٌّ عَنِ الْعَالَمِينَ ﴿٦﴾

Artinya: “Siapa yang berusaha dengan sungguh-sungguh (untuk berbuat kebajikan), sesungguhnya dia sedang berusaha untuk dirinya sendiri (karena manfaatnya kembali kepada dirinya). Sesungguhnya Allah benar-benar Maha Kaya (tidak memerlukan suatu apa pun) dari alam semesta.” (Q.S al-'Ankabut/29:6). Ayat tersebut menjelaskan bahwa apabila bersungguh-sungguh dan selalu berusaha dengan melakukan uji coba parameter, maka akan mendapatkan manfaatnya dengan mendapatkan akurasi yang maksimal. Sama halnya dengan seseorang yang terdiagnosis penyakit KSSRM, maka harus selalu berusaha untuk menyembuhkan penyakit yang dideritanya. Selain dengan berusaha pasien KSSRM juga harus bertawakkal kepada Allah sebagaimana pada hadis Imam Ahmad yang berbunyi:

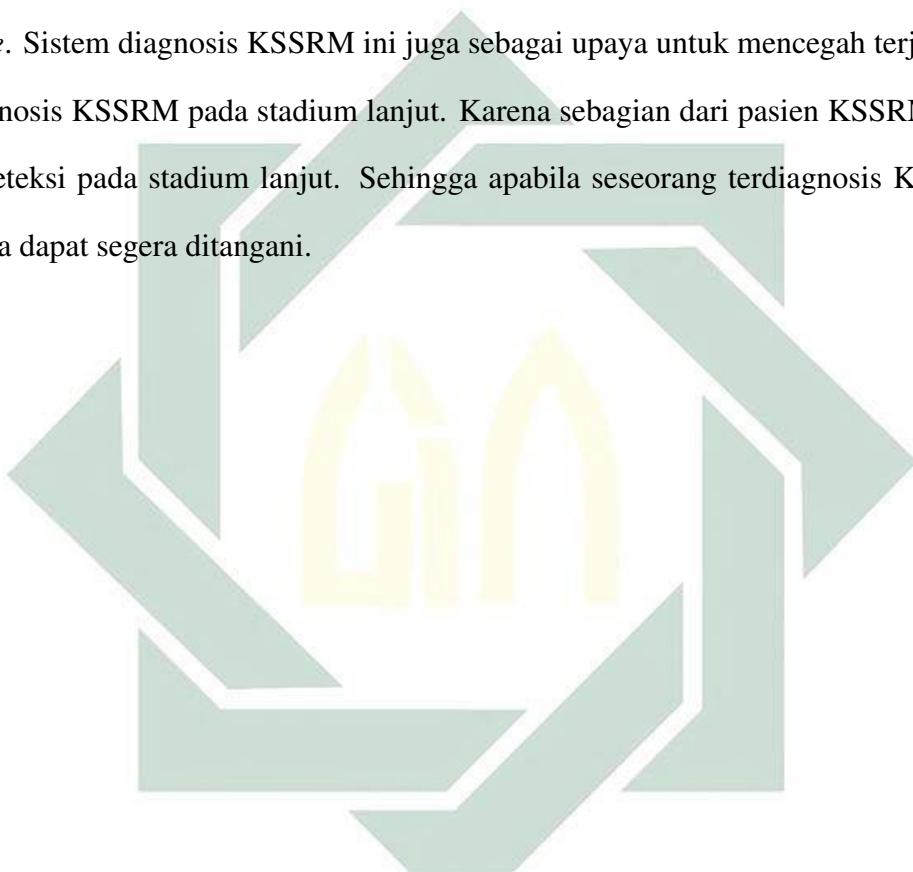
حَدَّثَنَا أَبُو عَبْدِ الرَّحْمَنِ حَدَّثَنَا حَيْوَةً أَخْبَرَنِي بَكْرُ بْنُ عَمْرٍو أَنَّهُ سَمِعَ عَبْدَ اللَّهِ بْنَ
هُبَيْرَةَ يَقُولُ إِنَّهُ سَمِعَ أَبَا تَمِيمَ الْجَيْشَانِيَّ يَقُولُ سَمِعَ عُمَرَ بْنَ الْحَطَابِ رَضِيَ اللَّهُ عَنْهُ
يَقُولُ إِنَّهُ سَمِعَ نَبِيَّ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ يَقُولُ لَوْ أَنْتُمْ تَتَوَكَّلُونَ عَلَى اللَّهِ حَقَّ
تَوْكِيلِهِ لَرَزَقَكُمْ كَمَا يَرْزُقُ الطَّيِّرَ تَقْدُو خِتَّاصًا وَتَرُوحُ بِطَانًا (رواه احمد)

Artinya: Telah menceritakan kepada kami [Abu Abdurrahman] Telah menceritakan kepada kami [Haiwah] telah mengabarkan kepadaku [Bakar Bin 'Amru] bahwa dia mendengar [Abdullah Bin Hubairah] berkata; bahwa dia mendengar [Abu Tamim al-Jaisyani] berkata; bahwa dia mendengar [Umar Bin al-Khatthab] menerangkan bahwa dia mendengar Nabiyullah saw bersabda: "Jika kalian bertawakkal kepada Allah dengan sebenar-benarnya tawakkal, niscaya Dia akan memberikan rezeki kepada kalian, sebagaimana Dia telah memberikan rezeki kepada burung yang berangkat di pagi hari dalam keadaan kosong dan kembali dalam keadaan kenyang." Berdasarkan hadis tersebut pasien KSSRM harus bertawakkal dengan bersungguh-sungguh, niscaya Allah akan memberi rezeki. Rezeki yang dimaksud dapat berupa kesehatan bagi pasien KSSRM sebagaimana pada kaidah fikih yang berbunyi:

الْأَمْرُ بِمَا يَرِيدُهَا

Artinya: "Segala sesuatu tergantung pada niatnya". Apabila seseorang berniat untuk menyembuhkan penyakit dengan selalu berusaha dengan ikhlas tanpa putus asa dan bertawakkal kepada Allah, maka Allah akan menyembuhkan penyakit yang dideritanya. Dengan adanya sistem diagnosis KSSRM seseorang

dapat mengetahui apakah pada rongga mulut terdapat KSSRM atau tidak dengan mudah dalam waktu yang singkat dan akurat. Akurasi terbaik yang diperoleh adalah 94.12%, sensitivitas 100%, dan spesifisitas 62.50% berdasarkan uji coba parameter data perbesaran $100\times$. pembagian data *kfold* 10, pada arah sudut 135° , *learning rate* 0.4, 2 *hidden layer* dengan jumlah *node* berturut-turut 100 dan 50 *node*. Sistem diagnosis KSSRM ini juga sebagai upaya untuk mencegah terjadinya diagnosis KSSRM pada stadium lanjut. Karena sebagian dari pasien KSSRM baru terdeteksi pada stadium lanjut. Sehingga apabila seseorang terdiagnosis KSSRM maka dapat segera ditangani.



BAB V

PENUTUP

Berdasarkan hasil yang diperoleh dari implementasi metode backpropagation dalam mendiagnosis KSSRM dapat disimpulkan bahwa:

5.1. Kesimpulan

1. Berdasarkan perbandingan histogram citra *grayscale* sebelum dan sesudah dilakukan CLAHE, CLAHE mampu meningkatkan kualitas citra sehingga dapat mengatasi keberagaman tingkat kecerahan pada citra yang digunakan dengan meratakan histogram pada citra. Nilai rata-rata citra setelah dilakukan CLAHE menjadi lebih kecil dibandingkan sebelum dilakukan CLAHE. Pada sampel citra normal $100 \times$ memiliki rata-rata sebelum dan sesudah secara berturut-turut sebesar 143.22 dan 126.50, pada citra KSSRM $100 \times$ memiliki rata-rata sebelum dan sesudah secara berturut-turut sebesar 218.30 dan 126.70, pada citra normal $400 \times$ memiliki rata-rata sebelum dan sesudah secara berturut-turut sebesar 145.84 dan 123.20, sedangkan pada citra KSSRM $400 \times$ memiliki rata-rata sebelum dan sesudah secara berturut-turut sebesar 189.07 dan 125.01.
 2. Berdasarkan hasil visualisasi pada setiap fitur menggunakan *boxplot*, citra normal memiliki tekstur yang lebih kasar dibandingkan dengan tekstur pada citra KSSRM berdasarkan visualisasi fitur SRE dan LRE menggunakan *boxplot*. SRE pada citra normal memiliki *range* yang lebih rendah

dibandingan SRE pada citra KSSRM. Semakin rendah nilai SRE, maka semakin kasar tekstur dari suatu citra. LRE pada citra normal memiliki *range* yang lebih tinggi dibandingan LRE pada citra KSSRM. Semakin tinggi nilai LRE, maka semakin kasar tekstur dari suatu citra.

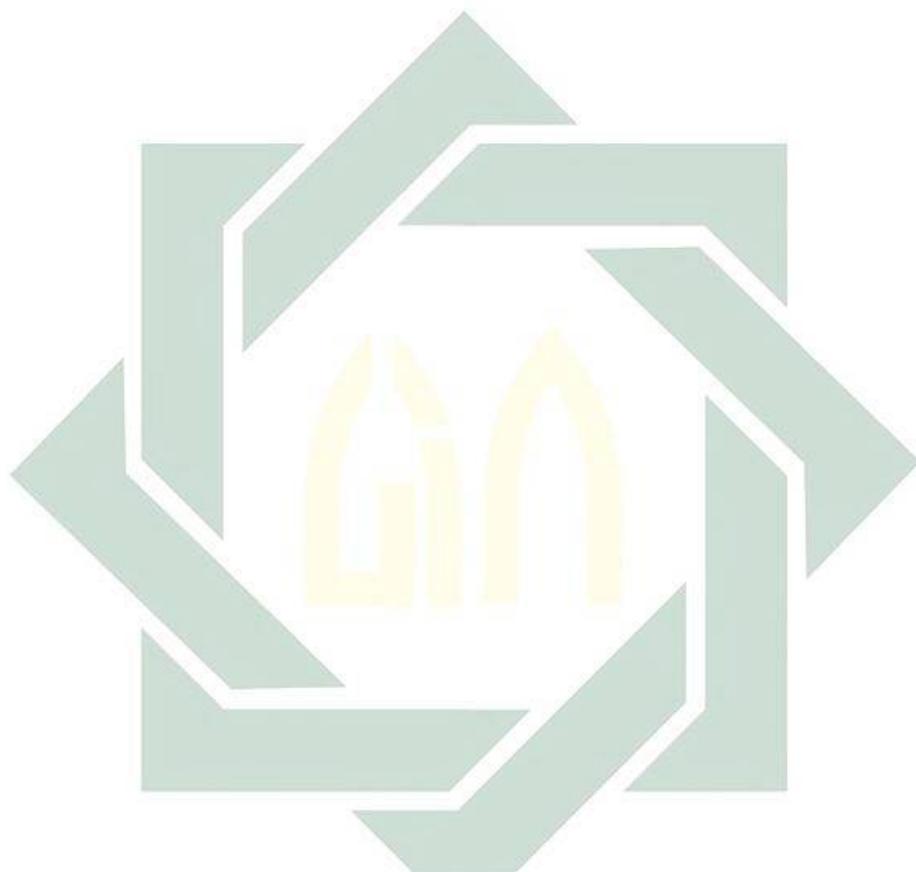
3. Dari hasil uji coba parameter yang telah dilakukan, diperoleh hasil akurasi maksimal sebesar 94.12%, sensitivitas 100%, dan spesifisitas 62.50% dengan parameter yang digunakan adalah data perbesaran $100\times$, pembagian dta *kfold* 10, pada arah sudut 135° , *learning rate* 0.4, 2 *hidden layer* dengan jumlah *node* berturut-turut 100 dan 50 *node*.

5.2. Saran

Pada penelitian ini membahas mengenai diagnosis penyakit KSSRM berdasarkan analisis tekstur citra histopatologi. Penelitian ini masih memiliki banyak kekurangan, sehingga perlu melakukan perbaikan dan inovasi agar sistem diagnosis ini menjadi lebih baik pada penelitian mendatang. Berikut saran-saran dari penulis untuk penelitian mendatang:

1. Jumlah data pada setiap kelas yang memiliki selisih yang besar dapat mengakibatkan sistem lebih mengenali data yang berjumlah lebih banyak. Sehingga perlu dilakukan teknik yang dapat mengatasi permasalahan *imbalanced data*.
2. Menggunakan metode seleksi fitur untuk memilih fitur yang paling relevan terhadap data, dengan mengurangi fitur yang digunakan pada tahap klasifikasi dapat mengurangi tingkat komputasi karena semakin banyak fitur yang digunakan maka tingkat komputasinya akan semakin berat.

3. Menggunakan metode perkembangan dari *Backpropagation* atau mengkombinasikan *Backpropagation* dengan metode lain agar dapat menghasilkan akurasi yang lebih baik.



DAFTAR PUSTAKA

- Adinugroho, S. and Sari, Y. A. (2017). Perbandingan Jaringan Learning Vector Quantization dan Backpropagation pada Klasifikasi Daun Berbasiskan Fitur Gabungan. *Jurnal Informatika & Multimedia*, p-ISSN 2252-486X e-ISSN 2548-4710, 9(02):58–64.

Anugraha, T., Handayani, P., and K, T. (2021). Hubungan Kebiasaan Merokok dengan Tingkat Pengetahuan Kanker Mulut pada Siswa SMA di Palembang.

Ariana, A. G. B. (2011). Customer segmentation dengan metode self organizing map (studi kasus: Ud. fenny). *Neuron*, 2(1):1–7.

Aro, K., Wei, F., Wong, D. T., and Tu, M. (2017). Saliva Liquid Biopsy for Point-of-Care Applications. *Frontiers in Public Health*, 5(APR).

Audiawati, A., Zakki, M., and Susana, U. (2021). Edukasi pengetahuan deteksi dini kanker rongga mulut pada masyarakat di lingkungan rptra harapan mulia kemayoran jakarta pusat. *Info Abdi Cendekia*, 2(1).

Barus, O. P. and Ronaldo, R. (2019). Perbandingan Metode Extreme Learning Machine dan Backpropagation untuk Mengklasifikasi Phising Websites. *Journal of Informatics Engineering Research and Technology*, 1(1):1–8.

Cahyanti, D., Rahmayani, A., and Husniar, S. A. (2020). Analisis Performa Metode KNN pada Dataset Pasien Pengidap Kanker Payudara. *Indonesian Journal of Data and Science*, 1(2):39–43.

- Chu, A., Sehgal, C. M., and Greenleaf, J. F. (1990). Use of Gray Value Distribution of Run Lengths for Texture Analysis. *Pattern Recognition Letters*, 11(6):415–419.

Cristaldi, M., Mauceri, R., Di Fede, O., Giuliana, G., Campisi, G., and Panzarella, V. (2019). Salivary Biomarkers for Oral Squamous Cell Carcinoma Diagnosis and Follow-Up: Current Status and Perspectives. *Frontiers in Psychology*, 10(December):1–12.

Dasarathy, B. V. and Holder, E. B. (1991). Image Characterizations Based on Joint Gray Level—Run Length Distributions. *Pattern Recognition Letters*, 12(8):497–502.

Devi, B. A. and Rajasekaran, M. P. (2019). Performance Comparison of ANN-BP, ELM for MRI Pancreas Image Classification. *2019 International Conference on Clean Energy and Energy Efficient Electronics Circuit for Sustainable Development, INCCES 2019*.

Fatimah, S. (2021). *Santri Siaga Tsunami*. Bandar Publishing.

Galloway, M. M. (1975). Texture Analysis Using Gray Level Run Lengths. *Computer graphics and image processing*, 4(2):172–179.

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. *Computers and Electronics in Agriculture*, 187(June):106267.

Gonzalez, R. C. and Woods, R. E. (2018). 4th edition digital image processing. page 1168.

- Hapsari, R. K., Utoyo, M. I., Rulaningtyas, R., and Suprajitno, H. (2020). Comparison of Histogram Based Image Enhancement Methods on Iris Images. *Journal of Physics: Conference Series*, 1569(2).

Hu, X., Zhang, Q., Hua, H., and Chen, F. (2016). Changes in the Salivary Microbiota of Oral Leukoplakia and Oral Cancer. *Oral Oncology*, 56:7–9.

Janotha, B. L. and Tamari, K. (2017). Oral Squamous Cell Carcinoma Focusing on Interprofessional Collaboration. *Nurse Practitioner*, 42(4):26–30.

MathWorks. *rgb2gray*.

MedlinePlus. Head and Neck Squamous Cell Carcinoma.

Miranda, N. D., Novamizanti, L., and Rizal, S. (2020). Convolutional neural network pada klasifikasi sidik jari menggunakan resnet-50. *Jurnal Teknik Informatika (Jutif)*, 1(2):61–68.

Mu’jizah, H. (2021a). *Klasifikasi Kanker Usus Besar Berdasarkan Citra Histopatologi Menggunakan Metode Gray Level Run Length Matrix-Extreme Learning Machine*. PhD thesis, UIN Sunan Ampel Surabaya.

Mu’jizah, H. (2021b). *Klasifikasi Kanker Usus Besar Berdasarkan Citra Histopatologi Menggunakan Metode Gray Level Run Length Matrix-Extreme Learning Machine*.

Müller, S. (2017). Update From the 4th Edition of the World Health Organization of Head and Neck Tumours: Tumours of the Oral Cavity and Mobile Tongue. *Head and Neck Pathology*, 11(1):33–40.

Mutiara, I. d. A. (2015). Penerapan K-Optimal pada Algoritma KNN untuk Prediksi Kelulusan Tepat Waktu Mahasiswa Program Studi Ilmu Komputer Fmipa Unlam

Berdasarkan Ip Sampai dengan Semester 4. *Klik - Kumpulan Jurnal Ilmu Komputer*, 2(2):159–173.

Nasution, D. A., Khotimah, H. H., and Chamidah, N. (2019). Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Computer Engineering, Science and System Journal*, 4(1):78.

Neville, B. W., Damm, D. D., Allen, C. M., and Chi, A. C. (2015). *Oral and Maxillofacial Pathology*. Elsevier Health Sciences.

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. *Advances in Science, Technology and Engineering Systems*, 4(4):115–120.

Priyatna, A. C. (2017). Kerolasian antara Tingkat Keganasan dengan Kecemasan dan Kualitas Hidup pada Pasien Karsinoma Sel Skuamosa Rongga Mulut.

Purwandari, E. P., Hasibuan, R. U., and Andreswari, D. (2018). Identifikasi Jenis Bambu Berdasarkan Tekstur Daun dengan Metode Gray Level Co-Occurrence Matrix dan Gray Level Run Length Matrix. *Jurnal Teknologi dan Sistem Komputer*, 6(4):146–151.

Qotadah, H. A. (2020). Covid-19: Tinjauan maqasid al-shariah terhadap penangguhan pelaksanaan ibadah shalat di tempat ibadah (hifdz al-nafs lebih utama dari hifdz al-din?). *SALAM: Jurnal Sosial dan Budaya Syar-i*, 7(7):659–672.

Radhika, T., Jedy, N., Nithya, S., and Muthumeenakshi, R. M. (2016). Salivary

Biomarkers in Oral Squamous Cell Carcinoma – An Insight. *Journal of Oral Biology and Craniofacial Research*, 6:S51–S54.

Rahman, T. Y. (2019). A Histopathological Image Repository of Normal Epithelium of Oral Cavity and Oral Squamous Cell Carcinoma.

Rahman, T. Y., Mahanta, L. B., Das, A. K., and Sarma, J. D. (2020). Histopathological Imaging Database for Oral Cancer Analysis. *Data in Brief*, 29:105114.

Rapado-González, O., Martínez-Reglero, C., Salgado-Barreira, A., López-López, R., Suárez-Cunqueiro, M. M., and Muinelo-Romay, L. (2019). miRNAs in Liquid Biopsy for Oral Squamous Cell Carcinoma Diagnosis: Systematic Review and Meta-Analysis. *Oral Oncology*, 99(October):104465.

Riadi, A. A., Chamid, A. A., and Sokhibi, A. (2017). Analisis Komparasi Metode Perbaikan Kontras Berbasis Histogram Equalization pada Citra Medis. *Simetris: Jurnal Teknik Mesin, Elektro dan Ilmu Komputer*, 8(1):383–388.

Rosiani, U. D., Batubulan, K. S., and Elisiana, M. (2021). Identifikasi “acne vulgaris” berdasarkan fitur warna dan tekstur menggunakan klasifikasi jst backpropagation. *Jurnal Informatika Polinema*, 7(2):7–12.

Rusdiana, Y. et al. (2019). *Hubungan Antara Interaksi Sosial dengan Perilaku Sosial Narapidana di Lembaga Pemasyarakatan (LAPAS) Kelas II B Majalengka*. PhD thesis, FISIP UNPAS.

Ruuska, S., Hämäläinen, W., Kajava, S., Mughal, M., Matilainen, P., and Mononen, J. (2018). Evaluation of the confusion matrix method in the validation of

an automated system for measuring feeding behaviour of cattle. *Behavioural processes*, 148:56–62.

Saenpaen, J., Arwatchananukul, S., and Aunsri, N. (2019). A comparison of Image Enhancement Methods for Lumbar Spine X-Ray Image. *ECTI-CON 2018 - 15th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, pages 798–801.

Sakinah, N. P., Cholissodin, I., and Widodo, A. W. (2018). Prediksi jumlah permintaan koran menggunakan metode jaringan syaraf tiruan backpropagation. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer e-ISSN*, 2548:964X.

Saputra, K., Taufik, I., Dharma, D. F., and Hidayat, M. (2021). Analisis perbaikan kualitas citra menggunakan clahe dan he pada citra x-ray covid-19 dan pneumonia. *IJCIT (Indonesian Journal on Computer and Information Technology)*, 6(2).

Sardaro, N., della Vella, F., Incalza, M. A., Stasio, D. D., Lucchese, A., Contaldo, M., Laudadio, C., and Petruzzi, M. (2019). Oxidative Stress and Ooral Mucosal Diseases: An Overview. *In Vivo*, 33(2):289–296.

Silverman, S., Eversole, L. R., and Truelove, E. L. (2001). *Essentials of Oral Medicine*, volume 223. Hamilton, London.

Solikhun, S., Safi, M., and Trisno, A. (2017). Jaringan saraf tiruan untuk memprediksi tingkat pemahaman sisiwa terhadap matapelajaran dengan menggunakan algoritma backpropagation. *J-SAKTI (Jurnal Sains Komputer dan Informatika)*, 1(1):24–36.

- Sonis, S. T., Fazio, R. C., and Fang, L. (1995). Principles and practice of oral medicine.

Suhartanto, R. S., Dewi, C., and Muflikhah, L. (2017). Implementasi jaringan syaraf tiruan backpropagation untuk mendiagnosis penyakit kulit pada anak. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer e-ISSN*, 2548:964X.

Tempola, F., Muhammad, M., and Khairan, A. (2018). Perbandingan Klasifikasi Antara KNN dan Naive Bayes pada Penentuan Status Gunung Berapi dengan K-Fold Cross Validation. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 5(5):577.

The Golbal Cancer Observatory (2020). Lip, Oral Cavity.

Tzeng, J., Lai, Y. R., Lin, M. L., Lin, Y. H., and Shih, Y. C. (2020). Improve the LSTM and GRU model for small training data by wavelet transformation. *Proceedings of the International Joint Conference on Neural Networks*, pages 2–7.

Untari, I. (2012). Kesehatan otak modal dasar hasilkan sdm handal. *Profesi (Profesional Islam): Media Publikasi Penelitian*, 8.

Wikipedia. Jaringan Saraf.

Yani, A. (2018). Pemanfaatan Teknologi dalam Bidang Kesehatan Masyarakat. *PROMOTIF: Jurnal Kesehatan Masyarakat*, 8(1):97.

Yudhistira, A. R. (2017). Analisa Customer Churn pada Perusahaan Internet Service Provider xyz Menggunakan Backpropagation Neural Network.

Zakiya, P. N. and Novamizanti, L. (2021). Klasifikasi patologi makula retina melalui citra oct menggunakan convolutional neural network dengan arsitektur mobilenet. *eProceedings of Engineering*, 8(5).