

**IDENTIFIKASI TUMOR OTAK MELALUI ANALISIS TEKSTUR CITRA
*MAGNETIC RESONANCE IMAGING (MRI) DENGAN METODE
GRAY LEVEL RUN LENGTH MATRIX (GLRLM) DAN
SUPPORT VECTOR MACHINE (SVM)***

SKRIPSI

Oleh:
MUHAMMAD BAQIBILLAH
NIM. 220604110023



**PROGRAM STUDI FISIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PENGAJUAN

**IDENTIFIKASI TUMOR OTAK MELALUI ANALISIS TEKSTUR CITRA
*MAGNETIC RESONANCE IMAGING (MRI) DENGAN METODE
GRAY LEVEL RUN LENGTH MATRIX (GLRLM) DAN
SUPPORT VECTOR MACHINE (SVM)***

SKRIPSI

**Diajukan kepada:
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi salah satu persyaratan dalam
Memperoleh gelar Sarjana Sains (S.Si)**

**Oleh:
MUHAMMAD BAQIBILLAH
NIM. 220604110023**

**PROGRAM STUDI FISIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN


IDENTIFIKASI TUMOR OTAK MELALUI ANALISIS TEKSTUR CITRA
*MAGNETIC RESONANCE IMAGING (MRI) DENGAN METODE
GRAY LEVEL RUN LENGTH MATRIX (GLRLM) DAN
SUPPORT VECTOR MACHINE (SVM)*

SKRIPSI

Oleh:
MUHAMMAD BAQIBILLAH
NIM. 220604110023

Telah diperiksa dan disetujui untuk diuji
Pada tanggal, 18 Desember 2025

Pembimbing I



Prof. Dr. Drs. H. Mokhamad Tirono, M.Si
NIP. 19641211 199111 1 001

Pembimbing II



Drs. H. Abdul Basid, M.Si
NIP. 19650504 199003 1 003



Mengetahui,
Ketua Program Studi

Farid Samsu Hananto, S.Si., M.T
NIP. 19740513 200312 1 001

HALAMAN PENGESAHAN


IDENTIFIKASI TUMOR OTAK MELALUI ANALISIS TEKSTUR CITRA
*MAGNETIC RESONANCE IMAGING (MRI) DENGAN METODE
GRAY LEVEL RUN LENGTH MATRIX (GLRLM) DAN
SUPPORT VECTOR MACHINE (SVM)*

SKRIPSI

Oleh:

MUHAMMAD BAQIBILLAH
NIM. 220604110023

Telah Dipertahankan Di Depan Dewan Penguji
Dan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Sains (S.Si)
Pada Tanggal, 22 Desember 2025

Penguji Utama :	<u>Dr. H. Agus Mulyono, M.Kes</u> NIP. 19750808 199903 1 003	
Ketua Penguji :	<u>Muthmainnah, M.Si</u> NIP. 19860325 201903 2 009	
Sekretaris Penguji :	<u>Prof. Dr. Drs. H. Mokhamad Tirono, M.Si</u> NIP. 19641211 199111 1 001	
Anggota Penguji :	<u>Drs. H. Abdul Basid, M.Si</u> NIP. 19650504 199003 1 003	



Mengesahkan,
Ketua Program Studi

Harid Samsu Hananto, S.Si., M.T
NIP. 19740513 200312 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : MUHAMMAD BAQIBILLAH

NIM : 220604110023

Program Studi : FISIKA

Fakultas : SAINS DAN TEKNOLOGI

Judul Penelitian : Identifikasi Tumor Otak Melalui Analisis Tekstur Citra
*Magnetic Resonance Imaging (MRI) Dengan Metode Gray
Level Run Length Matrix (GLRLM) Dan Support Vector
Machine (SVM)*

Menyatakan dengan sebenar-benarnya bahwa hasil penelitian saya ini tidak terdapat unsur penjiplakan karya penelitian atau karya ilmiah yang telah dilakukan atau dibuat oleh orang lain, kecuali yang dikutip dalam naskah ini dan disebutkan dalam sumber kutipan dan daftar pustaka. Apabila ternyata hasil penelitian ini terbukti terdapat unsur-unsur jiplakan maka saya bersedia untuk menerima sanksi yang telah ditetapkan.

Malang, 22 Desember 2025
Yang Membuat Pernyataan,

A handwritten signature in black ink is written over a rectangular postage stamp. The stamp is yellow and red, featuring the Garuda Pancasila emblem and the text '10000', 'METAL TEMPEL', and 'B212AKX394797216'.

Muhammad Baqibillah
NIM. 220604110023

MOTTO

“Kesuksesan lahir dari proses, bukan dari keluhan”

“Perbanyak proses, bukan protes”

-bqblh_bj

HALAMAN PERSEMBAHAN

Alhamdulillah Rabbil 'alamiin.

Di atas segalanya, sujud syukur saya haturkan kepada Allah SWT. Bukan hanya karena skripsi ini telah usai, melainkan karena Engkau tetap memeluk saya di malam-malam panjang ketika saya merasa bodoh, lelah, dan ingin berhenti. Terima kasih telah menggenggam hati ini agar tidak menyerah pada keputusan. Shalawat serta salam semoga tercurah kepada Rasulullah SAW, teladan kesabaran yang sesungguhnya.

Karya sederhana ini adalah saksi perjuangan yang saya persembahkan untuk:

1. Abah dan Ummi, Pintu Surga Saya. Yang tak pernah putus mengetuk pintu langit di sepertiga malam untuk nama saya. Maaf jika anakmu ini sering terlihat sibuk dan lelah. Ketahuilah, setiap lembar yang saya tulis adalah upaya saya untuk membalas setetes keringat dan air mata kalian, meski saya tahu itu tak akan pernah cukup.
2. Diri Saya Sendiri di Masa Lalu, Terima kasih sudah cukup keras kepala untuk bertahan. Terima kasih sudah memilih untuk menyeka air mata, mengambil air wudhu, dan kembali mengetik meski hanya satu paragraf. Kita berhasil.
3. Para Sahabat dan Guru Kehidupan, Yang Allah kirimkan sebagai "jeda" yang menyenangkan di tengah rumitnya bab demi bab. Kalian adalah bukti bahwa rezeki Tuhan juga berupa orang-orang baik.

Semoga lelah ini menjadi lillah.

KATA PENGANTAR

Puji syukur penulis panjatkan ke hadirat Allah SWT yang senantiasa memberikan rahmat, taufiq dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Identifikasi Tumor Otak Melalui Analisis Tekstur Citra *Magnetic Resonance Imaging* (MRI) Dengan Metode *Gray Level Run Length Matrix* (GLRLM) Dan *Support Vector Machine* (SVM)”. Sholawat serta salam senantiasa tercurahkan kepada Nabi Muhammad SAW yang telah menuntun manusia menuju zaman *zakiyyah*, yakni *Addinul Islam Wal Iman*.


Penulis menyadari bahwa banyak pihak yang telah berpartisipasi dan membantu dalam menyelesaikan penulisan skripsi ini. Oleh karena itu, penulis mengucapkan terima kasih kepada semua pihak yang telah membantu dalam menyelesaikan skripsi. Ucapan terima kasih penulis sampaikan kepada:

1. Allah *Subhanahu wa Ta’ala*, yang telah memberikan kesempatan, kemampuan, dan kekuatan dalam menyelesaikan tugas akhir ini.
2. Abah H. Achmad Sarkowi dan Ummi Hj. Linda Setiawati selaku kedua orang tua yang selalu memberikan dukungan moral, materi dan do’a yang tak pernah berhenti.
3. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., CAHRM., CRMP. selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Dr. H. Agus Mulyono, S.Pd., M.Kes. selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
5. Farid Samsu Hananto, S.Si., M.T. selaku Ketua Program Studi Fisika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
6. Prof. Dr. Drs. H. Mokhammad Tirono, M.Si. selaku Pembimbing skripsi yang

telah memberikan bimbingan dalam penyusunan skripsi dan senantiasa memberikan ilmu pengetahuan, motivasi serta meluangkan waktu untuk membimbing penulis selama proses penyusunan skripsi dengan baik.

7. Drs. H. Abdul Basid, M.Si. selaku Dosen pembimbing integrasi, yang bersedia meluangkan waktu untuk memberikan bimbingan dalam bidang integrasi sains dan Al-Quran.
8. Irjan, M.Si. selaku Dosen wali yang senantiasa memberikan pengarahan, motivasi dan ilmu pengetahuan.
9. Sebagai bagian akhir dari ungkapan terima kasih ini, penulis juga ingin memberikan apresiasi kepada Muhammad Baqibillah karena telah berusaha dan bersabar untuk tidak menyerah. Penulis paham akan semua kendala dan kesulitan yang telah berhasil dilalui, serta merasa sangat bangga dan akan terus mendukung segala keputusan yang ingin diambil.

Malang, 22 Desember 2025
Penulis,

A handwritten signature in black ink, featuring a large, stylized initial 'B' with a horizontal line extending to the right, and a small star-like mark above it.

Muhammad Baqibillah
NIM. 220604110023

DAFTAR ISI

COVER.....	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR GAMBAR.....	xii
DAFTAR TABEL	xiii
DAFTAR LAMPIRAN	xiv
ABSTRAK	xv
ABSTRACT	xvi
المخلص.....	xvii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Tujuan.....	6
1.4 Manfaat Penelitian	6
1.5 Batasan Penelitian	7
BAB II TINJAUAN PUSTAKA.....	9
2.1 Tumor Otak	9
2.1.1 Jenis-jenis Tumor Otak.....	10
2.1.2 Pemeriksaan dan Diagnosis	12
2.1.3 Identifikasi Ketidaknormalan Tubuh dalam Perspektif Al-Qur'an	16
2.2 <i>Magnetic Resonance Imaging</i> (MRI).....	17
2.3 Pengolahan Citra Digital	18
2.3.1 Citra RGB.....	19
2.3.2 Citra <i>Grayscale</i>	20
2.3.3 <i>Pre-processing</i>	21
2.4 <i>Gray Level Run Length Matrix</i> (GLRLM).....	22
2.4.1 Fitur-Fitur GLRLM.....	24
2.5 <i>Support Vector Machine</i> (SVM).....	26
2.6 <i>Confusion Matrix</i>	28
2.6.1 Parameter Metrik Evaluasi	29
BAB III METODE PENELITIAN	31
3.1 Jenis Penelitian.....	31
3.2 Sumber Data Penelitian.....	31
3.3 Rancangan Penelitian.....	31

3.4	Prosedur Penelitian	32
3.4.1	Pengambilan dan Pengelompokan data	32
3.4.2	<i>Pre-processing</i> Data	32
3.4.3	Ekstraksi GLRLM	33
3.4.4	Pengklasifikasian SVM	34
3.4.5	Perhitungan Validitas Data	34
3.5	Desain Tampilan GUI	35
BAB IV ANALISIS DAN PEMBAHASAN		36
4.1	Data Hasil Penelitian	36
4.1.1	<i>Pre-processing</i> Citra	36
4.1.2	Ekstraksi Fitur Tekstur	39
4.1.3	Analisis Klasifikasi SVM	43
4.1.4	Karakteristik Tekstur Citra	47
4.2	Pembahasan	50
4.3	Kajian Keislaman	55
BAB V PENUTUP		58
5.1	Kesimpulan	58
5.2	Saran	58
DAFTAR PUSTAKA		59
LAMPIRAN		64

DAFTAR GAMBAR

Gambar 2. 1 MRI (MICHEAU & HOA, 2025)	18
Gambar 2. 2 MRI otak dengan nodul tumor (Sarker, 2024)	18
Gambar 2. 3 Pengolahan citra digital.....	19
Gambar 2. 4 Representasi kanal warna RGB (Munir, 2022)	20
Gambar 2. 5 Citra RGB pada masing-masing kanal (Munir, 2022)	20
Gambar 2. 6 <i>Grayscale Level</i> (Mukherjee <i>et al.</i> , 2024).....	21
Gambar 2. 7 Direksi arah run (A.Harshavardhan <i>et al.</i> , 2017)	23
Gambar 2. 8 Matrik ukuran 4×4 dengan empat skala keabuan (0 sampai 3) (A.Harshavardhan <i>et al.</i> , 2017).....	24
Gambar 2. 9 Hasil GLRLM pada masing-masing orientasi sudut (A.Harshavardhan <i>et al.</i> , 2017).....	24
Gambar 2. 10 <i>Support Vector</i> (Saminu <i>et al.</i> , 2021).....	27
Gambar 2. 11 Model SVM (Singh, 2023).....	27
Gambar 2. 12 <i>Confusion Matrix</i> (Hicks <i>et al.</i> , 2022).....	29
Gambar 3. 1 Diagram Alir Penelitian	31
Gambar 3. 2 Tampilan Antarmuka GUI Sistem Klasifikasi Tumor Otak	35
Gambar 4. 1 Citra <i>Magnetic Resonance Imaging</i> (MRI).....	37
Gambar 4. 2 Area pemotongan citra	37
Gambar 4. 3 Hasil pemotongan citra dengan ukuran 36 x 36 px.....	38
Gambar 4. 4 <i>Matriks Run length</i>	40

DAFTAR TABEL

Tabel 3. 1 Data Fitur GLRLM	33
Tabel 3. 2 Data Input SVM	33
Tabel 4. 1 <i>Range</i> Nilai Fitur GLRLM pada Data <i>Training</i>	41
Tabel 4. 2 <i>Range</i> Nilai Fitur GLRLM pada Data <i>Testing</i>	42
Tabel 4. 3 <i>Confusion Matrix</i>	44
Tabel 4. 4 <i>Range</i> Nilai Fitur.....	47
Tabel 4. 5 Karakteristik Tekstur pada masing-masing Kelas	48

DAFTAR LAMPIRAN

Lampiran 1 Data Hasil Ekstraksi Fitur GLRLM dan Klasifikasi SVM.....	65
Lampiran 2 Data Karakteristik Tekstur Masing-Masing Citra	72
Lampiran 3 Tampilan Komputasi	80

ABSTRAK

Baqibillah, Muhammad. 2025. **Identifikasi Tumor Otak Melalui Analisis Tekstur Citra *Magnetic Resonance Imaging* (MRI) Dengan Metode *Gray Level Run Length Matrix* (GLRLM) Dan *Support Vector Machine* (SVM).** Skripsi. Program Studi Fisika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
Pembimbing: (I) Prof. Dr. Drs. H. Mokhammad Tirono, M.Si (II) Drs. Abdul Basid, M.Si

Kata Kunci: Tumor Otak, MRI, GLRLM, SVM, Tekstur Citra, Klasifikasi Multiclass

Tumor otak merupakan pertumbuhan sel abnormal yang memerlukan deteksi dini dan akurat untuk meningkatkan peluang kesembuhan. *Magnetic Resonance Imaging* (MRI) adalah modalitas utama dalam diagnosis, namun interpretasi manual memiliki keterbatasan berupa subjektivitas, variabilitas antar pengamat, dan risiko kesalahan pada lesi kecil sehingga pendekatan berbasis kecerdasan buatan diperlukan untuk mengatasi masalah tersebut melalui analisis citra yang objektif. Penelitian ini bertujuan untuk menganalisis tingkat validitas data (akurasi, presisi, sensitivitas, spesifisitas, dan F1-Score) dari metode GLRLM-SVM dalam mendeteksi empat kelas citra otak (Normal, Glioma, Meningioma, dan Pituitary), serta mengidentifikasi karakteristik tekstur dominan dari masing-masing kelas tersebut. Penelitian ini menggunakan data sekunder berupa 260 citra MRI (200 data latih dan 60 data uji) dengan tahapan meliputi *pre-processing* berupa *cropping* pada *Region of Interest* (ROI) berukuran 36x36 piksel dan *grayscale*ing, ekstraksi fitur tekstur menggunakan metode Gray Level Run Length Matrix (GLRLM) pada empat orientasi sudut (0°, 45°, 90°, 135°) dengan tujuh parameter fitur, dan klasifikasi menggunakan algoritma Support Vector Machine (SVM). Hasil pengujian menunjukkan performa sistem yang sangat optimal, di mana metode GLRLM-SVM berhasil mencapai nilai Akurasi, Presisi, Sensitivitas (Recall), Spesifisitas, dan F1-Score sebesar 100% tanpa ditemukan kesalahan klasifikasi (*misclassification*) pada seluruh data uji, yang membuktikan bahwa model yang dikembangkan sangat *robust* dalam membedakan keempat kelas citra. Selain itu, analisis karakteristik tekstur menunjukkan perbedaan pola yang signifikan antar kelas, di mana citra Normal cenderung memiliki permukaan halus dengan pola gray level homogen, citra Glioma didominasi permukaan kasar dengan intensitas tinggi (hiperintens), citra Meningioma memiliki karakteristik mirip normal namun lebih kasar pada Short Run, dan citra Pituitary memiliki karakteristik paling kontras yaitu permukaan yang sangat halus dengan Run Percentage (RP) yang sangat tinggi dan pola gray level yang sangat homogen.

ABSTRACT

Baqibillah, Muhammad. 2025. **Identification of Brain Tumors Through Texture Analysis of Magnetic Resonance Imaging (MRI) Using Gray Level Run Length Matrix (GLRLM) and Support Vector Machine (SVM) Methods.** Undergraduate Thesis. Physics Study Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
Advisors: (I) Prof. Dr. Drs. H. Mokhammad Tirono, M.Si (II) Drs. Abdul Basid, M.Si

Keywords: Brain Tumor, MRI, GLRLM, SVM, Image Texture, Multiclass Classification.

Brain tumors are abnormal cell growths that require early and accurate detection to improve survival rates. Magnetic Resonance Imaging (MRI) serves as the primary modality for diagnosis; however, manual interpretation is limited by subjectivity, inter-observer variability, and the risk of error in identifying small lesions. Consequently, an artificial intelligence-based approach is necessary to address these issues through objective image analysis. This study aims to analyze the data validity levels (accuracy, precision, sensitivity, specificity, and F1-Score) of the GLRLM-SVM method in detecting four classes of brain images (Normal, Glioma, Meningioma, and Pituitary), as well as to identify the dominant texture characteristics of each respective class. This research utilizes secondary data consisting of 260 MRI images (200 training data and 60 testing data). The methodology includes pre-processing stages such as cropping the Region of Interest (ROI) to 36x36 pixels and grayscaling; texture feature extraction using the Gray Level Run Length Matrix (GLRLM) method across four angular orientations (0° , 45° , 90° , 135°) with seven feature parameters; and classification using the Support Vector Machine (SVM) algorithm. The test results demonstrate highly optimal system performance, wherein the GLRLM-SVM method achieved 100% scores for Accuracy, Precision, Sensitivity (Recall), Specificity, and F1-Score. No misclassification was found across the entire testing dataset, proving that the developed model is highly robust in distinguishing between the four image classes. Furthermore, the analysis of texture characteristics reveals significant pattern differences between classes: Normal images tend to exhibit smooth surfaces with homogeneous gray level patterns; Glioma images are dominated by rough surfaces with high intensity (hyperintense); Meningioma images possess characteristics similar to Normal images but are coarser in the Short Run; and Pituitary images display the most contrasting characteristics, featuring very smooth surfaces with a very high Run Percentage (RP) and highly homogeneous gray level patterns.

المخلص

بِأَمْرِ اللَّهِ، مُحَمَّدٌ. ٢٠٢٥. تَحْدِيدُ أَوْرَامِ الدِّمَاغِ مِنْ خِلَالِ تَحْلِيلِ نَسِيجِ صُورِ الرِّينِ الْمَغْنَطِيسِيِّ (MRI) بِاسْتِخْدَامِ طَرِيقَةِ مَصْفُوفَةِ طُولِ التَّشْغِيلِ لِلْمُسْتَوَى الرَّمَادِيِّ (GLRLM) وَآلَةِ الْمُتَجَهَّاتِ الدَّاعِمَةِ (SVM). بَحْثٌ جَامِعِيٌّ. قِسْمُ الْفِيزِيَاءِ، كَلِيَّةُ الْعُلُومِ وَالتَّكْنُولُوجِيَا، جَامِعَةُ مَوْلَانَا مَالِكِ إِبْرَاهِيمِ الْإِسْلَامِيَّةِ الْحُكُومِيَّةِ بِمَالَانَج. الْمُسَرَّفُونَ: (١) الْأُسْتَاذُ الدُّكْتُورُ الْحَاجُّ مُحَمَّدٌ تَيْرُونُو الْمَاجِسْتِيرِ، (٢) الدُّكْتُورُ عَبْدُ الْبَاسِطِ الْمَاجِسْتِيرِ.

الكلمات المفتاحية: وَرَمُ الدِّمَاغِ، الرِّينُ الْمَغْنَطِيسِيُّ (MRI)، GLRLM، SVM، نَسِيجُ الصُّورَةِ، التَّصْنِيفُ مُتَعَدِّدُ الْفَنَاتِ.

وَرَمُ الدِّمَاغِ هُوَ نُمُوٌّ غَيْرٌ طَبِيعِيٍّ لِلْخَلَايَا يَتَطَلَّبُ كَشْفًا مُبَكِّرًا وَدَقِيقًا لِرِيزَادَةِ فُرْصِ الشِّفَاءِ. يُعَدُّ التَّصَوُّيرُ بِالرِّينِ الْمَغْنَطِيسِيِّ (MRI) الْوَسِيلَةَ الْأَسَاسِيَّةَ لِلتَّشْخِصِ، إِلَّا أَنَّ التَّفْسِيرَ الْيَدَوِيَّ لَهُ فُيُودٌ تَتِمَّتْ فِي الدَّائِيَّةِ، وَالتَّبَايُنِ بَيْنَ الْمُزَاقِبِينَ، وَخَطَرُ الْخَطَا فِي تَحْدِيدِ الْأَفَاتِ الصَّغِيرَةِ، مِمَّا يَسْتَدْعِي نَهْجًا قَائِمًا عَلَى الذِّكَاةِ الْإِصْطِنَاعِيَّةِ لِمُعَالَجَةِ هَذِهِ الْمَشْكَلَاتِ مِنْ خِلَالِ تَحْلِيلِ الصُّورِ بِمَوْضُوعِيَّةٍ. يَهْدَفُ هَذَا الْبَحْثُ إِلَى تَحْلِيلِ مُسْتَوَى صِحَّةِ الْبَيِّنَاتِ (الدِّقَّةُ، وَالْإِتْقَانُ، وَالْحَسَاسِيَّةُ، وَالنُّوعِيَّةُ، وَمِقْيَاسُ F1-Score) لِطَرِيقَةِ GLRLM-SVM فِي الْكَشْفِ عَنْ أَرْبَعِ فَنَاتٍ مِنْ صُورِ الدِّمَاغِ (الطَّبِيعِيَّةِ، وَالْوَرَمِ الدِّبْقِيِّ/Glioma، وَالْوَرَمِ السَّحَائِي/Meningioma، وَوَرَمِ الْغُدَّةِ النَّخَامِيَّةِ/Pituitary)، بِالإِضَافَةِ إِلَى تَحْدِيدِ خَصَائِصِ النَسِيجِ السَّائِدَةِ لِكُلِّ فَنَةٍ. يَسْتُخْدَمُ هَذَا الْبَحْثُ بَيِّنَاتٍ ثَانَوِيَّةً تَتَكَوَّنُ مِنْ ٢٦٠ صُورَةٍ رَيْنِ مَغْنَطِيسِيٍّ (٢٠٠ بَيِّنَاتٍ تَدْرِبُ وَ ٦٠ بَيِّنَاتٍ اخْتِبَارِيَّةً) مَعَ مَرَاكِزٍ تَشْمَلُ الْمُعَالَجَةَ الْأَوَّلِيَّةَ الْمُتَمَثِّلَةَ فِي قِصَصِ مَنْطِقَةِ الْاهْتِمَامِ (ROI) بِحَجْمِ ٣٦×٣٦ بِكْسَلٍ وَالتَّحْوِيلِ إِلَى التَّدْرُجِ الرَّمَادِيِّ (Grayscale)، وَاسْتِخْرَاجِ خَصَائِصِ النَسِيجِ بِاسْتِخْدَامِ طَرِيقَةِ GLRLM فِي أَرْبَعِ زَوَايَا تَوْجِيهِ (٠، ٩٠، ١٣٥، ١٨٠) مَعَ سَبْعِ مَعْلَمَاتٍ لِلْخَصَائِصِ، وَالتَّصْنِيفِ بِاسْتِخْدَامِ خَوَازِمِيَّةِ آلَةِ الْمُتَجَهَّاتِ الدَّاعِمَةِ (SVM). أَظْهَرَتْ نَتَائِجُ الْإِخْتِبَارِ أَدَاءً مِثَالِيًّا جَدًّا لِلنِّظَامِ، حَيْثُ نَجَحَتْ طَرِيقَةُ GLRLM-SVM فِي تَحْقِيقِ قِيَمِ الدِّقَّةِ وَالْإِتْقَانِ وَالْحَسَاسِيَّةِ (الِاسْتِدْعَاءِ) وَالنُّوعِيَّةِ وَمِقْيَاسِ F1-Score بِنِسْبَةِ ١٠٠٪ دُونَ وُجُودِ أَيِّ خَطَا فِي التَّصْنِيفِ (misclassification) فِي جَمِيعِ بَيِّنَاتِ الْإِخْتِبَارِ، مِمَّا يُثَبِّتُ أَنَّ النَّمُودَجَ الْمُطَوَّرَ قَوِيٌّ جَدًّا (robust) فِي التَّمْيِيزِ بَيْنَ فَنَاتِ الصُّورِ الْأَرْبَعِ. عِلَاوَةً عَلَى ذَلِكَ، أَظْهَرَ تَحْلِيلُ خَصَائِصِ النَسِيجِ اخْتِلَافَاتٍ جَوْهَرِيَّةً فِي الْأَنْمَاطِ بَيْنَ الْفَنَاتِ، حَيْثُ تَمِيلُ الصُّورُ الطَّبِيعِيَّةُ إِلَى أَنْ تَكُونَ ذَاتَ سَطْحٍ نَاعِمٍ مَعَ نَمَطٍ مُتَجَانِسٍ لِلْمُسْتَوَى الرَّمَادِيِّ، بَيْنَمَا يُسَيِّطُ عَلَى صُورِ الْوَرَمِ الدِّبْقِيِّ سَطْحٌ خَشِنٌ ذُو كِنَافَةٍ عَالِيَةٍ (فَرْطُ الْكِنَافَةِ)، وَتَمْتَلِكُ صُورُ الْوَرَمِ السَّحَائِيِّ خَصَائِصَ تُشَبِّهُ الطَّبِيعِيَّةَ وَلَكِنَّهَا أَكْثَرُ خُسُونَةً فِي التَّشْغِيلِ الْقَصِيرِ (Short Run)، وَتَتَمَيَّزُ صُورُ وَرَمِ الْغُدَّةِ النَّخَامِيَّةِ بِخَصَائِصٍ أَكْثَرَ تَبَايُنًا وَهِيَ سَطْحٌ نَاعِمٌ جَدًّا مَعَ نِسْبَةِ تَشْغِيلٍ (Run Percentage) عَالِيَةٍ جَدًّا وَنَمَطٍ مُسْتَوَى رَمَادِيٍّ مُتَجَانِسٍ لِلْعَالِيَةِ.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Tumor merupakan penyakit yang ditandai dengan pertumbuhan sel yang tidak terkendali dan dapat menyebar ke bagian tubuh lainnya. Ketika pertumbuhan sel abnormal ini terjadi di dalam jaringan otak, kondisi ini disebut sebagai tumor otak. Tumor otak adalah massa atau kumpulan sel-sel abnormal yang terbentuk di dalam otak atau struktur di sekitar otak, yang dapat bersifat jinak (non-kanker) maupun ganas (kanker). Pertumbuhan sel yang tidak normal ini dapat mengganggu fungsi normal otak, menekan struktur otak yang vital, dan berpotensi mengancam jiwa jika tidak terdeteksi dan ditangani secara dini (Ostrom *et al.*, 2022).

Berdasarkan data *Global Cancer Observatory* (GLOBOCAN) tahun 2020, tumor otak dan sistem saraf pusat menempati posisi signifikan dalam statistik kanker global. Dilaporkan terdapat lebih dari 308.102 kasus baru tumor otak di seluruh dunia setiap tahunnya, dengan angka kematian mencapai sekitar 251.329 kasus (Sung *et al.*, 2021). Di Indonesia, angka kejadian tumor otak menunjukkan tren peningkatan dari tahun ke tahun, dengan perkiraan lebih dari 6.000 kasus baru yang terdiagnosis setiap tahunnya (Prihantono *et al.*, 2023). Tingkat mortalitas yang tinggi pada tumor otak, yang mencapai lebih dari 80% dari total kasus, menunjukkan urgensi dalam deteksi dini dan penanganan yang tepat. Data ini menegaskan bahwa tumor otak merupakan tantangan kesehatan global yang memerlukan perhatian serius dalam aspek diagnosis dan terapinya.

Tumor otak dapat diklasifikasikan ke dalam berbagai jenis berdasarkan asal sel dan lokasi pertumbuhannya. Dua jenis yang paling umum ditemukan adalah

glioma, yang berasal dari sel *glial* penyokong di otak dan merupakan jenis tumor otak primer yang paling sering terjadi, dan *meningioma*, yang berkembang dari selaput yang melapisi otak dan sumsum tulang belakang (*meninges*). Selain itu, terdapat pula tumor *pituitary* yang tumbuh di kelenjar *pituitary* yang terletak di dasar otak (Molitch, 2017). Masing-masing jenis tumor ini memiliki karakteristik morfologi, tingkat keganasan, pola pertumbuhan, dan pendekatan pengobatan yang berbeda. *Glioma* umumnya bersifat invasif dan cenderung memiliki prognosis yang lebih buruk, sementara *meningioma* sebagian besar bersifat jinak namun dapat menyebabkan komplikasi serius akibat efek massa. Identifikasi jenis tumor secara akurat menjadi langkah fundamental dalam perencanaan terapi yang tepat dan prediksi *outcome* pasien (Weller *et al.*, 2021).

Deteksi dan diagnosis tumor otak saat ini sangat bergantung pada pencitraan medis seperti *Magnetic Resonance Imaging* (MRI), *Computed Tomography* (CT-Scan), dan dalam beberapa kasus menggunakan X-ray. MRI menjadi modalitas pencitraan pilihan utama karena mampu memberikan kontras jaringan lunak yang superior dan detail anatomis yang lebih baik dibandingkan modalitas lainnya (Martucci *et al.*, 2023). Namun, interpretasi citra medis ini masih sangat bergantung pada keahlian dan pengalaman radiolog atau dokter spesialis. Proses analisis citra yang dilakukan secara manual memiliki sejumlah keterbatasan, seperti potensi subjektivitas dalam penilaian, perbedaan hasil antar pembaca (*inter-observer variability*), kelelahan visual akibat beban kerja yang tinggi, serta kesulitan dalam mendeteksi lesi (daerah jaringan yang mengalami kelainan atau kerusakan, misalnya akibat tumor) berukuran kecil atau dengan kontras rendah. Faktor-faktor tersebut dapat menurunkan tingkat akurasi dan konsistensi diagnosis, yang pada

akhirnya memengaruhi kualitas pelayanan dan penanganan pasien (Bruno *et al.*, 2015).

Islam merupakan agama yang syamil, kamil, dan mutakamil (universal, sempurna, dan menyempurnakan). Ajarannya tidak hanya mencakup ibadah yang bersifat vertikal kepada Allah SWT, tetapi juga aspek horizontal yang berkaitan dengan seluruh dimensi kehidupan, termasuk dorongan untuk mempelajari ilmu pengetahuan dan teknologi. Al-Qur'an menegaskan pentingnya penggunaan akal dalam memahami tanda-tanda kebesaran Allah yang terbentang di alam semesta.

Hal ini sebagaimana firman Allah dalam Q.S. Fussilat (41): 53:

سَنُرِيهِمْ ءَايَاتِنَا فِي الْأَفَاقِ وَفِي أَنْفُسِهِمْ حَتَّىٰ يَتَبَيَّنَ لَهُمْ أَنَّهُ الْحَقُّ ۚ

Artinya: "Kami akan memperlihatkan kepada mereka tanda-tanda (kebesaran) Kami di segenap penjuru dan pada diri mereka sendiri, sehingga jelaslah bagi mereka bahwa Al-Qur'an itu adalah benar..." (Q.S. Fussilat [41]: 53).

Ayat ini menegaskan bahwa manusia diperintahkan untuk meneliti dan menganalisis tanda-tanda kebesaran-Nya, baik yang ada di alam semesta (*fi al-afaq*) maupun yang terdapat dalam diri manusia (*fi anfusihim*). Penelitian dalam bidang medis, misalnya mengidentifikasi kanker melalui analisis citra, dapat dipandang sebagai wujud nyata dari perintah tersebut. Dengan dukungan teknologi kecerdasan buatan, peneliti berupaya membaca pola-pola kompleks ciptaan Allah dalam tubuh manusia untuk membedakan kondisi sehat dan sakit, sekaligus menegaskan kebesaran dan kekuasaan-Nya.

Pemanfaatan Kecerdasan Buatan (AI), khususnya Deep Learning (DL) dan Machine Learning (ML), menjadi solusi menjanjikan untuk mengatasi keterbatasan metode konvensional dalam diagnosis tumor otak (Saba, 2020). AI mampu menganalisis citra medis secara objektif, konsisten, dan cepat dengan akurasi tinggi,

sehingga mengurangi subjektivitas, meningkatkan konsistensi diagnosis, serta mempercepat proses deteksi tumor (Hosny *et al.*, 2018). Selain berperan sebagai second opinion bagi tenaga medis, terutama di daerah dengan keterbatasan spesialis, AI juga menawarkan analisis non-invasif yang lebih efisien dibandingkan biopsi (Hosny *et al.*, 2018).

Dalam penelitian ini, digunakan ekstraksi fitur tekstur berbasis Gray Level Run Length Matrix (GLRLM) dan klasifikasi menggunakan Support Vector Machine (SVM). GLRLM efektif dalam menangkap karakteristik tekstur citra tumor otak melalui analisis pola run dalam berbagai arah, seperti homogenitas dan heterogenitas tekstur (Chu *et al.*, 1990). Fitur-fitur tekstur yang telah diekstraksi kemudian diklasifikasikan menggunakan algoritma SVM, yaitu metode *supervised machine learning* yang efektif untuk menangani masalah klasifikasi biner maupun multikelas. SVM beroperasi dengan mencari *hyperplane* optimal yang dapat memisahkan setiap kelas dengan margin maksimum, sehingga menghasilkan model klasifikasi yang robust (tahan terhadap variasi data dan tidak mudah terpengaruh oleh *noise*) serta memiliki kemampuan generalisasi yang baik (Dheepak *et al.*, 2023).

Beberapa penelitian sebelumnya telah mengeksplorasi penggunaan metode *machine learning* untuk deteksi tumor otak dengan berbagai pendekatan. Penelitian oleh Jena *et al.*, (2021) menggunakan kombinasi ekstraksi fitur GLCM dan GLRLM dengan klasifikasi SVM untuk deteksi tumor otak dari citra MRI dan mencapai akurasi 98,04%. Kibriya *et al.*, (2022) mengimplementasikan metode ekstraksi fitur tekstur berbasis GLRLM dengan algoritma *Random Forest* untuk klasifikasi *multiclass* tumor otak (*glioma*, *meningioma*, dan *pituitary*) dengan

akurasi 94,74%. Sementara itu, penelitian oleh Ayadi *et al.*, (2021) menggunakan kombinasi *deep learning* CNN dengan SVM sebagai *classifier* untuk klasifikasi tiga jenis tumor otak dan mencapai akurasi 93,68%. Meskipun penelitian-penelitian tersebut menunjukkan hasil yang menjanjikan dalam deteksi tumor otak, terdapat beberapa keterbatasan yang perlu diatasi. Penelitian Jena *et al.*, (2021) hanya fokus pada klasifikasi biner (tumor vs non-tumor), sementara Kibriya *et al.*, (2022) tidak melakukan analisis mendalam terhadap karakteristik tekstur spesifik yang membedakan setiap jenis tumor. Penelitian Ayadi *et al.*, (2021) menggunakan arsitektur *hybrid* yang kompleks dan memerlukan *computational resource* tinggi. Celah penelitian yang teridentifikasi adalah perlunya pengembangan sistem klasifikasi *multiclass* yang efisien dengan metode GLRLM-SVM yang dapat membedakan berbagai jenis tumor otak spesifik (normal, *glioma*, *meningioma*, dan *pituitary*) disertai dengan analisis mendalam terhadap karakteristik tekstur yang membedakan setiap jenis tumor untuk mendukung interpretasi klinis.

Pada penelitian ini dilakukan pengembangan sistem klasifikasi citra MRI tumor otak menggunakan metode ekstraksi ciri *Gray Level Run Length Matrix* (GLRLM) dan *Support Vector Machine* (SVM). Citra yang diklasifikasikan terdiri atas empat kategori, yaitu otak normal, *glioma*, *meningioma*, dan *pituitary*. Metode GLRLM dipilih karena memiliki kemampuan dalam menangkap karakteristik tekstur yang bersifat spesifik pada struktur citra, sehingga dapat membedakan pola tekstur antar kategori tumor otak. Dengan pendekatan kombinasi GLRLM dan SVM ini diharapkan dapat diperoleh performa klasifikasi yang optimal, yang diukur melalui akurasi, presisi, sensitivitas, spesifisitas, dan F1-Score. Selain itu, penelitian ini juga bertujuan untuk mengidentifikasi dan menganalisis ciri tekstur

dominan dari masing-masing kategori, sehingga dapat memberikan pemahaman yang lebih mendalam terkait perbedaan tekstur pada citra otak normal maupun tumor, serta berpotensi mendukung interpretasi klinis dalam diagnosis medis.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka penelitian ini memiliki rumusan masalah sebagai berikut:

1. Bagaimana tingkat validitas data (akurasi, presisi, sensitivitas, spesifisitas, dan F1-Score) dari metode GLRLM-SVM dalam mendeteksi Tumor Otak?
2. Bagaimana karakteristik tekstur citra tumor otak normal, *glioma*, *meningioma*, dan *pituitary* berdasarkan ekstraksi fitur GLRLM?

1.3 Tujuan

Sejalan dengan rumusan masalah di atas, tujuan dari penelitian ini adalah:

1. Untuk menganalisis tingkat validitas data yang meliputi akurasi, presisi, sensitivitas, spesifisitas, dan F1-Score dari metode GLRLM-SVM dalam mendeteksi tumor otak.
2. Untuk mengidentifikasi karakteristik tekstur pada citra otak normal, *glioma*, *meningioma*, dan *pituitary* melalui ekstraksi fitur GLRLM.

1.4 Manfaat Penelitian

1. Manfaat Teoritis
 - a. Memberikan kontribusi ilmiah dalam pengembangan sistem diagnosis berbantuan komputer (*Computer-Aided Diagnosis*) untuk tumor otak, khususnya dengan mengeksplorasi penerapan metode GLRLM yang dikombinasikan dengan SVM untuk klasifikasi multi-kelas.

- b. Memperkaya khazanah keilmuan di bidang fisika medis dan pengolahan citra digital mengenai analisis karakteristik tekstur citra MRI untuk identifikasi tumor otak.

2. Manfaat Praktis

- a. Bagi mahasiswa atau akademisi, penelitian ini dapat menjadi referensi dan sumber pembelajaran mengenai implementasi *machine learning* dalam analisis citra medis, serta menjadi dasar untuk pengembangan penelitian lebih lanjut.
- b. Secara jangka panjang, model yang dihasilkan berpotensi untuk dikembangkan menjadi sistem pendukung keputusan klinis (*clinical decision support system*) yang dapat membantu radiolog dalam mendiagnosis sub-tipe tumor otak secara lebih objektif dan efisien.

1.5 Batasan Penelitian

Untuk menjaga agar penelitian ini tetap fokus dan terarah, ditetapkan batasan-batasan sebagai berikut:

1. Data yang digunakan merupakan data sekunder berupa citra Magnetic Resonance Imaging (MRI) otak yang diperoleh dari repositori publik Kaggle (Brain Tumor MRI Dataset oleh Masoud Nickparvar). Data citra tumor diambil di Nanfang Hospital, Guangzhou dan General Hospital, Tianjin Medical University, China. Citra tersebut diakuisisi menggunakan protokol T1-weighted contrast-enhanced (dengan injeksi Gd-DTPA) yang memiliki spesifikasi resolusi in-plane 512×512 piksel (ukuran piksel 0.49×0.49 mm²), ketebalan irisan (slice thickness) 6 mm, dan celah irisan (slice gap) 1 mm.

2. Penelitian ini berfokus pada klasifikasi empat kelas, yaitu: otak normal, *glioma*, *meningioma*, dan *pituitary*.
3. Penelitian ini membatasi penggunaan metode pada ekstraksi fitur tekstur *Gray Level Run Length Matrix* (GLRLM) dan algoritma klasifikasi *Support Vector Machine* (SVM), serta tidak melakukan perbandingan komprehensif dengan metode lain.
4. Proses implementasi dan eksperimen akan dilakukan menggunakan perangkat lunak MATLAB R2025a atau versi yang lebih baru.
5. Hasil akhir dari penelitian ini adalah sebuah model komputasi beserta analisis performanya, dan tidak sampai pada tahap pembuatan aplikasi klinis yang siap diimplementasikan di lingkungan medis.

BAB II

TINJAUAN PUSTAKA

2.1 Tumor Otak

Tumor otak merupakan kondisi medis yang ditandai dengan adanya pembelahan sel abnormal yang tidak terkendali di dalam jaringan otak, membentuk massa atau benjolan yang dapat mengganggu fungsi normal otak. Tumor otak terjadi ketika sel-sel di otak atau sekitar otak mengalami mutasi pada DNA mereka, menyebabkan sel-sel tersebut tumbuh dan membelah dengan cara yang tidak normal. Karakteristik unik dari tumor otak adalah kemampuannya untuk berkembang dalam jangka waktu yang panjang tanpa menimbulkan gejala yang jelas pada tahap awal, sehingga seringkali diagnosis baru ditegakkan ketika tumor telah mencapai ukuran yang signifikan atau mulai menimbulkan komplikasi neurologis. Hal ini menjadikan deteksi dini tumor otak sebagai tantangan klinis yang penting untuk meningkatkan prognosis dan *outcome* pengobatan pasien (Hanahan, 2022).

Faktor risiko utama terjadinya tumor otak meliputi paparan radiasi ionisasi, terutama radiasi pada kepala yang diterima pada usia muda, riwayat keluarga dengan tumor otak, serta kondisi genetik tertentu seperti *neurofibromatosis* (kelainan genetik yang menyebabkan pertumbuhan tumor pada jaringan saraf) dan *sindrom Li-Fraumeni* (gangguan genetik langka yang meningkatkan risiko berbagai jenis kanker sejak usia muda). Usia juga menjadi faktor risiko, karena insiden tumor otak primer cenderung meningkat seiring bertambahnya usia. Meskipun belum ada metode yang terbukti sepenuhnya dapat mencegah tumor otak, beberapa penelitian

menunjukkan bahwa pola hidup sehat dapat membantu menurunkan risikonya, antara lain dengan mengonsumsi makanan kaya antioksidan seperti buah-buahan dan sayuran berwarna gelap, menghindari paparan zat karsinogenik (bahan kimia atau senyawa yang dapat memicu pertumbuhan sel kanker), membatasi paparan radiasi elektromagnetik yang tidak perlu, dan menjaga berat badan ideal. Konsumsi makanan yang mengandung flavonoid (senyawa alami dalam tumbuhan yang memiliki efek antioksidan dan antikanker), vitamin E, serta asam lemak omega-3 juga dikaitkan dengan penurunan risiko berbagai jenis kanker, termasuk tumor otak (Onyije *et al.*, 2024).

2.1.1 Jenis-jenis Tumor Otak

Berdasarkan karakteristik histologis, lokasi, dan asal sel, tumor otak diklasifikasikan menjadi dua kategori utama: tumor otak primer dan tumor otak sekunder. Tumor otak primer merupakan jenis yang berasal langsung dari jaringan otak dan *meninges*, sedangkan tumor otak sekunder berasal dari metastasis kanker dari organ lain. Fokus tinjauan ini akan membahas tumor otak primer, khususnya tiga jenis yang paling umum dijumpai secara klinis, yaitu *glioma*, *meningioma*, dan *pituitary* (Park *et al.*, 2023).

- a. *Glioma* merupakan tumor otak yang berasal dari sel-sel *glial*, yaitu sel pendukung yang berperan memberikan nutrisi, perlindungan, dan dukungan struktural bagi neuron di jaringan saraf otak. Tumor ini termasuk jenis tumor otak primer yang paling umum, mencakup sekitar 40–50% dari seluruh kasus tumor otak. *Glioma* dapat diklasifikasikan lebih lanjut berdasarkan jenis sel *glial* yang terlibat menjadi beberapa subtype utama, seperti astrosit (sel berbentuk bintang yang berfungsi mendukung dan

menjaga keseimbangan lingkungan kimia di sekitar neuron), *oligodendrosit* (sel yang membentuk selubung mielin untuk mempercepat transmisi impuls saraf), dan sel ependimal (sel yang melapisi ventrikel otak serta membantu sirkulasi cairan serebrospinal). *Glioma* memiliki tingkat agresivitas yang bervariasi, mulai dari *grade* rendah dengan pertumbuhan lambat hingga *grade* tinggi yang bersifat sangat invasif dan berpotensi ganas. Berdasarkan klasifikasi WHO 2021 yang terbaru, *glioma* dibedakan menjadi *glioma* tipe dewasa dan tipe pediatrik (jenis *glioma* yang terjadi pada anak-anak) dengan mempertimbangkan profil molekuler seperti mutasi IDH (perubahan gen pada enzim *isocitrate dehydrogenase* yang memengaruhi metabolisme sel kanker), status ATRX (penanda genetik yang terkait dengan kestabilan kromosom dan karakteristik sel tumor), serta perubahan genetik lainnya. (Park *et al.*, 2023).

- b. *Meningioma* adalah tumor otak yang berkembang dari sel-sel *meninges*, yaitu lapisan jaringan ikat yang menyelubungi dan melindungi otak serta sumsum tulang belakang. *Meningioma* merupakan jenis tumor otak primer kedua yang paling sering ditemukan, mencakup sekitar 30-35% dari semua kasus tumor otak intrakranial. Karakteristik histologis yang khas dari *meningioma* adalah pertumbuhan yang umumnya lambat, berbatas tegas, dan biasanya bersifat jinak, meskipun beberapa varian dapat menunjukkan sifat atipik atau ganas dengan tingkat pertumbuhan yang lebih cepat dan potensi invasi yang lebih tinggi. Berdasarkan klasifikasi WHO 2021, *meningioma* dibagi menjadi tiga grade berdasarkan kriteria histopatologi dan profil molekuler. Adanya mutasi TERT promoter (perubahan pada

wilayah pengatur gen TERT yang berperan dalam memperpanjang umur sel melalui aktivitas enzim telomerase) serta delesi CDKN2A/B (kehilangan segmen gen yang berfungsi menghambat pembelahan sel secara berlebihan) menunjukkan bahwa *meningioma* termasuk dalam *grade* tinggi, yang memiliki risiko rekurensi (kekambuhan) lebih besar (Park *et al.*, 2023).

- c. *Pituitary* adalah neoplasma yang berasal dari kelenjar pituitari, sebuah kelenjar endokrin kecil yang terletak di dasar otak dan berfungsi mengontrol berbagai fungsi metabolik dan hormonal dalam tubuh. Tumor pituitary mencakup sekitar 10-15% dari seluruh tumor otak primer dan dapat diklasifikasikan berdasarkan ukuran, fungsi hormonal, dan karakteristik klinis menjadi tumor yang menghasilkan hormon (*secreting*) atau tidak menghasilkan hormon (*non-secreting*). Klasifikasi berdasarkan ukuran membedakan tumor menjadi *microadenoma* (diameter <10 mm), *macroadenoma* (>10 mm), dan tumor raksasa (>40 mm). Meskipun mayoritas tumor pituitari bersifat jinak, tumor ini dapat menimbulkan masalah klinis yang signifikan melalui efek desakan pada struktur sekitar, termasuk kompresi pada struktur neural dan pembuluh darah, serta gangguan pada sekresi hormon yang berdampak pada keseimbangan endokrin tubuh (Melmed *et al.*, 2022).

2.1.2 Pemeriksaan dan Diagnosis

Dalam praktik klinis, penegakan diagnosis tumor otak memerlukan evaluasi yang sistematis dan menyeluruh untuk memastikan ketepatan diagnosis. Beberapa metode dapat digunakan untuk melakukan pemeriksaan dan menegakkan diagnosis tumor otak, di antaranya adalah sebagai berikut:

a. Pemeriksaan Fisik

Pemeriksaan fisik merupakan langkah awal yang penting dalam evaluasi pasien yang dicurigai mengalami tumor otak, dilakukan oleh dokter untuk mendeteksi tanda-tanda objektif penyakit dan mengumpulkan informasi riwayat medis lengkap pasien. Pemeriksaan ini meliputi evaluasi neurologis komprehensif yang mencakup penilaian fungsi saraf kranial, kekuatan motorik, refleks, koordinasi, fungsi sensorik, dan status mental. Dokter juga akan menanyakan secara detail mengenai gejala yang dialami pasien seperti pola dan karakteristik sakit kepala, riwayat kejang, perubahan penglihatan, gangguan keseimbangan, perubahan kepribadian atau kognitif, serta riwayat keluarga dengan tumor otak atau kondisi genetik terkait. Pemeriksaan funduskopi juga sering dilakukan untuk mendeteksi papilledema (pembengkakan diskus optikus) yang merupakan tanda peningkatan tekanan intrakranial. Hasil pemeriksaan fisik ini akan menentukan apakah diperlukan pemeriksaan penunjang lebih lanjut seperti pencitraan medis (Louis *et al.*, 2021).

b. MRI (*Magnetic Resonance Imaging*)

MRI merupakan modalitas pencitraan pilihan utama untuk deteksi dan karakterisasi tumor otak karena kemampuannya menghasilkan gambar tiga dimensi dengan resolusi tinggi dan kontras jaringan lunak yang superior. Teknologi MRI menggunakan medan magnet kuat dan gelombang radio untuk menghasilkan gambaran detail dari struktur anatomis otak, memungkinkan visualisasi tumor, edema peritumoral, dan hubungannya dengan struktur otak sekitarnya. Berbagai sekuens MRI digunakan untuk

karakterisasi tumor, termasuk T1-weighted (untuk anatomi), T2-weighted dan FLAIR (untuk edema dan batas tumor), serta T1-weighted dengan kontras gadolinium (untuk menilai peningkatan kontras tumor dan gangguan *blood-brain barrier*). *Advanced MRI techniques* seperti *diffusion-weighted imaging* (DWI), *perfusion-weighted imaging* (PWI), dan *MR spectroscopy* dapat memberikan informasi tambahan mengenai karakteristik biologis tumor seperti seluleritas, vaskularisasi, dan profil metabolik. Keunggulan MRI dibandingkan modalitas pencitraan lain adalah tidak menggunakan radiasi pengion, dapat membedakan berbagai jenis jaringan dengan baik, dan mampu mendeteksi tumor berukuran kecil atau lesi pada lokasi yang sulit dijangkau (Lapointe *et al.*, 2018).

c. Biopsi

Biopsi merupakan prosedur pengambilan sampel jaringan tumor untuk dilakukan analisis patologi mikroskopis guna memastikan diagnosis definitif tumor otak, menentukan jenis histologis, dan *grading* tumor. Terdapat beberapa metode biopsi tumor otak, antara lain *stereotactic needle biopsy*, yaitu prosedur pengambilan sampel jaringan menggunakan sistem navigasi komputer melalui lubang kecil di tengkorak, serta open biopsy yang dilakukan bersamaan dengan kraniotomi untuk reseksi atau pengangkatan sebagian tumor. Jaringan hasil biopsi kemudian diperiksa oleh ahli patologi anatomi guna mengidentifikasi jenis sel tumor, tingkat keganasan, serta karakteristik molekuler seperti mutasi IDH (perubahan pada gen *isocitrate dehydrogenase* yang memengaruhi metabolisme sel dan sering menjadi indikator prognosis yang lebih baik), kodelesi 1p/19q (kehilangan bersamaan

pada bagian kromosom 1p dan 19q yang biasanya menunjukkan respons baik terhadap terapi dan prognosis yang lebih menguntungkan), dan status metilasi promotor MGMT (tingkat penambahan gugus metil pada gen MGMT yang berperan dalam memperbaiki DNA, di mana metilasi tinggi sering dikaitkan dengan respons yang lebih baik terhadap kemoterapi *temozolomide*) yang penting dalam menentukan prognosis dan strategi terapi yang tepat. Meskipun biopsi memberikan informasi diagnostik yang sangat berharga, prosedur ini tidak bebas risiko dan dapat menimbulkan komplikasi seperti perdarahan intrakranial, infeksi, atau defisit neurologis, sehingga keputusan untuk melakukan biopsi harus mempertimbangkan risiko dan manfaat. Dalam era modern, molekular profiling dari jaringan tumor semakin penting untuk *personalized medicine* dan *targeted therapy* (Goldbrunner *et al.*, 2016).

d. Diagnosis Stadium

Diagnosis stadium merupakan proses sistematis untuk menentukan sejauh mana tumor telah berkembang dan menyebar di dalam tubuh, yang sangat penting untuk menentukan strategi pengobatan optimal dan memperkirakan prognosis pasien. Berbeda dengan kanker sistemik yang menggunakan sistem *staging* TNM (*Tumor, Node, Metastasis*), tumor otak primer umumnya tidak menggunakan sistem *staging* konvensional karena jarang bermetastasis ke luar sistem saraf pusat. Sebagai gantinya, tumor otak diklasifikasikan berdasarkan *grading histopatologis* WHO (*grade* I-IV) yang mencerminkan tingkat keganasan, kecepatan pertumbuhan, dan prognosis. Evaluasi ekstensif tumor meliputi penilaian ukuran tumor, lokasi anatomis, keterlibatan struktur vital, penyebaran ke ventrikel atau meningen, dan ada

tidaknya diseminasi leptomeningeal melalui cairan serebrospinal. Untuk tumor metastatik ke otak, *staging* juga mencakup pencarian tumor primer dan evaluasi metastasis sistemik lainnya menggunakan CT *scan* toraks-abdomen-pelvis atau PET-CT *whole body*. Informasi *staging* yang komprehensif membantu tim multidisiplin dalam merencanakan modalitas terapi yang tepat, apakah pembedahan, radioterapi, kemoterapi, atau kombinasinya (Louis *et al.*, 2021).

2.1.3 Identifikasi Ketidaknormalan Tubuh dalam Perspektif Al-Qur'an

Secara sunatullah, tubuh manusia diciptakan oleh Allah SWT dalam keadaan yang seimbang dan sempurna. Tumor otak, sebagai massa abnormal yang tumbuh tidak terkendali, merupakan bentuk gangguan pada keseimbangan tersebut. Upaya manusia untuk mengidentifikasi penyakit atau ketidaknormalan ini menggunakan teknologi (seperti MRI dan kecerdasan buatan) selaras dengan perintah Allah untuk mengamati ciptaan-Nya secara teliti guna menemukan "cacat" atau ketidakseimbangan yang mungkin terjadi. Hal ini tersirat dalam firman Allah SWT dalam Q.S. Al-Mulk ayat 3-4:

الَّذِي خَلَقَ سَبْعَ سَمَوَاتٍ طِبَاقًا مَا تَرَى فِي خَلْقِ الرَّحْمَنِ مِنْ تَفَوُّتٍ فَارْجِعِ الْبَصَرَ هَلْ تَرَى مِنْ فُتُورٍ ﴿٣﴾
ثُمَّ ارْجِعِ الْبَصَرَ كَرَّتَيْنِ يَنْقَلِبْ إِلَيْكَ الْبَصَرُ خَاسِئًا وَهُوَ حَسِيرٌ ﴿٤﴾

Artinya: (Dia juga) yang menciptakan tujuh langit berlapis-lapis. Kamu tidak akan melihat pada ciptaan Tuhan Yang Maha Pengasih ketidakseimbangan sedikit pun. Maka, lihatlah sekali lagi! Adakah kamu melihat suatu cela? Kemudian, lihatlah sekali lagi (dan) sekali lagi (untuk mencari cela dalam ciptaan Allah), niscaya pandanganmu akan kembali kepadamu dengan kecewa dan dalam keadaan letih (karena tidak menemukannya). (Q.S. Al-Mulk [67]: 3-4)


Menurut Tafsir Al-Misbah, kata tafavut (tidak seimbang) dan futur (cacat/retak) dalam ayat di atas mengajak manusia untuk melakukan observasi

berulang-ulang (research/re-search) untuk mencari ketidakaturan. Dalam konteks medis, teknologi MRI dan metode komputasi seperti GLRLM dan SVM berfungsi sebagai alat bantu bagi "penglihatan" manusia yang terbatas untuk melakukan observasi berulang tersebut secara presisi. Jika glioma, meningioma, atau pituitary adalah bentuk futur (ketidaknormalan/penyakit) pada fisik manusia, maka penelitian ini adalah bentuk ikhtiar untuk mendeteksinya sedini mungkin agar keseimbangan tubuh dapat dipulihkan kembali melalui pengobatan yang tepat.


2.2 *Magnetic Resonance Imaging (MRI)*

MRI (*Magnetic Resonance Imaging*) adalah prosedur diagnostik non-invasif yang menggunakan teknologi pencitraan medis canggih untuk menghasilkan gambar detail dari organ dan struktur internal tubuh, khususnya jaringan lunak seperti otak, sumsum tulang belakang, dan organ dalam kepala lainnya. Prinsip kerja MRI didasarkan pada fenomena resonansi magnetik inti atom hidrogen dalam tubuh manusia ketika ditempatkan dalam medan magnet kuat dan dipapar gelombang radio frekuensi tertentu. Atom hidrogen, yang berlimpah dalam tubuh manusia terutama dalam molekul air dan lemak, akan merespons rangsangan medan magnet dengan menghasilkan sinyal yang kemudian ditangkap oleh *receiver coils* dan diolah oleh komputer menjadi gambaran anatomi yang detail (Hui *et al.*, 2025). MRI memiliki keunggulan signifikan dalam visualisasi jaringan lunak dibandingkan modalitas pencitraan lain seperti CT-scan, karena mampu membedakan berbagai jenis jaringan berdasarkan kandungan air dan komposisi kimianya. Dalam konteks *neuroimaging*, MRI memungkinkan visualisasi struktur otak yang sangat detail, termasuk substansia grisea dan alba, ventrikel, pembuluh darah, serta abnormalitas seperti tumor, infark, perdarahan, dan lesi inflamasi.

Berbagai protokol dan sekuens MRI dapat disesuaikan untuk mengoptimalkan visualisasi patologi spesifik, menjadikan MRI sebagai *gold standard* untuk pencitraan tumor otak (Alam, 2023).



Gambar 2. 1 MRI (MICHEAU & HOA, 2025)




Gambar 2. 2 MRI otak dengan nodul tumor (Sarker, 2024)

2.3 Pengolahan Citra Digital

Pengolahan Citra Digital (*Digital Image Processing*) adalah bidang ilmu yang mempelajari teknik-teknik untuk membentuk, mengolah, memanipulasi, dan menganalisis citra dalam format digital menggunakan komputer. Citra dapat dibedakan menjadi dua kategori utama berdasarkan representasinya: citra analog

yang merupakan representasi kontinu dari objek visual dalam ruang dua dimensi (seperti foto cetak atau gambar pada film), dan citra digital yang merupakan representasi diskrit dari citra analog yang telah dikonversi menjadi *array* numerik piksel dengan nilai intensitas tertentu. Setiap piksel dalam citra digital memiliki koordinat spasial (x, y) dan nilai intensitas yang merepresentasikan informasi warna atau tingkat keabuan pada posisi tersebut. Pengolahan citra digital memiliki berbagai aplikasi penting dalam dunia medis, khususnya dalam analisis citra diagnostik seperti MRI, CT *scan*, dan X-ray, memungkinkan ekstraksi informasi kuantitatif, deteksi abnormalitas, dan membantu dalam pengambilan keputusan klinis (Bhusnurmath & Doddamani, 2024).




Gambar 2.3 Pengolahan citra digital

2.3.1 Citra RGB

Citra RGB (*Red, Green, Blue*) merupakan model representasi citra berwarna yang paling umum digunakan dalam pengolahan citra digital, di mana setiap piksel direpresentasikan oleh kombinasi tiga komponen warna dasar: merah (*Red*), hijau (*Green*), dan biru (*Blue*). Setiap komponen warna memiliki nilai intensitas dalam rentang 0-255 (untuk representasi 8-bit), sehingga total kombinasi warna yang dapat direpresentasikan mencapai 16.777.216 warna (256^3). Dalam citra RGB, setiap piksel memerlukan 24 bit informasi ($8 \text{ bit} \times 3 \text{ channel}$), menjadikannya sebagai representasi *true color* yang mampu menampilkan spektrum warna yang luas. Model RGB banyak digunakan dalam

tampilan digital seperti monitor komputer, televisi, dan kamera digital karena sesuai dengan cara mata manusia mempersepsikan warna melalui tiga jenis fotoreseptor kerucut (*cone cells*) yang sensitif terhadap panjang gelombang merah, hijau, dan biru. Dalam konteks citra medis, khususnya MRI yang umumnya dihasilkan dalam format *grayscale*, citra dapat divisualisasikan dalam format RGB menggunakan *color mapping* untuk meningkatkan kontras visual atau menyoroti fitur tertentu (Sollmann *et al.*, 2025).



Gambar 2. 4 Representasi kanal warna RGB (Munir, 2022)




Gambar 2. 5 Citra RGB pada masing-masing kanal (Munir, 2022)

2.3.2 Citra *Grayscale*

Citra *Grayscale* adalah representasi citra yang hanya menggunakan informasi intensitas atau tingkat keabuan tanpa informasi warna, dengan nilai piksel berkisar dari 0 (hitam) hingga 255 (putih) untuk representasi 8-bit. Berbeda dengan citra RGB yang memerlukan tiga channel warna, citra *grayscale* hanya memerlukan satu channel, sehingga ukuran file lebih kecil dan komputasi lebih efisien. Setiap tingkat keabuan merepresentasikan intensitas luminansi pada posisi piksel tersebut, dengan nilai yang lebih rendah menunjukkan area

yang lebih gelap dan nilai yang lebih tinggi menunjukkan area yang lebih terang. Citra *grayscale* sangat penting dalam aplikasi medis, khususnya dalam analisis citra MRI dan CT scan yang *inherently* merupakan citra *grayscale*, di mana intensitas piksel mencerminkan properti fisik jaringan seperti densitas proton atau koefisien atenuasi. Konversi dari citra RGB ke *grayscale* dapat dilakukan menggunakan berbagai metode, yang paling umum adalah *weighted average method* menggunakan rumus: $Gray = 0.299 \times R + 0.587 \times G + 0.114 \times B$, yang memberikan bobot lebih besar pada komponen hijau sesuai dengan sensitivitas mata manusia (Sollmann *et al.*, 2025).



Gambar 2. 6 Grayscale Level (Mukherjee *et al.*, 2024)

2.3.3 Pre-processing

Pre-processing merupakan tahap awal yang krusial dalam *pipeline* pengolahan citra digital, bertujuan untuk meningkatkan kualitas citra dengan menghilangkan *noise*, artifak, atau komponen yang tidak relevan, serta menyiapkan citra untuk tahap analisis selanjutnya. Dalam konteks analisis citra medis untuk klasifikasi tumor otak, tahap *pre-processing* sangat penting untuk memastikan konsistensi data input dan meningkatkan akurasi ekstraksi fitur. Beberapa teknik *pre-processing* yang umum diterapkan meliputi: (AvazBeigi & Ghazizadeh-Ahsaei, 2025)


- a. *Cropping* adalah teknik memotong atau mengambil *region of interest* (ROI) tertentu dari citra, menghilangkan area yang tidak relevan seperti *background* atau struktur non-otak, sehingga analisis dapat difokuskan pada area yang mengandung informasi diagnostik penting. Dalam citra MRI otak, *cropping* digunakan untuk mengisolasi area otak dari tengkorak, *scalp*, dan *background*, mengurangi *computational cost* dan meningkatkan fokus algoritma pada jaringan yang relevan.
- b. *Grayscale* adalah proses konversi citra berwarna (RGB) menjadi citra *grayscale*, yang penting karena sebagian besar algoritma ekstraksi fitur tekstur, termasuk GLRLM, dirancang untuk bekerja pada citra *grayscale single-channel*. Konversi ini menyederhanakan representasi citra tanpa kehilangan informasi intensitas yang signifikan, mempercepat komputasi, dan mengurangi kompleksitas analisis.

Teknik *pre-processing* lainnya yang sering diterapkan dalam analisis citra MRI tumor otak meliputi normalisasi intensitas untuk menstandarkan rentang nilai piksel, *filtering* untuk mengurangi *noise* (seperti *Gaussian filter* atau median filter), dan *contrast enhancement* untuk meningkatkan perbedaan intensitas antara tumor dan jaringan sehat (AvazBeigi & Ghazizadeh-Ahsaei, 2025).

2.4 Gray Level Run Length Matrix (GLRLM)

Tekstur merupakan karakteristik visual penting dalam sebuah citra yang menggambarkan pola spasial dan distribusi intensitas piksel, mencerminkan sifat permukaan dan struktur internal objek dalam citra. Dalam analisis citra medis, khususnya citra MRI tumor otak, fitur tekstur memberikan informasi kuantitatif

tentang heterogenitas jaringan yang sangat berharga untuk karakterisasi dan klasifikasi tumor. *Gray Level Run Length Matrix* (GLRLM) adalah metode analisis tekstur orde tinggi (*higher-order*) yang powerful untuk mengekstraksi fitur tekstur dari citra dengan cara menghitung pola "*run*" dalam citra. Run didefinisikan sebagai sekuens atau deretan piksel yang berurutan dengan nilai intensitas *gray level* yang sama dalam arah tertentu. Metode GLRLM menganalisis *run* dalam empat arah sudut yang berbeda: 0° (horizontal), 45° (diagonal kanan atas), 90° (vertikal), dan 135° (diagonal kiri atas), untuk menangkap informasi tekstur yang *direction-dependent*. Matriks GLRLM $P(i,j|\theta)$ merepresentasikan frekuensi kemunculan run dengan *gray level* i dan panjang *run* j pada arah θ , memberikan informasi statistik tentang distribusi dan pola *run* dalam citra. Metode ini sangat efektif untuk membedakan tekstur halus (yang memiliki banyak *run* pendek) dari tekstur kasar (yang memiliki *run* panjang), menjadikannya ideal untuk karakterisasi tumor otak yang memiliki pola tekstur heterogen (Durgamahanthi *et al.*, 2021).



Gambar 2. 7 Direksi arah run (A.Harshavardhan *et al.*, 2017)

Sebagai contoh, citra berbentuk matriks berukuran 4×4 dengan empat tingkat keabuan (0, 1, 2, dan 3) ditunjukkan pada Gambar 2.8, sedangkan hasil perhitungan GLRLM untuk masing-masing arah sudut pencarian dapat dilihat pada Gambar 2.9.

0	1	2	3
0	2	3	3
2	1	1	1
3	0	3	0

Gambar 2. 8 Matrik ukuran 4×4 dengan empat skala keabuan (0 sampai 3) (A.Harshavardhan *et al.*, 2017)

Gray Level (l)	Run Length (j)				$\theta = 0^\circ$
	1	2	3	4	$g(l)$
0	4	0	0	0	4
1	1	0	1	0	2
2	3	0	0	0	3
3	3	1	0	0	4
$r(j)$	11	1	1	0	$S = 13$

a. 0°

Gray Level (l)	Run Length (j)				$\theta = 45^\circ$
	1	2	3	4	$g(l)$
0	4	0	0	0	4
1	4	0	0	0	4
2	0	0	1	0	1
3	3	1	0	0	4
$r(j)$	11	1	1	0	$S = 13$

b. 45°

Gray Level (l)	Run Length (j)				$\theta = 90^\circ$
	1	2	3	4	$g(l)$
0	2	1	0	0	3
1	4	0	0	0	4
2	3	0	0	0	3
3	3	1	0	0	4
$r(j)$	12	2	0	0	$S = 14$

c. 90°

Gray Level (l)	Run Length (j)				$\theta = 135^\circ$
	1	2	3	4	$g(l)$
0	4	0	0	0	4
1	4	0	0	0	4
2	3	0	0	0	3
3	5	0	0	0	5
$r(j)$	16	0	0	0	$S = 16$

d. 135°

Gambar 2. 9 Hasil GLRLM pada masing-masing orientasi sudut (A.Harshavardhan *et al.*, 2017)

2.4.1 Fitur-Fitur GLRLM

Dari matriks GLRLM, dapat diekstraksi tujuh fitur tekstur utama yang masing-masing memiliki interpretasi fisik dan klinis yang spesifik:

a. *Short Runs Emphasis* (SRE)

Short Runs Emphasis (SRE) menguantifikasi dominasi *run* pendek dalam citra, dengan nilai yang tinggi mengindikasikan tekstur yang halus dan homogen. Fitur ini dihitung menggunakan formula: (Zhang *et al.*, 2019)

$$SRE = \frac{1}{s} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{j^2} = \sum_{j=1}^N \frac{r(i,j)}{j^2} \quad (2.1)$$

b. *Long Runs Emphasis* (LRE)

Long Runs Emphasis (LRE) mengukur dominasi *run* panjang dalam citra, dimana nilai tinggi menunjukkan tekstur kasar dan heterogen dengan pola yang lebih terstruktur. Formula yang digunakan: (Zhang *et al.*, 2019)

$$LRE = \frac{1}{s} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{j^2} = \sum_{j=1}^N j^2 r(j) / S \quad (2.2)$$

c. *Gray Level Non-Uniformity* (GLN)

Gray Level Non-Uniformity (GLN) mengevaluasi distribusi tingkat keabuan dalam citra, dengan nilai rendah mengindikasikan distribusi *gray level* yang seragam dan nilai tinggi menunjukkan variabilitas intensitas yang besar. (Zhang *et al.*, 2019)

$$GLN = \frac{1}{s} \sum_{i=1}^M \left(\sum_{j=1}^N p(i,j) \right)^2 = \sum_{j=1}^N g(i)^2 / S \quad (2.3)$$

d. *Run Length Non-Uniformity* (RLN)

Run Length Non-Uniformity (RLN) mengukur keseragaman distribusi panjang *run* dalam citra, memberikan informasi tentang regularitas pola tekstur. (Zhang *et al.*, 2019)

$$RLN = \frac{1}{s} \sum_{i=1}^M \left(\sum_{j=1}^N p(i,j) \right)^2 = \sum_{j=1}^N r(j)^2 / S \quad (2.4)$$

e. *Low Gray Level Runs Emphasis* (LGRE)

Low Gray Level Runs Emphasis (LGRE) menekankan *run* dengan intensitas *gray level* rendah, berguna untuk mengkarakterisasi region dengan kontras rendah. (Zhang *et al.*, 2019)

$$LGRE = \frac{1}{s} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{i^2} \quad (2.5)$$

f. *High Gray Level Runs Emphasis* (HGRE)

High Gray Level Runs Emphasis (HGRE) menekankan *run* dengan intensitas *gray level* tinggi, bermanfaat untuk identifikasi region dengan kontras tinggi. (Zhang *et al.*, 2019)

$$HGRE = \frac{1}{s} \sum_{i=1}^M \sum_{j=1}^N p(i, j) i^2 \quad (2.6)$$

g. *Run Percentage* (RP)

Run Percentage (RP) mengukur proporsi *run* dalam citra terhadap total jumlah piksel, memberikan indikasi tingkat homogenitas keseluruhan tekstur. (Zhang *et al.*, 2019)

$$RP = \frac{s}{\sum_{i=1}^M \sum_{j=1}^N p(i, j)} = \frac{1}{n} \sum_{i=1}^M \sum_{j=1}^N p(i, j) \quad (2.7)$$

Dimana:

S = Jumlah total seluruh nilai *run* pada sebuah citra

M = Jumlah urutan derajat keabuan (*gray level*) (0, 1, 2, ..., 255)

N = Jumlah urutan *run-length* (1, 2, 3, ...)

i = Nilai derajat keabuan (*gray level*) (0; 1; 2; ...; $M - 1$)

j = Nilai *run-length* (1; 2; 3; ...; N)

$r(j)$ = Jumlah *run-length* berdasarkan urutan j

$g(i)$ = Jumlah *run-length* berdasarkan urutan i (*gray level*)


n = Jumlah baris $\times$ jumlah kolom

$p(i, j)$ = Himpunan matriks i dan j

2.5 *Support Vector Machine* (SVM)


Support Vector Machine (SVM) adalah algoritma pembelajaran mesin supervisi yang dikembangkan berdasarkan prinsip *Structural Risk Minimization* (SRM) dan teori pembelajaran statistik *Vapnik-Chervonenkis*, yang dirancang untuk menyelesaikan masalah klasifikasi dan regresi dengan mencari *hyperplane* optimal yang dapat memisahkan data dari kelas-kelas yang berbeda dengan margin

maksimal. Konsep fundamental SVM adalah menemukan *decision boundary* berupa *hyperplane* di ruang fitur berdimensi tinggi yang dapat memaksimalkan jarak (margin) antara *support vectors* dari kelas-kelas yang berbeda (Basthikodi et al., 2024).



Gambar 2. 10 Support Vector (Saminu et al., 2021)

Dalam implementasinya untuk klasifikasi citra medis, SVM menunjukkan performa yang robust dan generalisasi yang baik, terutama untuk dataset dengan dimensi fitur yang tinggi dan jumlah sampel yang relatif terbatas. Algoritma ini awalnya dikembangkan untuk menangani masalah klasifikasi biner (dua kelas), namun kemudian diperluas untuk mengatasi masalah klasifikasi multikelas melalui strategi seperti *One-vs-One* (OvO) dan *One-vs-All* (OvA), dimana beberapa model SVM biner dikombinasikan untuk menghasilkan keputusan klasifikasi akhir untuk lebih dari dua kelas (Melis et al., 2015).



Gambar 2. 11 Model SVM (Singh, 2023)

Misalnya terdapat kelas A, B, C, dan D, kita akan membangun empat model SVM biner:

- a. Model SVM A-vs-BCD: Memisahkan kelas A dari kelas B, C, dan D.
- b. Model SVM B-vs-ACD: Memisahkan kelas B dari kelas A, C, dan D.
- c. Model SVM C-vs-ABD: Memisahkan kelas C dari kelas A, B, dan D.
- d. Model SVM D-vs-ABC: Memisahkan kelas D dari kelas A, B, dan C.

Setiap model SVM biner akan memiliki vektor penyeimbang (w) dan bias (b) yang spesifik untuk mengklasifikasikan satu kelas tertentu terhadap kelas-kelas lainnya. Ketika mengklasifikasikan data baru, kita akan menghitung fungsi keputusan dari keempat model SVM biner dan memilih kelas dengan nilai tertinggi sebagai kelas prediksi (Basthikodi *et al.*, 2024).

Penghitungan nilai fungsi keputusan dan pemilihan kelas prediksi:

$$fA - vs - BCD(x) = wA - vs - BCD \cdot x + bA - vs - BCD \quad (2.8)$$

$$fB - vs - ACD(x) = wB - vs - ACD \cdot x + bB - vs - ACD \quad (2.9)$$

$$fC - vs - ABD(x) = wC - vs - ABD \cdot x + bC - vs - ABD \quad (2.10)$$

$$fD - vs - ABC(x) = wD - vs - ABC \cdot x + bD - vs - ABC \quad (2.11)$$

Setelah menghitung nilai fungsi keputusan dari semua model SVM biner, kita memilih kelas dengan nilai tertinggi sebagai kelas prediksi untuk data tersebut:

$$\text{Prediksi} = \operatorname{argmax}(fA - vs - BCD(x), fB - vs - ACD(x), fC - vs - ABD(x), fD - vs - ABC(x)) \quad (2.12)$$

2.6 Confusion Matrix

Confusion Matrix merupakan alat evaluasi fundamental dalam *machine learning* yang menyajikan representasi tabuler dari performa model klasifikasi dengan cara merangkum jumlah prediksi yang benar dan salah untuk setiap kelas

dalam format matriks. Matrix ini memberikan gambaran komprehensif tentang bagaimana model *classifier* membuat kesalahan prediksi dan seberapa baik model dapat membedakan antara kelas-kelas yang berbeda (Hicks *et al.*, 2022).

Confusion Matrix			
		Predict Data	
		Positif	Negatif
Actual Data	Positif	TP	FN
	Negatif	FP	TN

Gambar 2. 12 Confusion Matrix (Hicks *et al.*, 2022)

Struktur Confusion Matrix untuk klasifikasi biner terdiri dari empat komponen fundamental: *True Positive* (TP) yang merepresentasikan jumlah sampel positif yang diprediksi dengan benar sebagai positif, *False Negative* (FN) yang menunjukkan jumlah sampel positif yang salah diprediksi sebagai negatif, *False Positive* (FP) yang merepresentasikan jumlah sampel negatif yang salah diprediksi sebagai positif, dan *True Negative* (TN) yang menunjukkan jumlah sampel negatif yang diprediksi dengan benar sebagai negatif (Hicks *et al.*, 2022).

2.6.1 Parameter Metrik Evaluasi

Dari *Confusion Matrix*, dapat dihitung berbagai parameter metrik untuk mengevaluasi performa model klasifikasi secara kuantitatif:

a. Akurasi (*Accuracy*)

Akurasi (*Accuracy*) mengukur proporsi total prediksi yang benar terhadap seluruh prediksi yang dibuat, dihitung dengan formula: (Hicks *et al.*, 2022)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.13)$$

b. Presisi (*Precision*)

Presisi (*Precision*) mengevaluasi seberapa akurat prediksi positif yang dibuat oleh model, dengan fokus pada minimalisasi *false positive*. Formula yang digunakan: (Hicks *et al.*, 2022)

$$Precision = \frac{TP}{TP+FP} \quad (2.14)$$

c. Recall/Sensitivitas (*Sensitivity*)

Recall/Sensitivitas (*Sensitivity*) mengukur kemampuan model untuk mengidentifikasi semua kasus positif yang sebenarnya, dengan penekanan pada minimalisasi *false negative*: (Hicks *et al.*, 2022)

$$Recall = \frac{TP}{TP+FN} \quad (2.15)$$

d. Spesifisitas (*Specificity*)

Spesifisitas (*Specificity*) mengevaluasi kemampuan model untuk mengidentifikasi semua kasus negatif yang sebenarnya dengan benar: (Hicks *et al.*, 2022)

$$Specificity = \frac{TN}{TN+FP} \quad (2.16)$$

e. *F1-Score*

F1-Score merupakan *harmonic mean* dari *precision* dan *recall* yang memberikan keseimbangan optimal antara kedua metrik tersebut, terutama berguna untuk dataset yang tidak seimbang: (Hicks *et al.*, 2022)

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.17)$$

Parameter-parameter ini secara kolektif memberikan evaluasi menyeluruh terhadap performa model klasifikasi dan membantu dalam pemilihan model yang optimal untuk aplikasi spesifik dalam diagnosis medis.

BAB III

METODE PENELITIAN


3.1 Jenis Penelitian

Jenis penelitian yang digunakan pada penelitian ini adalah deskriptif kuantitatif karena pada penelitian ini mengandung unsur perhitungan dan membutuhkan analisis berdasarkan nilai yang diperoleh. Hasil analisis kemudian dievaluasi agar dicapai tujuan dari penelitian.

3.2 Sumber Data Penelitian

Sumber data yang digunakan dalam penelitian merupakan data sekunder citra *Brain Tumor MRI Dataset* oleh Masoud Nickparvar dari Kaggle yang diambil dari *website* Kaggle. Data terdiri dari 65 citra otak normal, 65 citra *glioma*, 65 citra *meningioma*, dan 65 citra *pituitary*.

3.3 Rancangan Penelitian



Gambar 3. 1 Diagram Alir Penelitian

3.4 Prosedur Penelitian

3.4.1 Pengambilan dan Pengelompokan data

Data diperoleh dari *website Kaggle*. Selanjutnya, data tersebut dibagi menjadi dua kelompok: data latih (*training*) berjumlah 50 citra untuk setiap kelas, dan data uji (*testing*) berjumlah 15 citra per kelas. Pada penelitian ini digunakan empat kelas, yaitu: *normal*, *glioma*, *meningioma*, dan *pituitary*.

3.4.2 Pre-processing Data

Supaya analisis intensitas citra lebih mudah, dilakukan dua tahap pra-pemrosesan, yaitu *cropping* dan *grayscale*.

3.4.1 Cropping Citra

Proses ini dilakukan agar fokus analisis hanya pada area tertentu.

Algoritma yang digunakan:

- 1) Menentukan koordinat awal (x_1, y_1) (pojok kiri atas) dan koordinat akhir (x_2, y_2) (pojok kanan bawah)
- 2) Menghitung lebar sumbu horizontal:

$$\Delta_x = x_2 - x_1 \quad (3.1)$$

- 3) Menghitung tinggi sumbu vertikal:

$$\Delta_y = y_2 - y_1 \quad (3.2)$$

3.4.2 Grayscale

Karena hanya diperlukan informasi intensitas, citra RGB yang memiliki tiga kanal (R, G, B) dikonversi menjadi citra keabuan dengan satu kanal saja. Persamaan konversinya adalah:

$$Gray(m, n) = \frac{0.299 \cdot f_R(m, n) + 0.587 \cdot f_G(m, n) + 0.114 \cdot f_B(m, n)}{3} \quad (3.3)$$

3.4.4 Pengklasifikasian SVM

a. Pelatihan Model SVM

Untuk setiap model SVM biner (misalnya A vs BCD, B vs ACD, dst.), dilakukan pelatihan menggunakan fitur GLRLM sebagai input dan label kelas sebagai target. Proses ini juga melibatkan pencarian parameter optimal agar diperoleh *hyperplane* pemisah terbaik.

b. Pengujian dan Evaluasi

Setelah pelatihan, dilakukan uji performa model dengan data uji. Setiap sampel uji akan dihitung nilai fungsi keputusan dari semua model SVM biner, lalu dipilih kelas dengan nilai tertinggi sebagai hasil prediksi. Selanjutnya, hasil prediksi dibandingkan dengan label asli untuk menghitung metrik evaluasi seperti akurasi, presisi, *recall*, dan lainnya.

3.4.5 Perhitungan Validitas Data

Untuk mengevaluasi validitas hasil klasifikasi digunakan *Confusion Matrix*. Rumus-rumus yang digunakan adalah:

a. Akurasi:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.4)$$

b. Presisi:

$$Precision = \frac{TP}{TP+FP} \quad (3.5)$$

c. *Recall* / Sensitivitas:

$$Recall = \frac{TP}{TP+FN} \quad (3.6)$$

d. Spesifisitas:

$$Specificity = \frac{TN}{TN+FP} \quad (3.7)$$

e. F1-Score:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3.8)$$

3.5 Desain Tampilan GUI

Sistem klasifikasi tumor otak yang dikembangkan dalam penelitian ini diimplementasikan dalam bentuk *Graphical User Interface* (GUI) menggunakan MATLAB R2025a untuk memudahkan penggunaan dan visualisasi hasil analisis. GUI dirancang dengan antarmuka yang intuitif dan *user-friendly* agar proses klasifikasi dapat dilakukan dengan efisien oleh pengguna.

IDENTIFIKASI TUMOR OTAK

GLRLM-SVM
Muhammad Baqibillah (220604110023)

Pre-processing

Citra Asli [CA] Histogram CA

Citra Grayscale [CG] Histogram CG

Button

Load Citra

Grayscale

Ekstraksi Ciri

Klasifikasi

Reset

Identifikasi SVM

Skor
0

Kategori

Fitur GLRLM

LRE 0 RLN 0 HGRE 0
SRE 0 GLN 0 LGRE 0 RP 0

Gambar 3. 2 Tampilan Antarmuka GUI Sistem Klasifikasi Tumor Otak

BAB IV

ANALISIS DAN PEMBAHASAN

4.1 Data Hasil Penelitian


4.1.1 *Pre-processing* Citra

Pada tahap persiapan data, penelitian ini menggunakan total 260 citra MRI yang dibagi menjadi dua himpunan data, yaitu data latih (*training*) dan data uji (*testing*). Data latih terdiri dari 200 citra yang terbagi merata ke dalam empat kelas, meliputi 50 citra Normal, 50 citra *Glioma*, 50 citra *Meningioma*, dan 50 citra *Pituitary*. Sementara itu, data uji mencakup 60 citra, yang juga didistribusikan ke dalam empat kelas yang sama dengan 15 citra Normal, 15 citra *Glioma*, 15 citra *Meningioma*, dan 15 citra *Pituitary*. Mengingat citra MRI mentah seringkali masih mengandung area non-relevan seperti tengkorak atau jaringan sehat lainnya, diperlukan tahap *pre-processing* untuk mengisolasi *Region of Interest* (ROI) sebelum proses analisis.


Pada tahap *pre-processing* ini, dilakukan teknik pemotongan citra (*cropping*) yang bertujuan untuk mendapatkan area khusus yang akan dianalisis, yaitu jaringan otak. Proses ini difokuskan untuk mengisolasi *Region of Interest* (ROI) dan menghilangkan bagian non-relevan seperti tengkorak, mata, atau jaringan latar belakang lainnya. Selain itu, dilakukan pula teknik *grayscale* untuk mengonversi citra (jika belum) menjadi citra dengan 256 skala keabuan (rentang intensitas 0–255), yang merupakan format standar untuk proses analisis dan ekstraksi fitur lebih lanjut.

a. *Cropping*


Untuk memfokuskan dan mempermudah proses analisis, dilakukan teknik *cropping* (pemotongan citra) dengan ukuran 36×36 pixel (px) pada area tertentu dalam jaringan otak. Perintah yang digunakan di MATLAB adalah `croppedImage = imcrop(inputImage, [x1, y1, width, height]);`, di mana `croppedImage` merupakan citra hasil pemotongan, `imcrop` adalah fungsi yang digunakan, dan `inputImage` adalah citra masukan. Parameter `width` (lebar) dan `height` (tinggi) diatur ke 36 piksel. Penentuan koordinat titik awal (`x1`, `y1`) dilakukan secara otomatis dengan menentukan titik tengah (`x`, `y`) dari *Region of Interest* (ROI). Nilai `x1` dan `y1` dihitung dengan mengurangi setengah dari ukuran sisi (`halfSize = 18`) dari koordinat pusat tersebut, menggunakan formula `x1 = x - halfSize`; dan `y1 = y - halfSize`;



Gambar 4. 1 Citra Magnetic Resonance Imaging (MRI)



Gambar 4. 2 Area pemotongan citra



Gambar 4. 3 Hasil pemotongan citra dengan ukuran 36 x 36 px

Gambar 4.1 menampilkan citra MRI awal sebelum dilakukan pemrosesan. Penentuan area *cropping* pada citra tersebut direpresentasikan pada Gambar 4.2, sementara citra hasil *cropping* yang telah terisolasi ditampilkan pada Gambar 4.3. Citra hasil (Gambar 4.3) ini kemudian ditetapkan sebagai citra masukan untuk tahap analisis selanjutnya.

b. *Grayscale*

Tahap ini bertujuan untuk melakukan standardisasi, memastikan bahwa seluruh citra masukan (*input*) berada dalam format *grayscale* (skala keabuan). Hal ini penting karena proses analisis selanjutnya hanya membutuhkan informasi intensitas pada tiap piksel, yang direpresentasikan dalam rentang nilai 0 (hitam) hingga 255 (putih). Meskipun citra *Magnetic Resonance Imaging* (MRI) otak pada dasarnya sudah *grayscale*, langkah ini tetap diimplementasikan sebagai verifikasi. Apabila sistem mendeteksi citra masukan yang masih dalam format RGB, citra tersebut akan dikonversi secara otomatis menggunakan fungsi “*rgb2gray*” pada MATLAB. Namun, jika citra telah terkonfirmasi sebagai *grayscale*, tahap konversi ini akan dilewati.

4.1.2 Ekstraksi Fitur Tekstur

Setelah melalui tahap *pre-processing*, proses dilanjutkan dengan tahap ekstraksi fitur. Tahap ini bertujuan untuk mendapatkan informasi unik dalam bentuk nilai numerik yang terkandung dalam citra, di mana fitur tersebut akan digunakan sebagai parameter pembanding untuk mengidentifikasi jenis citra. Ciri tekstur, yang merupakan aspek penting dalam analisis citra MRI otak, mencakup informasi kuantitatif tentang struktur internal jaringan. Tekstur ini merepresentasikan pola piksel yang terbentuk dari kompleksitas spasial dan distribusi intensitas keabuan pada setiap pikselnya. Pada penelitian ini, tekstur menjadi karakteristik utama yang diukur untuk hiper nilai kekasaran (*roughness*), kehalusan (*smoothness*), keteraturan (*regularity*), dan heterogenitas (*heterogeneity*) dari pola *grayscale*.

Metode ekstraksi fitur yang digunakan dalam penelitian ini adalah *Gray Level Run Length Matrix* (GLRLM), yang merupakan sebuah metode statistik tekstur orde tinggi. GLRLM bekerja dengan menganalisis *run-length*, yaitu jumlah piksel berurutan (jarak) yang memiliki intensitas keabuan yang sama, dimulai dari *Pixel of Interest* (PoI). Perhitungan matriks *run-length* ini didasarkan pada pola *grayscale* citra dan dilakukan dalam empat arah orientasi sudut: 0°, 45°, 90°, dan 135°. Dari matriks yang dihasilkan, penelitian ini menganalisis tujuh fitur tekstur, meliputi *Short Run Emphasis* (SRE), *Long Run Emphasis* (LRE), *Gray Level Non-uniformity* (GLN), *Run Length Non-uniformity* (RLN), *Low Gray Level Run Emphasis* (LGRE), *High Gray Level Run Emphasis* (HGRE), dan *Run Percentage* (RP). Proses ekstraksi ketujuh fitur

ini pada setiap citra MRI otak dilakukan berdasarkan formulasi matematis yang dirinci pada persamaan (2.1) sampai dengan persamaan (2.7).

a. *Matrix Run Length*

Setelah citra MRI otak melalui tahap *pre-processing*, yang meliputi *cropping* dan *grayscale*, langkah selanjutnya adalah proses ekstraksi. Pada tahap ini, matriks citra yang mengandung nilai-nilai intensitas keabuan pada setiap pikselnya akan diekstrak, seperti yang diilustrasikan pada matriks berikut:

$$I_{36 \times 36} = \begin{bmatrix} 79 & 90 & 96 & 98 & \dots & 54 & 77 & 104 & 128 \\ 84 & 92 & 95 & 94 & \dots & 43 & 58 & 85 & 117 \\ 92 & 95 & 91 & 86 & \dots & 46 & 53 & 72 & 99 \\ 106 & 103 & 92 & 82 & \dots & 48 & 55 & 68 & 84 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots \\ 101 & 105 & 106 & 105 & \dots & 65 & 75 & 79 & 78 \\ 84 & 91 & 97 & 101 & \dots & 62 & 72 & 79 & 81 \\ 81 & 84 & 87 & 90 & \dots & 64 & 75 & 86 & 93 \\ 98 & 94 & 84 & 76 & \dots & 72 & 86 & 102 & 113 \end{bmatrix}$$

Gambar 4. 4 *Matriks Run length*

Melalui analisis matriks tersebut, dapat diamati hubungan spasial antara piksel asal (PoI) dan piksel tetangganya berdasarkan kesamaan nilai *grayscale*. Hubungan ini dilacak sepanjang lintasan dalam empat arah orientasi (0° , 45° , 90° , dan 135°). Jumlah piksel berurutan yang memiliki nilai *grayscale* yang sama dalam satu lintasan didefinisikan sebagai *run-length*. Nilai *run-length* ini, beserta nilai *grayscale* dari piksel-piksel yang terlibat, digunakan untuk mengkarakterisasi tekstur citra.

b. Hasil Ekstraksi Fitur GLRLM

Setelah statistik matriks *run-length* diperoleh dari citra MRI otak, data GLRL tersebut diproses menggunakan persamaan (2.1) hingga (2.7) untuk menghasilkan tujuh fitur GLRLM. Nilai fitur yang didapat dari setiap

orientasi sudut kemudian dirata-ratakan. Nilai rata-rata inilah yang akan digunakan sebagai vektor masukan (*input*) untuk algoritma *Support Vector Machine* (SVM), yang bertugas menentukan kelas citra. Proses ekstraksi fitur ini—mulai dari *pre-processing* hingga perhitungan rata-rata nilai fitur diterapkan pada keseluruhan 260 citra otak. Setelah seluruh data fitur terkumpul, 260 set data tersebut dibagi menjadi dua kelompok, yaitu data latih (*training*) dan data uji (*testing*).

4.1.1 Citra *Training*

Tabel 4. 1 *Range* Nilai Fitur GLRLM pada Data *Training*

Kelas	Fitur	<i>Range</i>
Normal	SRE	0.979366 - 1.495422
	LRE	4.051760 - 72.666667
	GLN	102.262766 - 297.113718
	RLN	160.020833 - 1022.612724
	LGRE	0.139070 - 0.483241
	HGRE	31.174145 - 157.701346
	RP	0.527392 - 1.356481
<i>Glioma</i>	SRE	0.911558 - 1.358696
	LRE	6.636307 - 21.353282
	GLN	92.373387 - 196.710486
	RLN	201.167339 - 673.091401
	LGRE	0.116091 - 0.279172
	HGRE	116.214174 - 303.642734
	RP	0.721836 - 1.126929
<i>Meningioma</i>	SRE	0.941237 - 1.529443
	LRE	3.607882 - 31.685273
	GLN	91.204704 - 250.087995
	RLN	159.850950 - 1160.326847
	LGRE	0.108880 - 0.279340
	HGRE	99.050413 - 262.445368
	RP	0.620563 - 1.422647
<i>Pituitary</i>	SRE	1.110016 - 1.454047
	LRE	4.686624 - 11.003115

	GLN	101.327972 - 194.619798
	RLN	371.225078 - 938.761866
	LGRE	0.124291 - 0.220163
	HGRE	114.972222 - 210.386560
	RP	0.918981 - 1.303819

4.1.2 Citra *Testing*

Tabel 4. 2 *Range* Nilai Fitur GLRLM pada Data *Testing*

Kelas	Fitur	<i>Range</i>
Normal	SRE	0.916797 - 1.519754
	LRE	3.949546 - 41.854118
	GLN	139.459124 - 243.344252
	RLN	134.256443 - 1114.507316
	LGRE	0.144319 - 0.541970
	HGRE	31.271907 - 160.619072
	RP	0.576003 - 1.390239
<i>Glioma</i>	SRE	0.988576 - 1.303026
	LRE	7.614691 - 20.358998
	GLN	111.192586 - 215.577110
	RLN	257.859403 - 613.096649
	LGRE	0.115834 - 0.261306
	HGRE	104.353526 - 333.557630
	RP	0.779900 - 1.099923
<i>Meningioma</i>	SRE	0.872470 - 1.496545
	LRE	4.290541 - 38.840659
	GLN	89.864508 - 245.367849
	RLN	156.933133 - 1041.978690
	LGRE	0.108880 - 0.278539
	HGRE	112.305255 - 382.340964
	RP	0.612461 - 1.351080
<i>Pituitary</i>	SRE	1.259281 - 1.397682
	LRE	5.942080 - 9.891643
	GLN	123.829196 - 166.821295
	RLN	510.456091 - 777.452128
	LGRE	0.154704 - 0.235738
	HGRE	121.916107 - 203.564421
	RP	1.005401 - 1.194444

4.1.3 Analisis Klasifikasi SVM

Setelah data rata-rata dari fitur GLRLM (yang diekstraksi dari 4 arah) diperoleh untuk setiap citra otak, data tersebut digunakan sebagai masukan (*input*) untuk tahap klasifikasi menggunakan SVM. Data latih (*training*), yang berjumlah 200 data, dimanfaatkan untuk melatih model SVM agar dapat mengenali pola dari setiap kelas citra otak. Sementara itu, 60 data uji (*testing*) digunakan untuk mengevaluasi kemampuan dan kinerja model SVM yang telah dilatih dalam mengklasifikasikan citra baru. Pembagian data latih dan data uji ini bertujuan untuk menguji kemampuan generalisasi model.

Tahap awal klasifikasi SVM adalah memasukkan variabel data latih (*training*), yang tersimpan dalam file Excel, ke dalam *classifier* SVM di MATLAB. Pada tahap selanjutnya, algoritma SVM memetakan (*plot*) seluruh data fitur GLRLM beserta data label kelas (Kelas Normal = 0, Kelas *Glioma* = 1, Kelas *Meningioma* = 2, dan Kelas *Pituitary* = 3). Proses pembelajaran atau tahap *training* algoritma SVM kemudian dilakukan, yang pada penelitian ini diatur dengan *10-fold cross-validation* dan menghasilkan akurasi *training* sebesar 95.5%. Setelah akurasi *training* didapat, model SVM yang telah terbentuk diekspor ke *workspace* dan disimpan dalam format “.mat”. Model (file .mat) inilah yang akan digunakan untuk mengidentifikasi data baru. Terakhir, setelah model disimpan, dilakukan pengujian menggunakan data *testing* (uji) untuk mengetahui kinerja dan performa sistem klasifikasi GLRLM-SVM.

a. Sebaran Validitas Data

Kinerja sistem GLRLM-SVM diukur melalui sebaran validitas data yang diperoleh dari perhitungan *confusion matrix*. Matriks ini

merepresentasikan rincian hasil prediksi SVM dengan empat parameter utama: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Dalam konteks klasifikasi empat kelas pada penelitian ini (Normal, *Glioma*, *Meningioma*, dan *Pituitary*), TP adalah klasifikasi yang benar-benar termasuk dalam suatu kelas dan diprediksi dengan benar. TN adalah klasifikasi yang benar-benar bukan bagian dari suatu kelas dan diprediksi dengan benar sebagai bukan kelas tersebut. FP terjadi ketika data yang sebenarnya bukan bagian dari suatu kelas, keliru diprediksi sebagai kelas tersebut. Terakhir, FN terjadi ketika data yang sebenarnya termasuk dalam suatu kelas, namun keliru diprediksi sebagai kelas lain. Berikut merupakan tabel *confusion matrix* yang dihasilkan:

Tabel 4. 3 Confusion Matrix

Confusion Matrix				
Kelas	Normal	Glioma	Meningioma	Pituitary
Normal	15	0	0	0
Glioma	0	15	0	0
Meningioma	0	0	15	0
Pituitary	0	0	0	15

Berdasarkan tabel tersebut, terlihat bahwa semua nilai *True Positive* (TP) dan *True Negative* (TN) untuk setiap kelas adalah 15. Sebaliknya, semua nilai *False Positive* (FP) dan *False Negative* (FN) adalah 0, yang mengindikasikan tidak adanya kesalahan klasifikasi pada data uji. Selanjutnya, seluruh komponen *confusion matrix* ini digunakan untuk menghitung sebaran validitas data dari algoritma SVM.

1. Akurasi (*Accuracy*)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% = \frac{15 + 15}{15 + 15 + 0 + 0} = 100\%$$

Nilai akurasi 100% menunjukkan bahwa sistem prediksi SVM telah berhasil mengklasifikasikan seluruh citra MRI otak pada data *testing* dengan benar, semata-mata berdasarkan fitur teksturnya. Hal ini dapat diinterpretasikan bahwa kinerja dan performa SVM dalam mengenali pola tekstur yang khas pada masing-masing kelas citra otak (Normal, Glioma, Meningioma, Pituitary) tergolong sangat baik dan akurat.

2. Presisi (*Precision*)

$$Precision = \frac{TP}{TP + FP} \times 100\% = \frac{15}{15 + 0} \times 100\% = 100\%$$

Presisi (*Precision*) merepresentasikan rasio antara jumlah data yang diprediksi dengan benar sebagai suatu kelas (*True Positive*), terhadap total data yang diprediksi sebagai kelas tersebut (termasuk yang benar/TP dan yang salah/FP). Ketika nilai presisi mencapai 100%, ini menunjukkan bahwa setiap citra yang diprediksi sistem sebagai kelas tertentu. Hal ini mengindikasikan tidak adanya kesalahan prediksi *False Positive* (FP = 0).

3. Recall/Sensitivitas (*Sensitivity*)

$$Recall = \frac{TP}{TP + FN} \times 100\% = \frac{15}{15 + 0} \times 100\% = 100\%$$

Sensitivitas (*Sensitivity*), atau Recall, adalah metrik yang mengukur rasio *True Positive* (TP) terhadap jumlah total data aktual dari suatu kelas (TP + *False Negative* [FN]). Metrik ini mengkuantifikasi kemampuan model untuk mengidentifikasi semua sampel positif yang relevan. Pencapaian

nilai recall 100% (FN = 0) dalam penelitian ini menunjukkan bahwa sistem SVM berhasil mengenali setiap citra aktual dari masing-masing kelas tanpa ada yang terlewat. Secara krusial, ini berarti tidak ada citra tumor yang salah diklasifikasikan sebagai Normal, sehingga menghindari risiko diagnostik yang paling berbahaya. Dengan presisi dan recall yang sama-sama mencapai 100%, sistem menunjukkan kinerja ideal di mana setiap pasien dikategorikan dengan benar sesuai dengan kondisi patologi mereka, yang merupakan dasar untuk penentuan perawatan yang akurat.

4. Spesifisitas (*Specificity*)

$$Specificity = \frac{TN}{TN + FP} \times 100\% = \frac{15}{15 + 15} \times 100\% = 100\%$$

Spesifisitas (*Specificity*) mencerminkan rasio citra otak Normal pada data aktual yang berhasil diidentifikasi dengan benar oleh SVM, dibandingkan dengan keseluruhan data aktual pada kelas Normal. Dengan nilai spesifisitas yang mencapai 100%, dapat disimpulkan bahwa sistem prediksi SVM berhasil mengklasifikasikan semua citra Normal pada data aktual dengan benar dan tepat. Dengan kata lain, tidak terdapat kesalahan prediksi (*False Positive*) di mana citra otak Normal pada data aktual salah diklasifikasikan sebagai salah satu kelas tumor (misalnya *Glioma*, *Meningioma*, atau *Pituitary*).

5. $F1_{Score}$

$$\begin{aligned} F1_{Score} &= 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \times 100\% = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \times 100\% \\ &= \frac{15}{15 + \frac{1}{2}(0 + 0)} \times 100\% = 100\% \end{aligned}$$

$F1_{Score}$ merupakan nilai rata-rata harmonik antara presisi (*precision*) dan sensitivitas (*recall*), yang digunakan sebagai metrik tunggal untuk mengukur keseimbangan antara keduanya. Metrik ini penting karena seringkali terdapat *trade-off* di mana peningkatan presisi dapat menurunkan sensitivitas, atau sebaliknya. Oleh karena itu, $F1_{Score}$ menjadi indikator komprehensif untuk menilai kualitas sistem prediksi. Pencapaian nilai $F1_{Score}$ 100% pada penelitian ini menandakan bahwa presisi dan *recall* berada dalam keseimbangan yang optimal. Hal ini membuktikan bahwa sistem prediksi SVM memiliki kualitas yang sangat baik dalam memahami pola tekstur MRI otak dan memprediksi dataset pada tahap pengujian.

4.1.4 Karakteristik Tekstur Citra

Setelah data diekstraksi fiturnya melalui GLRLM dan diklasifikasikan menggunakan SVM, karakteristik citra otak dapat diidentifikasi. Identifikasi ini dilakukan dengan menganalisis ciri teksturnya, yaitu melalui penentuan nilai ambang batas (*mid point*) yang berfungsi untuk memisahkan atau membedakan antara dua karakteristik tekstur yang berlawanan (seperti halus dan kasar).

Tabel 4. 4 *Range* Nilai Fitur

Fitur	Parameter	Range	<i>Mid Point</i>	$\geq$ <i>Mid Point</i>	$<$ <i>Mid Point</i>
SRE	<i>Short Run</i>	0.872470 - 1.529443	1.200956	Halus	Kasar
LRE	<i>Long Run</i>	3.607882 - 72.666667	38.137274	Kasar	Halus
GLN	<i>Gray Level</i>	89.864508 - 297.113718	193.489113	Heterogen	Homogen
RLN	<i>Run Length</i>	134.256443 - 1160.326847	647.291645	Heterogen	Homogen
LGRE	<i>Low Gray Level</i>	0.108880 - 0.541970	0.325425	Banyak	Sedikit
HGRE	<i>High Gray Level</i>	31.174145 - 382.340964	206.757555	Banyak	Sedikit
RP	<i>Run</i>	0.527392 - 1.422647	0.975019	Tinggi	Rendah

Setelah rentang (*range*) nilai berdasarkan data yang diperoleh dari ekstraksi fitur GLRLM pada masing-masing citra diketahui, karakteristik tekstur dapat diidentifikasi berdasarkan parameter-parameter yang ada. Berikut adalah

tabel ringkasan yang menyajikan karakteristik tekstur pada masing-masing kelas citra otak:

Tabel 4. 5 Karakteristik Tekstur pada masing-masing Kelas

Parameter		Kelas			
		Normal	<i>Glioma</i>	<i>Meningioma</i>	<i>Pituitary</i>
<i>Short Run</i>	Halus	32	29	31	63
	Kasar	33	36	34	2
<i>Long Run</i>	Halus	58	65	64	65
	Kasar	7	0	1	0
<i>Gray Level</i>	Heterogen	23	3	20	1
	Homogen	42	62	45	64
<i>Run Length</i>	Heterogen	22	4	28	38
	Homogen	43	61	37	27
<i>Low Gray Level</i>	Banyak	26	0	0	0
	Sedikit	39	65	65	65
<i>High Gray Level</i>	Banyak	1	40	24	1
	Sedikit	64	25	41	64
<i>Run</i>	Tinggi	21	21	22	63
	Rendah	44	44	43	2

Berdasarkan Tabel 4.5 yang menyajikan data karakteristik tekstur pada masing-masing kelas citra, dapat diuraikan analisisnya sebagai berikut:

Pada kelas Normal, sebagian besar data citra memiliki permukaan yang cenderung halus, dikarenakan nilai *Long Run* yang dominan halus (58) meskipun nilai *Short Run* hampir seimbang (32 Halus vs 33 Kasar). Karakteristik utamanya adalah pola *gray level* yang homogen (42) dan jumlah *run length* yang juga homogen (43). Citra normal memiliki sedikit intensitas *low gray level* (39) dan sangat sedikit *high gray level* (64), dengan persentase *run* (*Run Percentage*) yang rendah (44). Nilai RP yang rendah ini berkorelasi dengan adanya *run* yang kasar (*Short Run Kasar* 33), yang mengindikasikan tekstur yang tidak seragam sempurna.

Pada kelas *Glioma*, data citra didominasi oleh permukaan yang cenderung kasar, ditunjukkan oleh nilai *Short Run* yang dominan kasar (36). Meskipun demikian, *Long Run*-nya sangat halus (65). Mirip dengan kelas Normal, kelas *Glioma* memiliki pola *gray level* (62) dan *run length* (61) yang sangat homogen serta persentase *run* (RP) yang rendah (44). Perbedaan utamanya dengan kelas Normal adalah pada distribusi intensitas, di mana *Glioma* memiliki sangat sedikit *low gray level* (65) namun banyak *high gray level* (40).

Pada kelas *Meningioma*, karakteristiknya cukup mirip dengan kelas Normal. Data citra memiliki permukaan yang cenderung kasar (*Short Run* Kasar 34) namun *Long Run* yang sangat halus (64). *Pola gray level* (45) dan *run length* (37) cenderung homogen. Kelas ini juga memiliki persentase *run* (RP) yang rendah (43) serta sangat sedikit *low gray level* (65) dan sedikit *high gray level* (41). Perbedaan utamanya dari kelas Normal adalah *Short Run* yang lebih dominan kasar dan distribusi *gray level* yang sedikit berbeda.

Pada kelas *Pituitary*, karakteristiknya sangat kontras dibandingkan ketiga kelas lainnya. Sebagian besar data citra memiliki permukaan yang sangat halus, dikonfirmasi oleh nilai *Short Run* (63) dan *Long Run* (65) yang dominan halus. Hal ini berkorelasi dengan persentase *run* (RP) yang sangat tinggi (63). Kelas ini memiliki pola *gray level* yang sangat homogen (64) dan sangat sedikit intensitas *low gray level* (65) serta *high gray level* (64). Satu-satunya karakteristik yang menonjol adalah pola *run length* yang cenderung heterogen (38), menjadikannya unik dibandingkan kelas-kelas lain yang cenderung homogen pada parameter ini.

4.2 Pembahasan

Penelitian ini dilakukan untuk mengetahui kinerja sistem klasifikasi berbasis *machine learning* dengan metode *Gray Level Run Length Matrix* (GLRLM) dan *Support Vector Machine* (SVM) dalam mengidentifikasi citra otak normal dan jenis-jenis tumor otak (*glioma*, *meningioma*, dan *pituitary*). Selain itu, penelitian ini juga bertujuan untuk menganalisis karakteristik tekstur pada masing-masing kelas citra berdasarkan nilai ekstraksi fitur GLRLM. Citra *Magnetic Resonance Imaging* (MRI) yang dianalisis difokuskan pada area jaringan otak yang mengandung informasi diagnostik vital. Masing-masing citra diekstraksi fiturnya menjadi nilai numerik melalui metode GLRLM, sehingga dapat digunakan sebagai input bagi *classifier* SVM untuk mengenali pola tekstur dan mengklasifikasikan citra ke dalam kelas yang sesuai. Kemudian, hasil data prediksi dibandingkan dengan data aktual untuk mengetahui sebaran validitasnya guna mengukur kehandalan sistem.

Tumor otak adalah pertumbuhan sel-sel abnormal di dalam atau di sekitar jaringan otak yang dapat mengganggu fungsi neurologis (Ostrom *et al.*, 2022). Untuk mendapatkan citra otak yang optimal sebagai input sistem, dilakukan tahap *pre-processing* yang meliputi *cropping* citra untuk memfokuskan pada *Region of Interest* (ROI) berukuran 36x36 piksel dan *grayscale* untuk menyederhanakan kanal warna. Setelah melalui proses *pre-processing*, citra menghasilkan statistik intensitas piksel yang kemudian diolah menggunakan teknik ekstraksi fitur tekstur GLRLM. Secara matematis, metode ini menghitung frekuensi kemunculan runut piksel dengan intensitas sama pada arah tertentu, yang merepresentasikan kekasaran atau kehalusan tekstur citra. Langkah ekstraksi ini sangat krusial untuk

mendapatkan nilai dari tujuh fitur GLRLM (SRE, LRE, GLN, RLN, LGRE, HGRE, dan RP). Fitur-fitur ini menjadi atribut pembeda yang dipelajari oleh algoritma SVM selama tahap pelatihan (*training*) untuk membentuk *hyperplane* pemisah antar kelas. Sebagai hasil akhir, sistem memberikan label kelas (Normal, *Glioma*, *Meningioma*, atau *Pituitary*) pada citra yang diuji.

Hasil prediksi sistem kemudian divalidasi menggunakan teknik *confusion matrix* dengan membandingkan kelas prediksi terhadap kelas aktual. *Confusion matrix* memetakan empat karakteristik dasar: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Berdasarkan pengujian pada 60 data citra testing, didapatkan hasil yang sangat memuaskan di mana nilai akurasi, presisi, *recall* (sensitivitas), spesifisitas, dan F1-Score semuanya mencapai nilai sempurna yaitu 100%. Hal ini dibuktikan dengan tidak adanya kesalahan klasifikasi (*missclassification*), di mana seluruh citra pada setiap kelas (15 citra per kelas) berhasil dikenali dengan tepat oleh sistem. Capaian ini membuktikan bahwa kombinasi metode ekstraksi fitur GLRLM dan klasifikasi SVM memiliki kualitas yang sangat baik dan robust dalam membedakan pola tekstur yang kompleks pada citra MRI tumor otak.

Hasil penelitian ini menunjukkan peningkatan performa dibandingkan dengan beberapa penelitian terdahulu. Sebagaimana penelitian yang dilakukan oleh Jena *et al.* (2021) yang menggunakan kombinasi fitur GLCM dan GLRLM dengan klasifikasi SVM, diperoleh akurasi sebesar 98,04%. Penelitian serupa oleh Kibriya *et al.* (2022) menggunakan GLRLM dengan algoritma Random Forest untuk klasifikasi *multiclass* tumor otak menghasilkan akurasi 94,74%. Pada penelitian ini, didapatkan akurasi yang lebih tinggi yaitu 100%. Peningkatan akurasi ini dapat

disebabkan oleh beberapa faktor, terutama pada tahapan *pre-processing*. Pada penelitian ini, dilakukan teknik *cropping* yang presisi pada area tumor atau jaringan otak (ROI) berukuran 36x36 piksel. Teknik ini secara efektif menghilangkan *noise* dari latar belakang (tengkorak atau area hitam di sekitar otak) yang seringkali mengaburkan fitur tekstur utama, sehingga algoritma SVM dapat mempelajari pola karakteristik tumor dengan lebih fokus dan akurat dibandingkan jika menggunakan citra otak utuh.

Analisis karakteristik tekstur berdasarkan fitur GLRLM menunjukkan perbedaan pola yang signifikan antar kelas. Pada kelas normal, sebagian besar citra memiliki karakteristik permukaan yang cenderung halus namun dengan Run Percentage (RP) yang rendah. Hal ini menunjukkan bahwa meskipun terdapat homogenitas pada pola gray level, distribusi run length masih memiliki variasi yang menyebabkan tekstur tidak sepenuhnya seragam. Karakteristik ini merepresentasikan jaringan otak sehat yang memiliki struktur materi putih (white matter) dan materi abu-abu (gray matter) yang terorganisir namun kompleks. Secara fisiologis, otak normal memiliki arsitektur seluler yang teratur dengan pembagian gray matter (korteks serebral yang kaya akan badan sel neuron) dan white matter (substansi putih subkortikal yang kaya akan akson bermielin) yang jelas dan konsisten. Homogenitas tekstur mencerminkan densitas jaringan otak normal yang relatif seragam dengan karakteristik mekanik yang stabil, tanpa adanya massa patologis, proliferasi seluler abnormal, atau nekrosis, sementara variasi run length yang masih ada mencerminkan kompleksitas anatomis natural dari struktur otak yang terdiri dari berbagai region fungsional dengan densitas seluler yang sedikit berbeda (Maldonado & Alsayouri, 2023).

Pada kelas tumor glioma, citra cenderung memiliki tekstur permukaan yang kasar (Short Run dominan kasar) namun dengan pola intensitas yang homogen dan nilai High Gray Level Run Emphasis (HGRE) yang tinggi. Tingginya nilai HGRE mengindikasikan bahwa citra glioma memiliki banyak area dengan intensitas kecerahan tinggi (hiperintens). Karakteristik tekstur kasar dan intensitas tinggi ini berkaitan dengan sifat glioma yang tumbuh dari sel glial dan seringkali bersifat infiltratif (menyusup ke jaringan sekitar), menciptakan heterogenitas jaringan yang tertangkap sebagai pola kasar pada analisis tekstur. Secara patofisiologis, tekstur Short Run yang kasar mencerminkan sifat infiltratif dan invasif dari sel glioma yang tumbuh difus menyebar ke parenkim otak sekitarnya, menciptakan batas tumor yang tidak jelas atau ill-defined margin. Tingginya nilai HGRE berkorelasi dengan karakteristik fisiologis glioma tingkat tinggi (high-grade glioma/glioblastoma) yang menunjukkan adanya proliferasi mikrovaskular, peningkatan vaskularisasi tumor (angiogenesis), dan area nekrosis yang menyebabkan perbedaan densitas signifikan pada citra MRI. Pola heterogenitas tekstur ini juga mencerminkan pleomorfisme seluler (cellular pleomorphism), atypia nuklear (nuclear atypia), aktivitas mitosis tinggi, serta variasi densitas yang disebabkan oleh komponen heterogen tumor seperti area solid, komponen kistik, nekrosis sentral, perdarahan intratumoral, dan edema peritumoral yang merupakan ciri khas glioblastoma (Bebyn et al., 2021).

Pada kelas tumor meningioma, karakteristik teksturnya memiliki kemiripan dengan kelas normal namun dengan kecenderungan permukaan yang lebih kasar pada Short Run. Pola gray level dan run length cenderung homogen dengan intensitas low gray level yang sangat sedikit. Karakteristik ini sejalan dengan sifat

patologis meningioma yang tumbuh dari selaput pelindung otak (meninges). Tumor ini biasanya memiliki batas yang tegas (tidak infiltratif seperti glioma) dan struktur yang padat, yang tercermin dari homogenitas pola run length yang terbentuk. Secara fisiologis, meningioma merupakan tumor ekstraaksial yang berasal dari sel meningotheial arachnoid dengan pertumbuhan ekspansif dan berbatas tegas (well-circumscribed). Pola Long Run yang halus mencerminkan massa tumor meningioma yang solid, berbatas jelas dengan jaringan otak sekitar dengan karakteristik broad-based dural attachment, dan tidak bersifat infiltratif seperti glioma. Homogenitas gray level berkorelasi dengan struktur histologis meningioma WHO Grade I yang mendominasi (80,5% kasus), yang memiliki pola whorls (pusaran sel), psammoma bodies (badan kalsifikasi), dan arsitektur seluler yang relatif uniform tanpa nekrosis ekstensif. Short Run yang kasar dapat mengindikasikan adanya kalsifikasi intratumoral atau area dengan vaskularisasi tinggi yang sering ditemukan pada meningioma, serta dapat mencerminkan hipertensi tulang (hyperostosis) yang merupakan tanda invasi tulang oleh sel meningioma, terutama pada skull base meningioma, dengan pertumbuhan lambat rata-rata 2-4 mm/tahun yang berkontribusi terhadap homogenitas tekstur (Ogasawara et al., 2021).

Pada kelas tumor pituitary, ditemukan karakteristik yang paling berbeda (kontras) dibandingkan ketiga kelas lainnya. Sebagian besar data citra memiliki permukaan yang sangat halus, ditandai dengan nilai Short Run dan Long Run yang dominan halus, serta Run Percentage (RP) yang sangat tinggi. Selain itu, kelas ini memiliki pola gray level yang sangat homogen. Tekstur yang sangat halus dan homogen ini mengindikasikan bahwa tumor pituitary, yang tumbuh pada kelenjar

pituitari di dasar otak, memiliki struktur jaringan yang sangat seragam dan lunak. Tingginya nilai RP menunjukkan bahwa citra didominasi oleh garis-garis tekstur pendek dan halus yang rapat, merepresentasikan kepadatan seluler yang unik pada jenis tumor ini. Secara patofisiologis, karakteristik tekstur yang sangat halus dan homogen sesuai dengan ciri fisiologis adenoma pituitary sebagai tumor neuroendokrin dengan pertumbuhan lambat, ekspansif, dan memiliki batas yang sangat jelas dengan jaringan sekitarnya. Homogenitas tinggi pada gray level mencerminkan struktur histologis adenoma pituitary yang terdiri dari sel-sel endokrin uniform dengan granula sekretorik yang relatif seragam, tanpa komponen nekrotik signifikan atau perdarahan ekstensif. Nilai RP yang sangat tinggi berkorelasi dengan densitas seluler yang padat dan konsisten pada pituitary adenoma yang berasal dari ekspansi monoklonal sel adenohypophyseal. Run length yang sedikit heterogen dapat mengindikasikan variasi densitas minor akibat perbedaan tipe sel pituitary seperti somatotroph adenoma, prolactinoma, atau corticotroph adenoma pada functioning adenoma, atau perbedaan intensitas sinyal antara komponen solid tumor dengan area mikrokistik pada macroadenoma, dengan lokasi anatomis di sella turcica yang terbatas berkontribusi terhadap pola pertumbuhan yang lebih terorganisir dan homogen (Melmed et al., 2022).

4.3 Kajian Keislaman

Tumor otak merupakan salah satu gangguan kesehatan serius yang menyerang organ paling vital dalam tubuh manusia. Keberadaannya dapat mengganggu fungsi kognitif, motorik, dan sensorik, yang pada akhirnya memengaruhi kualitas hidup penderita. Dalam perspektif Islam, segala bentuk penyakit yang menimpa manusia, termasuk tumor otak, dipandang tidak hanya

sebagai fenomena medis, tetapi juga memiliki dimensi spiritual. Rasulullah SAW mengajarkan bahwa sakit adalah bentuk ujian sekaligus kasih sayang Allah SWT untuk menggugurkan dosa-dosa hamba-Nya, selama hamba tersebut bersabar. Hal ini sebagaimana diriwayatkan dalam hadis shahih:

مَا يُصِيبُ الْمُسْلِمَ مِنْ نَصَبٍ وَلَا وَصَبٍ وَلَا هَمٍّ وَلَا حُزْنٍ وَلَا أَذًى وَلَا غَمٍّ حَتَّى الشَّوْكَةِ يُشَاكِمَهَا،
إِلَّا كَفَّرَ اللَّهُ بِهَا مِنْ خَطَايَاهُ

Artinya: "Tidaklah seorang muslim tertimpa suatu kelelahan, atau penyakit, atau kekhawatiran, atau kesedihan, atau gangguan, bahkan duri yang melukainya melainkan Allah akan menghapus kesalahan-kesalahannya karenanya." (HR. Bukhari No. 5641, 5642).

Hadis tersebut memberikan landasan spiritual bagi pasien tumor otak untuk tetap optimis dan tidak berputus asa. Namun, Islam tidak hanya mengajarkan kesabaran pasif. Islam adalah agama yang sangat menekankan pada ikhtiar (usaha) mencari kesembuhan. Rasulullah SAW secara tegas memerintahkan umatnya untuk berobat dan meyakinkan bahwa setiap penyakit yang diturunkan Allah pasti memiliki obatnya, kecuali kematian atau penuaan. Keyakinan ini menjadi motivasi utama bagi pengembangan ilmu kedokteran dan teknologi kesehatan. Hal ini ditegaskan dalam hadis yang diriwayatkan oleh Imam Tirmidhi:

قَالَتْ الْأَعْرَابُ يَا رَسُولَ اللَّهِ أَلَا نَتَدَاوَى قَالَ "نَعَمْ يَا عِبَادَ اللَّهِ تَدَاوَوْا فَإِنَّ اللَّهَ لَمْ يَضَعْ دَاءً إِلَّا وَضَعَ لَهُ شِفَاءً أَوْ قَالَ دَوَاءً إِلَّا دَاءً وَاحِدًا". قَالُوا يَا رَسُولَ اللَّهِ وَمَا هُوَ قَالَ "الْهَرَمُ"

Artinya: "Orang-orang Badui bertanya: 'Wahai Rasulullah, bolehkah kami berobat?' Beliau menjawab: 'Ya, wahai hamba-hamba Allah, berobatlah! Sesungguhnya Allah tidak menurunkan penyakit, melainkan Dia juga menurunkan penawarnya (obatnya), kecuali satu penyakit.' Mereka bertanya: 'Penyakit apa itu wahai Rasulullah?' Beliau menjawab: 'Tua (pikun).'" (Jami' at-Tirmidhi No. 2038).

Salah satu bentuk implementasi dari perintah "berobatlah" (*tadavvu*) di era modern adalah melalui upaya deteksi dini dan diagnosis yang akurat. Deteksi

penyakit merupakan langkah awal yang krusial sebelum pengobatan dapat diberikan. Tanpa diagnosis yang tepat, ikhtiar pengobatan mungkin tidak akan efektif. Di sinilah peran ilmu pengetahuan dan teknologi menjadi sangat vital. Manusia dianugerahi akal oleh Allah SWT untuk terus berinovasi, termasuk menciptakan teknologi pencitraan medis seperti *Magnetic Resonance Imaging* (MRI) yang mampu melihat ke dalam struktur otak tanpa pembedahan.

Penelitian ini, yang menerapkan metode komputasi cerdas menggunakan *Gray Level Run Length Matrix* (GLRLM) dan *Support Vector Machine* (SVM) untuk mengidentifikasi jenis tumor otak, merupakan wujud nyata dari ikhtiar manusia dalam meningkatkan kualitas diagnosis medis. Pemanfaatan teknologi kecerdasan buatan untuk membedakan antara otak normal, *glioma*, *meningioma*, dan *pituitary* bertujuan untuk membantu tenaga medis mengambil keputusan yang lebih cepat dan tepat. Hal ini sejalan dengan semangat syariat Islam yang mendorong umatnya untuk memberikan manfaat sebesar-besarnya bagi kehidupan manusia (*hifz an-nafs* atau menjaga jiwa).

Dengan demikian, pengembangan sistem identifikasi tumor otak ini tidak hanya bernilai akademis, tetapi juga bernilai ibadah sebagai bentuk kontribusi dalam mempermudah proses pengobatan sesama manusia. Upaya menggabungkan kecanggihan teknologi dengan ilmu kedokteran adalah manifestasi dari rasa syukur atas akal yang diberikan Allah, sekaligus pelaksanaan perintah Rasulullah SAW untuk terus berikhtiar mencari kesembuhan dengan cara-cara terbaik yang dimungkinkan oleh zaman.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan penelitian yang telah dilakukan mengenai identifikasi tumor otak melalui analisis tekstur citra MRI menggunakan metode GLRLM dan SVM, didapatkan bahwa:

1. Diperoleh hasil penyebaran validitas dengan akurasi, presisi, sensitivitas, spesifisitas, dan F1-Score mencapai 100%, sistem prediksi SVM berhasil mengklasifikasikan citra tumor otak dengan tingkat keakuratan yang tinggi, menunjukkan kualitas prediksi yang sangat baik.
2. Berdasarkan analisis karakteristik tekstur pada masing-masing kelas citra, kelas Normal memiliki permukaan halus dengan pola homogen; kelas Glioma didominasi permukaan kasar dengan intensitas tinggi; kelas Meningioma memiliki karakteristik mirip normal namun lebih kasar pada Short Run; dan kelas Pituitary memiliki permukaan sangat halus dengan Run Percentage yang sangat tinggi.

5.2 Saran

Adapun saran dalam penelitian yang dapat penulis sampaikan yaitu penggunaan data primer dari rumah sakit untuk menguji variabilitas alat, penerapan metode segmentasi otomatis untuk meningkatkan presisi pemotongan citra (ROI), serta penambahan variasi data untuk klasifikasi tingkat keganasan tumor agar sistem menjadi lebih komprehensif.

DAFTAR PUSTAKA

- A.Harshavardhan, Babu, S., & Venugopal, T. (2017). Analysis of Feature Extraction Methods for the Classification of Brain Tumor Detection. *International Journal of Pure and Applied Mathematics*, Volume 117(No. 7), 147–155. <https://acadpubl.eu/jsi/2017-117-7/articles/7/16.pdf>
- Alam, M. M. (2023). *Brief Note on Magnetic Resonance Imaging*. 15(6), 119–120. [https://doi.org/10.47532/1755-5191.2023.15\(6\).119-120](https://doi.org/10.47532/1755-5191.2023.15(6).119-120)
- AvazBeigi, M., & Ghazizadeh-Ahsaei, M. (2025). A Complete Preprocessing Pipeline for Brain Tumor Classification and Overall Survival Prediction Using Bidirectional Convolutional LSTM. *SN Computer Science*, 6. <https://doi.org/10.1007/s42979-024-03569-8>
- Ayadi, W., Elhamzi, W., Charfi, I., & Atri, M. (2021). Deep CNN for Brain Tumor Classification. *Neural Processing Letters*, 53(1), 671–700. <https://doi.org/10.1007/s11063-020-10398-2>
- Basthikodi, M., Chaithrashree, M., Ahamed Shafeeq, B. M., & Gурpur, A. P. (2024). Enhancing multiclass brain tumor diagnosis using SVM and innovative feature extraction techniques. *Scientific Reports*, 14(1), 1–15. <https://doi.org/10.1038/s41598-024-77243-7>
- Bebyn, M. G., Furtak, J., Kowalewski, J., & Sledzi, P. (2021). *Prognostic and Predictive Biomarkers in Gliomas*. 1–32.
- Bhusnurmath, R. A., & Doddamani, S. (2024). *Texture Feature Extraction and Classification Using Machine Learning Techniques BT - Advances in Computing and Information* (N. R. Shetty, N. H. Prasad, & N. Nalini (eds.); pp. 509–520). Springer Nature Singapore.
- Bruno, M. A., Walker, E. A., & Abujudeh, H. H. (2015). Understanding and Confronting Our Mistakes: The Epidemiology of Error in Radiology and Strategies for Error Reduction. *Radiographics : A Review Publication of the Radiological Society of North America, Inc*, 35(6), 1668–1676. <https://doi.org/10.1148/rg.2015150023>
- Chu, A., Sehgal, C. M., & Greenleaf, J. F. (1990). Use of gray value distribution of run lengths for texture analysis. *Pattern Recognition Letters*, 11(6), 415–419. [https://doi.org/10.1016/0167-8655\(90\)90112-F](https://doi.org/10.1016/0167-8655(90)90112-F)
- Dheepak, G., J, A. C., & Vaishali, D. (2023). Brain tumor classification: a novel approach integrating GLCM, LBP and composite features. *Frontiers in Oncology*, 13(January), 1–12. <https://doi.org/10.3389/fonc.2023.1248452>
- Durgamahanthi, V., Anita Christaline, J., & Shirley Edward, A. (2021). *GLCM and GLRLM Based Texture Analysis: Application to Brain Cancer Diagnosis*

Using Histopathology Images BT - Intelligent Computing and Applications (S. S. Dash, S. Das, & B. K. Panigrahi (eds.); pp. 691–706). Springer Singapore.

Goldbrunner, R., Minniti, G., Preusser, M., Jenkinson, M. D., Sallabanda, K., Houdart, E., von Deimling, A., Stavrinou, P., Lefranc, F., Lund-Johansen, M., Moyal, E. C.-J., Brandsma, D., Henriksson, R., Soffietti, R., & Weller, M. (2016). EANO guidelines for the diagnosis and treatment of meningiomas. *The Lancet Oncology*, 17(9), e383–e391. [https://doi.org/https://doi.org/10.1016/S1470-2045\(16\)30321-7](https://doi.org/https://doi.org/10.1016/S1470-2045(16)30321-7)

Hanahan, D. (2022). Hallmarks of Cancer: New Dimensions. *Cancer Discovery*, 12(1), 31–46. <https://doi.org/10.1158/2159-8290.CD-21-1059>

Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 12(1), 1–9. <https://doi.org/10.1038/s41598-022-09954-8>

Hosny, A., Parmar, C., Coroller, T. P., Grossmann, P., Zeleznik, R., Kumar, A., Bussink, J., Gillies, R. J., Mak, R. H., & Aerts, H. J. W. L. (2018). Deep learning for lung cancer prognostication: A retrospective multi-cohort radiomics study. *PLoS Medicine*, 15(11), 1–25. <https://doi.org/10.1371/journal.pmed.1002711>

Hui, S. C. N., Andescavage, N., & Limperopoulos, C. (2025). The Role of Proton Magnetic Resonance Spectroscopy in Neonatal and Fetal Brain Research. *Journal of Magnetic Resonance Imaging*, 61(6), 2404–2424. <https://doi.org/10.1002/jmri.29709>

Jena, B., Nayak, G. K., & Saxena, S. (2021). An empirical study of different machine learning techniques for brain tumor classification and subsequent segmentation using hybrid texture feature. *Machine Vision and Applications*, 33(1), 6. <https://doi.org/10.1007/s00138-021-01262-x>

Kibriya, H., Amin, R., Alshehri, A. H., Masood, M., Alshamrani, S. S., & Alshehri, A. (2022). A Novel and Effective Brain Tumor Classification Model Using Deep Feature Fusion and Famous Machine Learning Classifiers. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/7897669>

Lapointe, S., Perry, A., & Butowski, N. A. (2018). Primary brain tumours in adults. *The Lancet*, 392(10145), 432–446. [https://doi.org/10.1016/S0140-6736\(18\)30990-5](https://doi.org/10.1016/S0140-6736(18)30990-5)

Louis, D. N., Perry, A., Wesseling, P., Brat, D. J., Cree, I. A., Soffietti, D., Deimling, A. von, & Ellison, D. W. (2021). The 2021 WHO Classification of Tumors of the Central Nervous System: a summary. *Neuro-Oncology*, 23(8), 1231–1251. <https://doi.org/https://doi.org/10.1093/neuonc/noab106>

- Maldonado, K. A., & Alsayouri, K. (2023). Physiology, Brain. In *StatPearls*. StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK551718/>
- Martucci, M., Russo, R., Schimperna, F., D'Apolito, G., Panfili, M., Grimaldi, A., Perna, A., Ferranti, A. M., Varcasia, G., Giordano, C., & Gaudino, S. (2023). Magnetic Resonance Imaging of Primary Adult Brain Tumors: State of the Art and Future Perspectives. *Biomedicines*, 11(2). <https://doi.org/10.3390/biomedicines11020364>
- Melis, M., Piras, L., Biggio, B., Giacinto, G., Fumera, G., Roli, F., & Department. (2015). Fast Image Classification with Reduced Multiclass Support Vector Machines. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9280, 78–88. <https://doi.org/10.1007/978-3-319-23234-8>
- Melmed, S., Kaiser, U. B., Lopes, M. B., Bertherat, J., Syro, L. V., Raverot, G., Reincke, M., Johannsson, G., Beckers, A., Fleseriu, M., Giustina, A., Wass, J. A. H., & Ho, K. K. Y. (2022). Clinical Biology of the Pituitary Adenoma. *Endocrine Reviews*, 43(6), 1003–1037. <https://doi.org/10.1210/endrev/bnac010>
- MICHEAU, A., & HOA, D. (2025). Anatomy of the encephalon (MRI) in axial slices. *E-Anatomy*, 1–4. <https://doi.org/https://doi.org/10.37019/e-anatomy/49541>
- Molitch, M. E. (2017). Diagnosis and Treatment of Pituitary Adenomas: A Review. *JAMA*, 317(5), 516–524. <https://doi.org/10.1001/jama.2016.19699>
- Mukherjee, A., Paul, A., & Ghosh, K. (2024). Deep learning models for perception of brightness related illusions. *Applied Intelligence*, 54, 10259–10283. <https://doi.org/10.1007/s10489-024-05658-w>
- Munir, R. (2022). *IF4073 Interpretasi dan Pengolahan Citra* (Issue Bagian 1).
- Ogasawara, C., Philbrick, B. D., & Adamson, D. C. (2021). *Meningioma : A Review of Epidemiology , Pathology , Diagnosis , Treatment , and Future Directions*.
- Onyije, F. M., Dolatkhah, R., Olsson, A., Bouaoun, L., Deltour, I., Erdmann, F., Bonaventure, A., Scheurer, M. E., Clavel, J., & Schüz, J. (2024). Risk factors for childhood brain tumours: A systematic review and meta-analysis of observational studies from 1976 to 2022. *Cancer Epidemiology*, 88, 102510. <https://doi.org/10.1016/j.canep.2023.102510>
- Ostrom, Q. T., Price, M., Neff, C., Cioffi, G., Waite, K. A., Kruchko, C., & Barnholtz-Sloan, J. S. (2022). CBTRUS Statistical Report: Primary Brain and Other Central Nervous System Tumors Diagnosed in the United States in 2015–2019. *Neuro-Oncology*, 25(5), vi1–vi95.

<https://doi.org/https://doi.org/10.1093/neuonc/noac202>

- Park, Y. W., Vollmuth, P., Foltyn-Dumitru, M., Sahm, F., Ahn, S. S., Chang, J. H., & Kim, S. H. (2023). The 2021 WHO Classification for Gliomas and Implications on Imaging Diagnosis: Part 1—Key Points of the Fifth Edition and Summary of Imaging Findings on Adult-Type Diffuse Gliomas. *Journal of Magnetic Resonance Imaging*, 58(3), 677–689. <https://doi.org/10.1002/jmri.28743>
- Prihantono, Rusli, R., Christeven, R., & Faruk, M. (2023). Cancer Incidence and Mortality in a Tertiary Hospital in Indonesia: An 18-Year Data Review. *Ethiopian Journal of Health Sciences*, 33(3), 515–522. <https://doi.org/10.4314/ejhs.v33i3.15>
- Saba, T. (2020). Recent advancement in cancer detection using machine learning: Systematic survey of decades, comparisons and challenges. *Journal of Infection and Public Health*, 13(9), 1274–1289. <https://doi.org/10.1016/j.jiph.2020.06.033>
- Saminu, S., Xu, G., Shuai, Z., El Kader, I. A., Jabire, A. H., Ahmed, Y. K., Karaye, I. A., & Ahmad, I. S. (2021). A recent investigation on detection and classification of epileptic seizure techniques using eeg signal. *Brain Sciences*, 11(5). <https://doi.org/10.3390/brainsci11050668>
- Sarker, S. (2024). Transfer Learning and Explainable AI for Brain Tumor Classification: A Study Using MRI Data from Bangladesh. *2024 6th International Conference on Sustainable Technologies for Industry 5.0, STI 2024*. <https://doi.org/10.1109/STI64222.2024.10951092>
- Singh, N. (2023). *Sigmoid to Success: Unveiling Logistic Regression with OVR/OVA*. AI Mind. <https://pub.aimind.so/sigmoid-to-success-unveiling-logistic-regression-with-ovr-ova-e56b17c93254>
- Sollmann, N., Fuderer, M., Cramer, F., Weingärtner, S., Baeßler, B., Gulani, V., Keenan, K. E., Mandija, S., Golay, X., & deSouza, N. M. (2025). Color Maps: Facilitating the Clinical Impact of Quantitative MRI. *Journal of Magnetic Resonance Imaging*, 61(4), 1572–1579. <https://doi.org/10.1002/jmri.29573>
- Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F. (2021). Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians*, 71(3), 209–249. <https://doi.org/10.3322/caac.21660>
- Weller, M., van den Bent, M., Preusser, M., Le Rhun, E., Tonn, J. C., Minniti, G., Bendszus, M., Balana, C., Chinot, O., Dirven, L., French, P., Hegi, M. E., Jakola, A. S., Platten, M., Roth, P., Rudà, R., Short, S., Smits, M., Taphoorn, M. J. B., ... Wick, W. (2021). EANO guidelines on the diagnosis and treatment

of diffuse gliomas of adulthood. *Nature Reviews Clinical Oncology*, 18(3), 170–186. <https://doi.org/10.1038/s41571-020-00447-z>

Zhang, H., Hung, C. L., Min, G., Guo, J. P., Liu, M., & Hu, X. (2019). GPU-Accelerated GLRLM Algorithm for Feature Extraction of MRI. *Scientific Reports*, 9(1), 1–13. <https://doi.org/10.1038/s41598-019-46622-w>

LAMPIRAN

Lampiran 1 Data Hasil Ekstraksi Fitur GLRLM dan Klasifikasi SVM

a. Data Training

No.	Average Fitur GLRLM							Kelas
	SRE	LRE	GLN	RLN	LGRE	HGRE	RP	
1	1.158578	14.03078	130.6514	356.2766	0.265761	88.8411	0.863619	0
2	1.339825	6.761222	186.1939	670.4258	0.192776	113.0143	1.135031	0
3	1.227047	10.75746	166.1843	454.0455	0.271174	69.61119	0.95679	0
4	1.151125	70.57218	146.6286	195.7133	0.377976	48.09843	0.566551	0
5	1.177801	20.57391	220.5976	327.5456	0.221537	85.01734	0.792052	0
6	1.05811	29.74464	187.4238	223.0483	0.392868	46.88305	0.681327	0
7	1.287955	12.07185	164.0462	511.1811	0.338102	69.14883	0.972994	0
8	1.495232	4.791314	213.152	1018.92	0.153242	134.7918	1.326775	0
9	1.485046	4.545503	196.1582	1004.418	0.176639	114.3931	1.328125	0
10	1.155128	20.30582	149.4587	302.7584	0.436165	53.68011	0.771798	0
11	1.342958	6.154633	297.1137	705.0153	0.23282	56.72623	1.17419	0
12	1.495422	4.75396	208.6183	1022.613	0.141361	143.6151	1.330826	0
13	1.119705	67.95455	141.0554	164.4432	0.428417	43.06108	0.527392	0
14	1.088507	33.3935	260.1962	216.3901	0.367226	33.56839	0.654321	0
15	1.28106	10.71126	190.8004	506.3808	0.250363	64.48465	0.975694	0
16	1.282763	14.96708	181.623	468.3049	0.179767	96.08072	0.91358	0
17	1.11743	70.18544	202.2294	172.1566	0.411077	33.21841	0.543596	0
18	1.172325	18.75707	185.3348	338.9514	0.344945	48.95318	0.816358	0
19	1.385292	7.451174	196.2441	725.5374	0.189783	99.14153	1.144483	0
20	1.124203	18.00268	158.5716	311.53	0.332281	62.52862	0.806906	0
21	1.273216	14.12734	210.2055	464.3531	0.230538	70.21172	0.916281	0
22	1.05903	17.99618	128.2586	255.2214	0.322194	65.65935	0.759645	0
23	1.003645	24.85515	170.1706	200.8315	0.257636	74.73712	0.681327	0
24	1.156012	18.57532	191.0517	317.4315	0.359039	45.34936	0.796103	0
25	1.074207	72.66667	134.9986	160.0208	0.326087	63.11528	0.538194	0
26	1.06039	30.79167	202.0075	226.7094	0.483241	31.17415	0.684028	0
27	1.156684	22.03477	110.563	308.3374	0.272522	108.1194	0.770448	0
28	1.451348	4.672766	170.6066	937.4943	0.162289	152.0727	1.30652	0
29	1.045961	14.47679	130.8634	274.5893	0.401037	63.29554	0.808256	0
30	1.3216	15.92598	170.7002	521.0627	0.222759	79.77568	0.945988	0
31	1.168885	12.59824	189.258	383.3746	0.204326	89.13019	0.897377	0
32	1.43658	5.1404	176.4678	885.7633	0.17507	128.7608	1.268711	0
33	1.259914	10.11528	276.0757	515.7118	0.242298	57.4901	1.006752	0
34	1.245235	16.70647	195.432	411.0601	0.373919	47.50829	0.866319	0

35	1.23464	13.32868	214.9729	442.3012	0.256242	70.24109	0.923032	0
36	1.245235	16.70647	195.432	411.0601	0.373919	47.50829	0.866319	0
37	1.105422	13.91345	198.5504	328.4164	0.272342	58.0395	0.855517	0
38	1.13165	24.35098	147.0343	276.3578	0.325402	72.41863	0.740741	0
39	1.387013	5.974676	154.6637	768.8077	0.185424	130.6873	1.198495	0
40	1.191689	9.76138	191.4736	440.6597	0.288662	60.45448	0.971644	0
41	0.997525	31.02283	159.9258	184.3196	0.45477	53.9258	0.643519	0
42	0.979366	19.14538	142.4077	225.1125	0.331001	62.32908	0.73939	0
43	1.257172	10.03107	172.5947	494.7355	0.270105	68.24205	0.986497	0
44	1.473339	4.05176	193.9912	1011.639	0.13907	157.7013	1.356481	0
45	1.220179	28.44369	141.8515	325.8995	0.364688	67.61456	0.747492	0
46	1.248948	10.42972	200.5644	480.6519	0.302779	60.96266	0.974344	0
47	1.303115	7.59375	228.5358	605.3783	0.281498	59.71549	1.08912	0
48	1.118667	22.70693	143.401	269.4639	0.206707	92.27228	0.733989	0
49	1.076316	26.43085	102.2628	224.3223	0.372429	101.8543	0.686728	0
50	1.142425	17.59091	109.33	308.6127	0.33744	92.71545	0.794753	0
51	1.208528	12.47163	140.7293	433.1212	0.180486	183.7538	0.932485	1
52	1.163855	12.84435	92.37339	374.1177	0.208703	173.9605	0.889275	1
53	1.189495	11.94962	149.1565	423.5469	0.164216	180.3076	0.936535	1
54	1.238008	11.45414	192.8744	457.5726	0.158726	253.0248	0.950039	1
55	1.174842	11.70469	118.6492	396.3547	0.216628	135.6398	0.916281	1
56	1.182426	10.99696	121.3174	416.3071	0.190647	155.1712	0.939236	1
57	1.154129	10.93769	147.1438	394.7531	0.167772	155.6946	0.929784	1
58	1.259685	8.992497	169.4918	539.954	0.156549	170.0075	1.04186	1
59	1.110014	11.85285	154.8916	364.2729	0.191189	174.2366	0.905478	1
60	1.250349	10.83721	150.7028	487.6563	0.175817	219.165	0.981096	1
61	1.224304	13.64936	145.4688	417.6254	0.145753	167.8938	0.897377	1
62	1.14868	9.221821	177.6004	437.7796	0.187356	177.5455	0.986497	1
63	1.135245	11.01357	152.0385	411.9325	0.177706	163.1516	0.947338	1
64	1.216218	9.289886	127.1332	478.9829	0.171497	251.8796	1	1
65	1.262601	9.821429	121.925	505.8764	0.162291	211.7593	0.997299	1
66	1.332634	7.25574	151.6728	645.2825	0.154611	215.6422	1.110725	1
67	1.118116	12.46072	152.7684	343.268	0.135786	292.5131	0.877122	1
68	1.204103	10.87239	144.059	442.3231	0.162506	247.7843	0.95679	1
69	1.183318	10.40253	171.4993	430.2046	0.16067	160.4487	0.959491	1
70	1.21857	12.42547	140.0054	426.9907	0.141624	228.4682	0.921682	1
71	1.075089	15.97924	99.94856	282.074	0.266966	159.2446	0.800154	1
72	0.980032	18.1216	138.2636	226.0924	0.162664	188.3881	0.746142	1

73	1.078796	14.67622	117.0616	301.3238	0.215476	119.2977	0.829861	1
74	1.25397	10.82055	132.2395	493.2659	0.154556	299.2699	0.985147	1
75	0.929416	18.76529	181.3047	220.5192	0.169493	148.4606	0.73669	1
76	1.201064	8.058172	179.7445	484.0339	0.135301	276.4508	1.027006	1
77	1.258095	8.521233	172.4979	530.4192	0.134352	271.2459	1.037809	1
78	1.204849	11.37255	186.0475	435.8888	0.158546	185.4442	0.947338	1
79	1.092562	11.96278	190.6982	341.5801	0.138323	185.8471	0.886574	1
80	1.200981	11.10134	168.4314	441.0302	0.148388	228.0708	0.95814	1
81	1.308926	6.636307	191.0044	635.027	0.116091	234.6024	1.126929	1
82	1.12933	13.49265	108.6397	353.3129	0.225875	141.2508	0.878472	1
83	0.911558	18.72278	92.8619	201.1673	0.279172	123.8014	0.721836	1
84	1.114952	15.18439	111.3302	324.8864	0.232759	128.9322	0.839313	1
85	1.070527	12.73471	136.8686	325.6029	0.208411	140.5182	0.86902	1
86	1.154361	11.03834	99.31825	397.1979	0.190166	197.2109	0.932485	1
87	1.13488	11.73622	108.5252	373.9531	0.176601	241.4386	0.909529	1
88	1.13861	11.41199	146.6472	381.3107	0.18971	116.2142	0.918981	1
89	1.295553	8.913863	158.7746	578.2904	0.152732	226.4381	1.055363	1
90	1.217733	11.53343	196.7105	438.0228	0.157524	254.8138	0.940586	1
91	1.219765	10.84118	131.3228	459.0471	0.186222	169.4022	0.970293	1
92	1.162562	9.394315	186.5066	432.1035	0.142496	249.8535	0.978395	1
93	1.358696	8.120382	125.2911	673.0914	0.147706	257.8745	1.112076	1
94	1.151486	10.35281	147.6442	400.077	0.166596	211.8445	0.941937	1
95	0.982464	15.38391	106.4963	252.6257	0.226576	129.681	0.790702	1
96	1.241646	8.557479	167.5783	510.696	0.171929	170.5256	1.027006	1
97	1.230011	8.761142	189.4979	499.7848	0.159099	195.2416	1.021605	1
98	1.15405	15.85467	119.8123	336.2682	0.174766	303.6427	0.832562	1
99	1.043667	21.35328	121.3967	248.4546	0.200689	244.3349	0.751543	1
100	1.2481	8.736842	171.8442	515.7278	0.136724	269.4342	1.027006	1
101	1.405093	5.35877	225.6304	820.9265	0.122701	222.3525	1.237654	2
102	1.090779	12.85041	185.6818	329.4905	0.204828	99.05041	0.86902	2
103	1.191579	11.31677	175.388	442.0504	0.182484	153.1803	0.962191	2
104	1.378071	6.417163	187.7586	748.803	0.130482	216.4523	1.184992	2
105	1.379816	5.675408	250.088	770.3479	0.122471	241.1626	1.210648	2
106	0.941237	31.68527	123.6235	159.851	0.196415	262.4454	0.620563	2
107	1.30238	11.10229	150.9492	538.8237	0.193268	122.7461	0.995949	2
108	1.311766	7.380645	171.9916	617.1597	0.163527	183.3413	1.098573	2
109	1.077209	26.86674	131.7593	236.874	0.178771	246.1436	0.705633	2
110	1.137329	14.38533	144.3668	339.5105	0.235701	100.1981	0.852816	2

111	1.328823	7.116308	202.8287	649.1672	0.15309	134.9096	1.120177	2
112	1.428905	5.237345	185.9094	862.1448	0.129362	203.3538	1.252508	2
113	1.255689	7.05599	211.7754	566.4408	0.133952	128.2936	1.08912	2
114	1.415644	5.428328	187.7105	834.345	0.141626	173.3441	1.239005	2
115	1.20983	19.99141	173.3187	375.3677	0.162612	131.4424	0.837963	2
116	1.137915	24.84091	130.8607	278.2658	0.191539	115.0346	0.73534	2
117	1.307876	8.572848	198.5609	598.6891	0.13291	195.0113	1.071566	2
118	1.529443	3.607882	207.5522	1160.327	0.12974	198.8409	1.422647	2
119	1.228632	15.36275	134.8358	408.9297	0.206051	124.2574	0.878472	2
120	1.215327	9.412981	173.4686	474.9404	0.174137	138.1334	0.99865	2
121	1.429045	4.709836	233.2169	891.6423	0.119586	228.0607	1.287616	2
122	1.180905	15.60583	236.6058	369.0708	0.186553	117.6758	0.862269	2
123	1.451143	4.886587	218.5229	923.0297	0.148318	165.2514	1.290316	2
124	1.244097	11.66298	157.6925	483.0479	0.186758	147.2028	0.967593	2
125	1.485386	4.753739	217.1191	994.5059	0.122722	208.0208	1.315972	2
126	1.511513	4.847208	214.7835	1050.693	0.138891	187.3251	1.333526	2
127	1.423889	5.651602	245.3678	839.4165	0.10888	173.8072	1.232253	2
128	1.336535	6.896894	213.905	672.086	0.137603	221.9497	1.139082	2
129	1.278678	8.352863	168.034	567.9451	0.181014	147.1924	1.066165	2
130	1.288064	12.95407	155.3267	508.5826	0.166268	174.7815	0.963542	2
131	1.198631	12.08502	188.5952	412.5402	0.175224	131.0164	0.917631	2
132	1.110289	14.05372	231.3479	349.05	0.155202	143.4868	0.86902	2
133	1.350696	7.879594	168.9651	669.9718	0.157869	183.9994	1.117477	2
134	1.06868	22.74197	180.5019	288.8578	0.216055	174.7854	0.766397	2
135	1.119111	19.05993	152.8348	336.8048	0.199772	164.4991	0.840664	2
136	0.941237	31.68527	123.6235	159.851	0.196415	262.4454	0.620563	2
137	1.065195	25.01423	159.0152	245.4004	0.234965	170.3974	0.716435	2
138	1.009146	24.98596	148.6598	207.4887	0.196959	240.595	0.677276	2
139	1.074338	20.51229	134.7779	271.8275	0.208851	165.0992	0.766397	2
140	1.164873	13.18289	133.6413	400.3395	0.210125	137.5754	0.91223	2
141	1.054998	18.2817	129.3179	284.529	0.220222	139.3252	0.797454	2
142	1.442275	6.697892	190.6036	842.0422	0.148191	165.8448	1.205247	2
143	1.451196	8.316364	234.9836	822.1936	0.138404	186.4576	1.166088	2
144	1.496545	4.290541	203.4465	1041.979	0.137331	188.6232	1.35108	2
145	1.141353	16.5993	91.2047	328.6237	0.27934	142.142	0.82716	2
146	1.263019	13.11596	157.0233	480.4608	0.1624	179.0173	0.948688	2
147	1.049407	17.67751	115.9619	264.8374	0.25083	120.7388	0.778549	2
148	1.077209	26.86674	131.7593	236.874	0.178771	246.1436	0.705633	2

149	1.137329	14.38533	144.3668	339.5105	0.235701	100.1981	0.852816	2
150	1.415839	5.413408	208.0508	856.6897	0.1419	167.0453	1.26061	2
151	1.19107	9.760294	124.3875	439.4625	0.15239	170.2051	0.970293	3
152	1.341053	6.153753	157.704	696.3614	0.175557	144.6774	1.167438	3
153	1.218224	10.20468	130.1864	461.5409	0.201208	123.9613	0.975694	3
154	1.241558	7.888211	126.3896	525.2148	0.172511	154.9289	1.048611	3
155	1.233608	9.896952	121.1401	474.8915	0.201219	130.1415	0.982446	3
156	1.355954	6.437805	140.2579	704.4915	0.163519	158.9823	1.159336	3
157	1.289917	9.919718	129.0641	537.4683	0.215258	146.5289	1.010802	3
158	1.355143	7.559126	129.1716	662.8014	0.144272	203.4467	1.102623	3
159	1.22484	9.058205	129.8198	495.6392	0.201931	127.8927	1.014853	3
160	1.316951	7.683226	130.7323	622.6739	0.17938	157.4961	1.098573	3
161	1.310058	7.566406	125.9004	608.3997	0.160053	168.9889	1.08912	3
162	1.358909	5.82619	180.4137	728.0262	0.150974	147.9542	1.186343	3
163	1.308032	6.696721	194.6198	630.9568	0.148227	128.3272	1.122878	3
164	1.331378	7.585382	127.2102	632.9829	0.169294	167.2283	1.095872	3
165	1.281885	7.210117	153.3353	587.7539	0.165959	159.6725	1.093171	3
166	1.365904	6.506699	141.6681	716.3054	0.168034	180.2844	1.160687	3
167	1.321942	6.738095	134.3102	649.1767	0.172861	195.9217	1.12963	3
168	1.417401	4.782249	175.1681	867.4859	0.150355	185.8275	1.276813	3
169	1.348853	6.06506	169.691	707.7729	0.149676	171.1078	1.17284	3
170	1.244173	8.567175	139.3677	512.7902	0.185401	151.7888	1.027006	3
171	1.367081	6.02503	144.1925	736.1922	0.160668	157.1722	1.184992	3
172	1.306783	9.205075	131.1077	568.9482	0.220163	151.5933	1.036458	3
173	1.256109	8.215447	162.8394	536.9905	0.18909	114.9722	1.048611	3
174	1.319761	6.294335	164.4526	661.165	0.152414	166.8048	1.148534	3
175	1.347321	6.397041	135.1091	686.586	0.172976	158.7367	1.147184	3
176	1.314819	8.495302	124.0826	590.6252	0.157604	191.143	1.058063	3
177	1.33041	6.533993	147.6755	667.9842	0.142139	187.6854	1.144483	3
178	1.323205	7.747112	137.3575	632.4387	0.150827	182.9442	1.103974	3
179	1.353456	6.023381	168.551	716.8759	0.155519	147.8483	1.178241	3
180	1.333117	7.359335	137.9431	643.7596	0.137045	183.3216	1.108025	3
181	1.247797	7.819892	160.1176	536.4328	0.160146	163.6015	1.056713	3
182	1.432436	5.324126	130.3782	864.7754	0.182107	177.4718	1.249807	3
183	1.38264	5.563805	177.4194	778.3005	0.147539	166.9878	1.216049	3
184	1.110016	11.00312	123.4447	371.2251	0.217764	116.8341	0.918981	3
185	1.347682	6.528256	140.8249	689.9957	0.159939	160.621	1.151235	3
186	1.435354	4.838992	163.8834	897.6974	0.145392	192.0849	1.284915	3

187	1.328098	6.054005	176.3392	681.6814	0.149328	160.7664	1.164738	3
188	1.298209	8.098545	140.4015	587.5754	0.158897	186.7216	1.072917	3
189	1.300207	7.587696	171.1198	596.0641	0.185853	120.4967	1.083719	3
190	1.350007	7.715561	151.9688	663.1486	0.124291	189.6218	1.110725	3
191	1.291186	7.83727	167.6581	587.9646	0.181259	122.7526	1.081019	3
192	1.234715	9.24539	111.0433	491.2401	0.213876	140.9468	1.004051	3
193	1.256595	9.072028	101.328	515.7129	0.195172	196.6566	1.017554	3
194	1.335575	6.09988	165.2341	698.4113	0.160008	142.2329	1.17419	3
195	1.454047	4.686624	147.6305	938.7619	0.147033	191.3565	1.303819	3
196	1.318859	6.401356	170.6702	661.5897	0.135819	210.3866	1.147184	3
197	1.192679	10.43437	109.486	443.5413	0.187703	177.9993	0.967593	3
198	1.241175	9.746043	119.0295	485.0637	0.187895	158.0856	0.990548	3
199	1.282856	8.312081	129.4195	564.1238	0.217542	121.9161	1.058063	3
200	1.350602	7.484655	110.1017	661.1432	0.182769	194.8024	1.108025	3

b. *Data Testing*

No.	Average Fitur GLRLM							Kelas
	SRE	LRE	GLN	RLN	LGRE	HGRE	RP	
1	1.234373	9.820313	204.5618	496.4347	0.166228	96.60724	1.002701	0
2	0.965497	27.23661	162.2578	180.4163	0.363146	54.94978	0.657022	0
3	0.916797	39.50387	206.7101	134.2564	0.54197	31.27191	0.576003	0
4	1.27838	10.90511	139.4591	505.3018	0.315617	80.23285	0.977045	0
5	1.269457	7.822667	188.138	557.5887	0.214787	89.20467	1.064815	0
6	1.127008	41.85412	146.5071	217.8794	0.403732	60.92588	0.625965	0
7	1.519754	3.949546	185.5474	1114.507	0.144319	160.6191	1.390239	0
8	1.260015	23.77449	171.8235	415.8041	0.294786	55.77618	0.851466	0
9	1.067091	20.25337	200.7428	257.1103	0.375546	43.84875	0.752894	0
10	1.303004	12.32731	203.1669	533.2204	0.285754	56.86633	0.986497	0
11	1.023712	25.75942	191.8969	193.9263	0.279566	65.9102	0.661073	0
12	1.483661	4.21488	215.5728	1020.867	0.146028	149.7102	1.34973	0
13	1.310534	6.39555	243.3443	651.6134	0.201091	98.50371	1.144483	0
14	0.971377	18.94522	229.8795	213.8506	0.30516	42.02291	0.729938	0
15	1.034868	22.16171	194.7847	243.62	0.257558	66.85218	0.732639	0
16	1.236445	9.25389	152.0191	493.3554	0.137303	278.4208	1.006752	1
17	1.108245	12.49594	215.5771	346.5584	0.127999	333.5576	0.883873	1
18	1.23787	9.060501	175.0452	508.4823	0.166783	186.2524	1.022955	1
19	1.209166	10.85618	170.5894	444.8379	0.120832	293.9486	0.95814	1
20	1.114961	20.359	154.1475	291.07	0.158748	331.0863	0.7799	1

21	1.144135	17.23112	112.6394	316.9595	0.202141	198.3444	0.802855	1
22	0.988576	14.88788	111.1926	257.8594	0.261306	104.3535	0.798804	1
23	1.159707	10.57599	142.747	405.2675	0.186776	171.6436	0.940586	1
24	1.258275	9.45582	156.7482	516.5754	0.143006	232.4088	1.014853	1
25	1.269504	7.6187	186.2911	561.0458	0.115834	273.9251	1.070216	1
26	1.095639	11.48071	177.1568	343.2436	0.14805	150.4944	0.891975	1
27	1.303026	7.614691	193.9117	613.0966	0.116821	227.3318	1.099923	1
28	1.119378	11.56778	146.9689	361.9725	0.190788	133.3612	0.898727	1
29	1.053243	14.92349	207.1664	279.8336	0.144488	222.9564	0.810957	1
30	1.155132	13.02751	120.8859	371.7832	0.167488	302.2516	0.886574	1
31	1.238705	12.449	129.1584	443.2709	0.247427	112.3053	0.925733	2
32	0.962512	35.36331	89.86451	161.4347	0.225146	143.6103	0.615162	2
33	1.034138	31.70205	132.7386	191.4874	0.206817	196.3642	0.643519	2
34	0.952158	33.97349	182.712	156.9331	0.192414	382.341	0.612461	2
35	1.153717	38.84066	132.3022	247.5214	0.223186	226.9659	0.666474	2
36	1.220938	10.84269	222.0761	458.1784	0.180646	204.4276	0.966242	2
37	1.423889	5.651602	245.3678	839.4165	0.10888	173.8072	1.232253	2
38	1.168929	18.21404	154.1605	339.6307	0.169876	193.6026	0.821759	2
39	1.078586	23.73148	147.5051	236.3961	0.215401	211.8796	0.708333	2
40	1.496545	4.290541	203.4465	1041.979	0.137331	188.6232	1.35108	2
41	0.87247	26.96767	146.6085	161.1761	0.190625	198.1882	0.636767	2
42	1.384816	6.123068	182.418	757.3725	0.145304	181.11	1.187693	2
43	1.232966	25.90189	121.7651	344.6528	0.210307	287.7726	0.767747	2
44	1.155411	12.6126	202.9504	385.8366	0.162848	122.963	0.909529	2
45	1.36731	10.14625	107.5593	656.3389	0.278539	147.5329	1.076968	2
46	1.330327	6.974747	155.762	651.0631	0.169341	158.0372	1.121528	3
47	1.334129	7.983681	161.5242	628.9641	0.169691	145.6678	1.08642	3
48	1.387615	6.715591	127.4074	739.9997	0.157809	196.7862	1.160687	3
49	1.352799	6.306334	143.3002	701.845	0.154704	191.6242	1.160687	3
50	1.365733	6.330909	128.1715	719.6712	0.235738	148.0842	1.166088	3
51	1.314316	7.266026	140.3276	624.1006	0.156432	189.5712	1.105324	3
52	1.343288	6.717933	166.8213	673.991	0.157307	156.3032	1.136381	3
53	1.330244	7.994118	139.385	624.3761	0.173986	144.2843	1.085069	3
54	1.367492	7.336025	153.5671	701.9904	0.176805	143.5323	1.139082	3
55	1.386776	6.001777	159.8383	762.856	0.15541	187.3169	1.191744	3
56	1.282856	8.312081	129.4195	564.1238	0.217542	121.9161	1.058063	3
57	1.397682	5.94208	123.8292	777.4521	0.170406	203.5644	1.194444	3
58	1.334129	7.983681	161.5242	628.9641	0.169691	145.6678	1.08642	3

59	1.36351	6.54823	136.1532	711.4863	0.181282	158.1166	1.157986	3
60	1.259281	9.891643	126.2146	510.4561	0.176789	158.9653	1.005401	3

Lampiran 2 Data Karakteristik Tekstur Masing-Masing Citra

a. Data Training

No.	Karakteristik Tekstur Citra							Kelas
	SRE	LRE	GLN	RLN	LGRE	HGRE	RP	
1	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
2	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	0
3	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
4	Kasar	Kasar	Homogen	Homogen	Banyak	Sedikit	Rendah	0
5	Kasar	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	0
6	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
7	Halus	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
8	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	0
9	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	0
10	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
11	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	0
12	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	0
13	Kasar	Kasar	Homogen	Homogen	Banyak	Sedikit	Rendah	0
14	Kasar	Halus	Heterogen	Homogen	Banyak	Sedikit	Rendah	0
15	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	0
16	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
17	Kasar	Kasar	Heterogen	Homogen	Banyak	Sedikit	Rendah	0
18	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
19	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	0
20	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
21	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	0
22	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
23	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
24	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
25	Kasar	Kasar	Homogen	Homogen	Banyak	Sedikit	Rendah	0
26	Kasar	Halus	Heterogen	Homogen	Banyak	Sedikit	Rendah	0
27	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
28	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	0
29	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
30	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0

31	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
32	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	0
33	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Tinggi	0
34	Halus	Halus	Heterogen	Homogen	Banyak	Sedikit	Rendah	0
35	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	0
36	Halus	Halus	Heterogen	Homogen	Banyak	Sedikit	Rendah	0
37	Kasar	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	0
38	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
39	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	0
40	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
41	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
42	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
43	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	0
44	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	0
45	Halus	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
46	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	0
47	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Tinggi	0
48	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
49	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
50	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
51	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
52	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
53	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
54	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
55	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
56	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
57	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
58	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	1
59	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
60	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
61	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
62	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	1
63	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
64	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
65	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
66	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
67	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
68	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1

69	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
70	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
71	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
72	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
73	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
74	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
75	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
76	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
77	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
78	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
79	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
80	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
81	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
82	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
83	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
84	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
85	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
86	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
87	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
88	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
89	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
90	Halus	Halus	Heterogen	Homogen	Sedikit	Banyak	Rendah	1
91	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
92	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
93	Halus	Halus	Homogen	Heterogen	Sedikit	Banyak	Tinggi	1
94	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
95	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
96	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	1
97	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	1
98	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
99	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
100	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
101	Halus	Halus	Heterogen	Heterogen	Sedikit	Banyak	Tinggi	2
102	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
103	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
104	Halus	Halus	Homogen	Heterogen	Sedikit	Banyak	Tinggi	2
105	Halus	Halus	Heterogen	Heterogen	Sedikit	Banyak	Tinggi	2
106	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	2

107	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	2
108	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	2
109	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	2
110	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
111	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
112	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	2
113	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Tinggi	2
114	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	2
115	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
116	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
117	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Tinggi	2
118	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
119	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
120	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	2
121	Halus	Halus	Heterogen	Heterogen	Sedikit	Banyak	Tinggi	2
122	Kasar	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	2
123	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
124	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
125	Halus	Halus	Heterogen	Heterogen	Sedikit	Banyak	Tinggi	2
126	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
127	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
128	Halus	Halus	Heterogen	Heterogen	Sedikit	Banyak	Tinggi	2
129	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	2
130	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
131	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
132	Kasar	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	2
133	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	2
134	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
135	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
136	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	2
137	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
138	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	2
139	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
140	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
141	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
142	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	2
143	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
144	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2

145	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
146	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
147	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
148	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	2
149	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
150	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
151	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	3
152	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
153	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
154	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
155	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
156	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
157	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
158	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
159	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
160	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
161	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
162	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
163	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Tinggi	3
164	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
165	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
166	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
167	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
168	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
169	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
170	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
171	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
172	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
173	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
174	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
175	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
176	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
177	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
178	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
179	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
180	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
181	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
182	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3

183	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
184	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	3
185	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
186	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
187	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
188	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
189	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
190	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
191	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
192	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
193	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
194	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
195	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
196	Halus	Halus	Homogen	Heterogen	Sedikit	Banyak	Tinggi	3
197	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	3
198	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
199	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
200	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3

b. Data Testing

No.	Karakteristik Tekstur Citra							Kelas
	SRE	LRE	GLN	RLN	LGRE	HGRE	RP	
1	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Tinggi	0
2	Kasar	Halus	Homogen	Homogen	Banyak	Sedikit	Rendah	0
3	Kasar	Kasar	Heterogen	Homogen	Banyak	Sedikit	Rendah	0
4	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	0
5	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	0
6	Kasar	Kasar	Homogen	Homogen	Banyak	Sedikit	Rendah	0
7	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	0
8	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
9	Kasar	Halus	Heterogen	Homogen	Banyak	Sedikit	Rendah	0
10	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Tinggi	0
11	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	0
12	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	0
13	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	0
14	Kasar	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	0

15	Kasar	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	0
16	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
17	Kasar	Halus	Heterogen	Homogen	Sedikit	Banyak	Rendah	1
18	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	1
19	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
20	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
21	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
22	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
23	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
24	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
25	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Tinggi	1
26	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
27	Halus	Halus	Heterogen	Homogen	Sedikit	Banyak	Tinggi	1
28	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	1
29	Kasar	Halus	Heterogen	Homogen	Sedikit	Banyak	Rendah	1
30	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	1
31	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
32	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
33	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
34	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	2
35	Kasar	Kasar	Homogen	Homogen	Sedikit	Banyak	Rendah	2
36	Halus	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	2
37	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
38	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
39	Kasar	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	2
40	Halus	Halus	Heterogen	Heterogen	Sedikit	Sedikit	Tinggi	2
41	Kasar	Halus	Homogen	Homogen	Sedikit	Sedikit	Rendah	2
42	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	2
43	Halus	Halus	Homogen	Homogen	Sedikit	Banyak	Rendah	2
44	Kasar	Halus	Heterogen	Homogen	Sedikit	Sedikit	Rendah	2
45	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	2
46	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
47	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
48	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
49	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
50	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
51	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
52	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3

53	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
54	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
55	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
56	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
57	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
58	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3
59	Halus	Halus	Homogen	Heterogen	Sedikit	Sedikit	Tinggi	3
60	Halus	Halus	Homogen	Homogen	Sedikit	Sedikit	Tinggi	3

Lampiran 3 Tampilan Komputasi

a. GUI Matlab





KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
Jalan Gajayana Nomor 50, Telepon (0341) 551354, Fax. (0341) 572533
Website: <http://www.uin-malang.ac.id> Email: info@uin-malang.ac.id

JURNAL BIMBINGAN SKRIPSI/TESIS/DISERTASI

IDENTITAS MAHASISWA

NIM : 220604110023
Nama : MUHAMMAD BAQIBILLAH
Fakultas : SAINS DAN TEKNOLOGI
Jurusan : FISIKA
Dosen Pembimbing 1 : Prof. Dr. Drs.MOKHAMMAD TIRONO,M.Si
Dosen Pembimbing 2 : Drs. H.ABDUL BASID,M.Si
Judul Skripsi/Tesis/Disertasi : IDENTIFIKASI TUMOR OTAK MELALUI ANALISIS TEKSTUR CITRA MAGNETIC RESONANCE IMAGING (MRI) DENGAN METODE GRAY LEVEL RUN LENGTH MATRIX (GLRLM) DAN SUPPORT VECTOR MACHINE (SVM)

IDENTITAS BIMBINGAN

No	Tanggal Bimbingan	Nama Pembimbing	Deskripsi Proses Bimbingan	Tahun Akademik	Status
1	19 September 2025	Prof. Dr. Drs.MOKHAMMAD TIRONO,M.Si	Konsultasi BAB I - III	Ganjil 2025/2026	Sudah Dikoreksi
2	22 September 2025	Prof. Dr. Drs.MOKHAMMAD TIRONO,M.Si	Revisi Bab I - III	Ganjil 2025/2026	Sudah Dikoreksi
3	17 Oktober 2025	Prof. Dr. Drs.MOKHAMMAD TIRONO,M.Si	Konsultasi persiapan Ujian Proposal	Ganjil 2025/2026	Sudah Dikoreksi
4	17 November 2025	Drs. H.ABDUL BASID,M.Si	Konsultasi Integrasi BAB I	Ganjil 2025/2026	Sudah Dikoreksi
5	24 November 2025	Prof. Dr. Drs.MOKHAMMAD TIRONO,M.Si	Konsultasi BAB IV	Ganjil 2025/2026	Sudah Dikoreksi
6	26 November 2025	Prof. Dr. Drs.MOKHAMMAD TIRONO,M.Si	Konsultasi Abstrak dan Bab V	Ganjil 2025/2026	Sudah Dikoreksi
7	28 November 2025	Drs. H.ABDUL BASID,M.Si	Konsultasi Perbaikan BAB I	Genap 2025/2026	Sudah Dikoreksi
8	17 Desember 2025	Drs. H.ABDUL BASID,M.Si	Konsultasi Integrasi BAB II dan BAB IV	Ganjil 2025/2026	Sudah Dikoreksi
9	18 Desember 2025	Prof. Dr. Drs.MOKHAMMAD TIRONO,M.Si	Konsultasi Saran Penambahan Pada Poin Batasan Masalah dan Pembahasan	Genap 2025/2026	Sudah Dikoreksi

Telah disetujui
Untuk mengajukan ujian Skripsi/Tesis/Desertasi

Dosen Pembimbing 2

Drs. H.ABDUL BASID,M.Si

Malang, 18 Desember 2025

Dosen Pembimbing 1

Prof. Dr. Drs.MOKHAMMAD TIRONO,M.Si

