

**KLASIFIKASI JENIS TUMOR OTAK BERDASARKAN CITRA MRI
MENGUNAKAN *GRAY LEVEL CO-OCCURRENCE MATRIX*
(GLCM) DAN *SUPPORT VECTOR MACHINE* (SVM)**

SKRIPSI

Oleh :
YOZA SETYA FEBRIYANTI
NIM. 220605110062



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

**KLASIFIKASI JENIS TUMOR OTAK BERDASARKAN CITRA MRI
MENGUNAKAN *GRAY LEVEL CO-OCCURRENCE MATRIX*
(GLCM) DAN *SUPPORT VECTOR MACHINE* (SVM)**

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh:
YOZA SETYA FEBRIYANTI
NIM. 220605110062

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

HALAMAN PERSETUJUAN

KLASIFIKASI JENIS TUMOR OTAK BERDASARKAN CITRA MRI MENGUNAKAN *GRAY LEVEL CO-OCCURRENCE MATRIX* (GLCM) DAN *SUPPORT VECTOR MACHINE* (SVM)

SKRIPSI

Oleh :
YOZA SETYA FEBRIYANTI
NIM. 220605110062

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 28 November 2025


Pembimbing I,


Okta Qomaruddin Aziz, M.Kom
NIP. 19911019 201903 1 013

Pembimbing II,


Prof. Dr. Suhartono, S.Si., M.Kom
NIP. 19680519 200312 1 001

Mengetahui
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Supriyono, M. Kom
NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

KLASIFIKASI JENIS TUMOR OTAK BERDASARKAN CITRA MRI MENGUNAKAN *GRAY LEVEL CO-OCCURRENCE MATRIX* (GLCM) DAN *SUPPORT VECTOR MACHINE* (SVM)



SKRIPSI

Oleh :
YOZA SETYA FEBRIYANTI
NIM. 220605110062

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 12 Desember 2025

Susunan Dewan Penguji

Ketua Penguji	: <u>Prof. Dr. Muhammad Faisal, M.T</u> NIP. 19740510 200501 1 007
Anggota Penguji I	: <u>Nurizal Dwi Priandani, M.Kom</u> NIP. 19920830 202203 1 001
Anggota Penguji II	: <u>Okta Qomaruddin Aziz, M.Kom</u> NIP. 19911019 201903 1 013
Anggota Penguji III	: <u>Prof. Dr. Suhartono, S.Si., M.Kom</u> NIP. 19680519 200312 1 001

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Suhartono, M. Kom
NIP. 19841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Yoza Setya Febriyanti
NIM : 220605110062
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Klasifikasi Jenis Tumor Otak Berdasarkan Citra MRI Menggunakan *Gray Level Co-Occurrence* (GLCM) dan *Support Vector Machine* (SVM)

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 11 Desember 2025
Yang membuat pernyataan,



Yoza Setya Febriyanti
NIM.220605110062

MOTTO

“maka, sesungguhnya beserta kesulitan ada kemudahan”

(Q.S Al-Insyirah: 5)

HALAMAN PERSEMBAHAN

Segala puji bagi Allah Subhanahu Wa Ta'ala atas rahmat, karunia, dan pertolongan-Nya, sehingga penulis dapat menuntaskan skripsi ini.

Karya ini penulis persembahkan kepada:

Orang Tua Penulis,

Bapak Supani dan Ibu Hasanatun Nasihah

Atas doa yang senantiasa mengiringi, kasih sayang, dan dukungan yang tak pernah putus.

Kakak-Kakak Penulis,

Melly Setya Haryanti dan Dela Ananda Setyarini

Atas bantuan, semangat, dan dukungan yang selalu menguatkan langkah penulis.

Dosen Pembimbing dan Dosen Penguji,

Atas ilmu, arahan, dan bimbingan yang diberikan selama proses penyusunan skripsi.

Teman-Teman Angkatan 22,

Atas kebersamaan dan cerita selama masa perkuliahan.

KATA PENGANTAR

Assalamu'alaikum Wr. Wb.

Alhamdulillah, segala puji dan syukur penulis panjatkan ke hadirat Allah Subhanahu Wa Ta'ala atas rahmat, karunia, dan hidayah-Nya, sehingga skripsi yang berjudul “Klasifikasi Jenis Tumor Otak Berdasarkan Citra MRI Menggunakan *Gray Level Co-Occurrence Matrix* (GLCM) dan *Support Vector Machine* (SVM)” dapat diselesaikan. Sholawat serta salam semoga senantiasa tercurah kepada Nabi Muhammad Shallallahu Alaihi Wasallam, teladan dalam menuntut ilmu, berikhtiar, dan menjaga keikhlasan dalam setiap proses.

Dalam penyusunan skripsi ini, penulis menyadari bahwa banyak pihak telah memberikan doa, bantuan, bimbingan, dan dukungan. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., CAHRM., CRMP selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Supriyono, M.Kom selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Okta Qomaruddin Aziz, M.Kom selaku Dosen Pembimbing I dan Prof. Dr. Suhartono, S.Si., M.Kom selaku Dosen Pembimbing II, yang telah meluangkan waktu dengan penuh kesabaran untuk membimbing,

mengarahkan, serta memberikan masukan yang sangat berharga sejak awal penyusunan hingga skripsi ini terselesaikan.

5. Prof. Dr. Muhammad Faisal, M.T selaku Ketua Penguji dan Nurizal Dwi Priandani, M.Kom selaku Anggota Penguji I, yang telah memberikan saran dan evaluasi yang membangun dalam penyempurnaan skripsi ini.
6. Seluruh Dosen dan Staf Program Studi Teknik Informatika, yang telah memberikan ilmu, pelayanan, serta bantuan administratif selama penulis menempuh perkuliahan.
7. Keluarga penulis, Bapak Supani dan Ibu Hasanatun Nasihah, serta kakak penulis Melly Setya Haryanti dan Dela Ananda Setyarini, yang senantiasa mengiringi penulis dengan doa yang tak putus, kasih sayang, serta dukungan sehingga penulis dapat menapaki setiap proses hingga skripsi ini terselesaikan.
8. Teman-teman terdekat penulis yaitu Gavril Pandita dan Sakila Aulia Maharani, yang telah menemani perjalanan perkuliahan dan penyusunan skripsi melalui kebersamaan, bantuan, serta dukungan yang selalu terasa besar artinya bagi penulis.
9. Teman-Teman Teknik Informatika Angkatan 2022, terutama Firna, Atsila dan Iim yang telah membersamai penulis melalui bantuan dan diskusi selama pengerjaan skripsi.
10. A. Shohibul Aqshal Radanta, yang telah memberikan dukungan serta bantuan dalam berbagai hal selama proses penyusunan skripsi ini.

11. Lailiyah Rahma Dita yang selalu membantu, menemani dan mendukung penulis selama masa perkuliahan.
12. Teman-teman Kamar 39 Fatimah az-Zahra yang telah kebersamai penulis selama masa perkuliahan.
13. Seluruh pihak yang tidak dapat penulis sebutkan satu per satu yang telah membantu penulis, baik secara langsung maupun tidak langsung.
14. Diri sendiri, yang telah berusaha menjaga komitmen, bertahan dalam proses, dan menuntaskan tanggung jawab hingga skripsi ini selesai.

Penulis menyadari skripsi ini masih memiliki keterbatasan. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan demi penyempurnaan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat bagi pembaca dan pengembangan ilmu pengetahuan.

Wassalamu'alaikum Wr, Wb.

Malang, 12 Desember 2025

Penulis

DAFTAR ISI

HALAMAN JUDUL	ii
HALAMAN PERSETUJUAN.....	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO.....	vi
HALAMAN PERSEMBAHAN.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI	xi
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xiv
ABSTRAK.....	xv
ABSTRACT	xvi
مستخلص البحث	xvii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	7
1.5 Manfaat Penelitian	7
BAB II STUDI PUSTAKA	8
2.1 Klasifikasi Tumor Otak.....	8
2.2 Tumor Otak.....	11
2.2.1 <i>Glioma</i>	12
2.2.2 <i>Meningioma</i>	12
2.2.3 <i>Pituitary Tumor</i>	13
2.3 <i>Gray Level Co-Occurrence Matrix (GLCM)</i>	13
2.3.1 <i>Contrast</i>	15
2.3.2 <i>Correlation</i>	15
2.3.3 <i>Energy</i>	16
2.3.4 <i>Homogeneity</i>	16
2.4 <i>Support Vector Machine (SVM)</i>	17
2.4.1 <i>Kernel Linear</i>	20
2.4.2 <i>Kernel Polynomial</i>	20
2.4.3 <i>Kernel Radial Basis Function (RBF)</i>	20
2.4.4 <i>Kernel Sigmoid</i>	21
BAB III METODE PENELITIAN	22
3.1 Alur Penelitian	22
3.2 Pengumpulan Data	23
3.3 Desain Sistem	24
3.4 Preprocessing Citra	26
3.4.1 <i>Cropping</i>	26
3.4.2 <i>Noise Reduction</i>	27
3.4.3 <i>Resize</i>	27
3.5 Ekstraksi Fitur GLCM	28
3.5.1 Pembentukan Matriks <i>Co-Occurrence</i>	29
3.5.2 Normalisasi	31
3.5.3 Ekstraksi Fitur Tekstur.....	32

3.6 Implementasi Metode SVM	35
3.6.1 Strategi Klasifikasi <i>One vs All</i>	36
3.6.2 Proses Pelatihan Model	36
3.6.3 Proses Prediksi	40
3.7 Evaluasi	42
3.8 Skenario Uji Coba	47
BAB IV HASIL DAN PEMBAHASAN	49
4.1 Hasil Uji Coba	49
4.1.1 Hasil Skenario Uji 1	49
4.1.2 Hasil Skenario Uji 2	51
4.1.3 Hasil Skenario Uji 3	53
4.1.4 Hasil Skenario Uji 4	54
4.1.5 Hasil Skenario Uji 5	56
4.1.6 Hasil Skenario Uji 6	58
4.1.7 Hasil Skenario Uji 7	60
4.1.8 Hasil Skenario Uji 8	61
4.1.9 Hasil Skenario Uji 9	63
4.1.10 Hasil Skenario Uji 10	65
4.1.11 Hasil Skenario Uji 11	67
4.1.12 Hasil Skenario Uji 12	68
4.1.13 Hasil Skenario Uji 13	70
4.1.14 Hasil Skenario Uji 14	72
4.1.15 Hasil Skenario Uji 15	74
4.1.16 Hasil Skenario Uji 16	75
4.1.17 Hasil Skenario Uji 17	77
4.1.18 Hasil Skenario Uji 18	79
4.1.19 Hasil Skenario Uji 19	81
4.1.20 Hasil Skenario Uji 20	82
4.1.21 Hasil Skenario Uji 21	84
4.1.22 Hasil Skenario Uji 22	86
4.1.23 Hasil Skenario Uji 23	88
4.1.24 Hasil Skenario Uji 24	89
4.2 Pembahasan	91
4.2.1 Performa Berdasarkan Keseimbangan Dataset	95
4.2.2 Performa Berdasarkan Sudut Pandang Citra MRI	98
4.2.3 Performa Berdasarkan Jenis Kernel	101
4.3 Integrasi Islam	104
BAB V KESIMPULAN DAN SARAN	107
5.1 Kesimpulan	107
5.2 Saran	108
DAFTAR PUSTAKA	
LAMPIRAN	

DAFTAR GAMBAR

Gambar 2. 1 Sudut pada GLCM	14
Gambar 2. 2 SVM.....	18
Gambar 3. 1 Alur Penelitian	22
Gambar 3. 2 Desain Sistem.....	25
Gambar 3. 3 Hasil <i>Cropping</i>	26
Gambar 3. 4 Hasil <i>Noise Reduction</i>	27
Gambar 3. 5 Hasil <i>Resize</i>	28
Gambar 3. 6 Blok Diagram GLCM.....	29
Gambar 3. 7 Blok Diagram SVM.....	35
Gambar 4. 1 <i>Confusion matrix</i> Skenario Uji 1	50
Gambar 4. 2 <i>Confusion matrix</i> Skenario Uji 2	51
Gambar 4. 3 <i>Confusion matrix</i> Skenario Uji 3	53
Gambar 4. 4 <i>Confusion matrix</i> Skenario Uji 4	55
Gambar 4. 5 <i>Confusion matrix</i> Skenario Uji 5	57
Gambar 4. 6 <i>Confusion matrix</i> Skenario Uji 6	58
Gambar 4. 7 <i>Confusion matrix</i> Skenario Uji 7	60
Gambar 4. 8 <i>Confusion matrix</i> Skenario Uji 8	62
Gambar 4. 9 <i>Confusion matrix</i> Skenario Uji 9	64
Gambar 4. 10 <i>Confusion matrix</i> Skenario Uji 10	65
Gambar 4. 11 <i>Confusion matrix</i> Skenario Uji 11	67
Gambar 4. 12 <i>Confusion matrix</i> Skenario Uji 12	69
Gambar 4. 13 <i>Confusion matrix</i> Skenario Uji 13	71
Gambar 4. 14 <i>Confusion matrix</i> Skenario Uji 14	72
Gambar 4. 15 <i>Confusion matrix</i> Skenario Uji 15	74
Gambar 4. 16 <i>Confusion matrix</i> Skenario Uji 16	76
Gambar 4. 17 <i>Confusion matrix</i> Skenario Uji 17	78
Gambar 4. 18 <i>Confusion matrix</i> Skenario Uji 18	79
Gambar 4. 19 <i>Confusion matrix</i> Skenario Uji 19	81
Gambar 4. 20 <i>Confusion matrix</i> Skenario Uji 20	83
Gambar 4. 21 <i>Confusion matrix</i> Skenario Uji 21	85
Gambar 4. 22 <i>Confusion matrix</i> Skenario Uji 22	86
Gambar 4. 23 <i>Confusion matrix</i> Skenario Uji 23	88
Gambar 4. 24 <i>Confusion matrix</i> Skenario Uji 24	90
Gambar 4. 25 Diagram Batang Perbandingan <i>F1-score</i> Seluruh Skenario Pengujian	93
Gambar 4. 26 Perbandingan <i>F1-score</i> Skenario 9 dan Skenario 21	97

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait Klasifikasi Tumor Otak.....	10
Tabel 3. 1 Contoh Citra MRI Jenis Tumor Otak	24
Tabel 3. 2 Tabel Level Kuantisasi.....	30
Tabel 3. 3 <i>Confusion matrix</i> 4 Kelas	42
Tabel 3. 4 Data <i>Confusion matrix</i>	45
Tabel 3. 5 Skenario Pengujian	48
Tabel 4. 1 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 1	50
Tabel 4. 2 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 2	52
Tabel 4. 3 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 3	54
Tabel 4. 4 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 4	55
Tabel 4. 5 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 5	57
Tabel 4. 6 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 6	59
Tabel 4. 7 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 7	60
Tabel 4. 8 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 8	62
Tabel 4. 9 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 9	64
Tabel 4. 10 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 10	66
Tabel 4. 11 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 11	67
Tabel 4. 12 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 12	69
Tabel 4. 13 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 13	71
Tabel 4. 14 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 14	73
Tabel 4. 15 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 15	74
Tabel 4. 16 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 16	76
Tabel 4. 17 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 17	78
Tabel 4. 18 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 18	80
Tabel 4. 19 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 19	81
Tabel 4. 20 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 20	83
Tabel 4. 21 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 21	85
Tabel 4. 22 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 22	87
Tabel 4. 23 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 23	89
Tabel 4. 24 Nilai <i>Precision</i> , <i>Recall</i> , dan <i>F1-score</i> pada Skenario Uji 24	90
Tabel 4. 25 Ringkasan Hasil Pengujian 24 Skenario	91
Tabel 4. 26 Penelitian dengan Data yang Sama	94
Tabel 4. 27 Rata-Rata Hasil Pengujian Pada Setiap Kondisi Dataset	96
Tabel 4. 28 Rata-Rata Hasil Pengujian Pada Setiap Sudut Pandang Citra (Dataset Seimbang)	99
Tabel 4. 29 Rata-Rata Hasil Pengujian Pada Setiap Sudut Pandang Citra (Dataset Tidak Seimbang)	99
Tabel 4. 30 Rata-Rata Hasil Pengujian Pada Setiap Kernel (Dataset Seimbang)	101
Tabel 4. 31 Rata-Rata Hasil Pengujian Pada Setiap Kernel (Dataset Tidak Seimbang)	102

ABSTRAK

Febriyanti, Yoza Setya. 2025. **Klasifikasi Jenis Tumor Otak Berdasarkan Citra MRI Menggunakan *Gray Level Co-Occurrence Matrix* (GLCM) dan *Support Vector Machine* (SVM).** Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Okta Qomaruddin Aziz, M.Kom. (II) Prof. Dr. Suhartono, S.Si M.Kom.

Kata kunci: Tumor Otak, Citra MRI, *Gray Level Co-Occurrence Matrix*, *Support Vector Machine*.

Tumor otak merupakan salah satu gangguan pada sistem saraf pusat yang dapat meningkatkan risiko kematian sehingga memerlukan diagnosis yang cepat dan akurat. *Magnetic Resonance Imaging* (MRI) banyak digunakan untuk mendeteksi tumor, tetapi interpretasi manual citra oleh radiolog masih memakan waktu dan rentan terhadap subjektivitas, sehingga diperlukan pendekatan berbasis komputer untuk mendukung proses klasifikasi. Penelitian ini bertujuan menganalisis hasil kombinasi *Gray Level Co-occurrence Matrix* (GLCM) dan *Support Vector Machine* (SVM) dengan empat kernel dalam mengklasifikasikan citra MRI otak ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*. GLCM digunakan untuk mengekstraksi fitur tekstur, sedangkan SVM dengan kernel *Linear*, *Polynomial*, RBF, dan *Sigmoid* diterapkan pada citra dari tiga sudut pandang (*axial*, *sagittal*, *coronal*) dan dua kondisi dataset (seimbang dan tidak seimbang). Hasil pengujian menunjukkan bahwa kombinasi sudut pandang *coronal* dengan kernel RBF pada dataset seimbang memberikan performa terbaik dengan *F1-score* sebesar 84%. Penelitian ini menunjukkan bahwa kombinasi GLCM dan SVM dengan pemilihan kernel dan sudut pandang yang tepat dapat dimanfaatkan sebagai pendekatan yang efektif untuk membantu proses klasifikasi jenis tumor otak berbasis citra MRI.

ABSTRACT

Febriyanti, Yoza Setya. 2025. **Classification of Brain Tumor Types Based on MRI Images Using Gray Level Co-Occurrence Matrix (GLCM) and Support Vector Machine (SVM)**. Thesis. Department of Informatics Engineering, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University Malang. Supervisor: (I) Okta Qomaruddin Aziz, M.Kom. (II) Prof. Dr. Suhartono, S.Si M.Kom.

Keywords: *Brain Tumor, MRI Image, Gray Level Co-Occurrence Matrix, Support Vector Machine*

Brain tumors are one of the disorders of the central nervous system that can increase the risk of death, thus requiring rapid and accurate diagnosis. Magnetic Resonance Imaging (MRI) is widely used to detect tumors, but manual interpretation of images by radiologists is still time-consuming and prone to subjectivity, thus requiring a computer-based approach to support the classification process. This study aims to analyze the results of combining Gray Level Co-occurrence Matrix (GLCM) and Support Vector Machine (SVM) with four kernels in classifying brain MRI images into four classes, namely *glioma*, *meningioma*, *pituitary*, and *no tumor*. GLCM was used to extract texture features, while SVM with *Linear*, *Polynomial*, *RBF*, and *Sigmoid* kernels was applied to images from three viewpoints (*axial*, *sagittal*, *coronal*) and two dataset conditions (balanced and unbalanced). The test results showed that the combination of the *coronal* angle of view with the *RBF* kernel on the balanced dataset provided the best performance with an *F1-score* of 84%. This study shows that the combination of GLCM and SVM with the right kernel and angle of view selection can be used as an effective approach to assist in the classification of brain tumor types based on MRI images.

مستخلص البحث

فرياني، يوزا سبتيا. ٢٠٢٥. تصنيف أنواع أورام الدماغ بناءً على صور الرنين المغناطيسي (MRI) باستخدام مصفوفة الحدوث المشترك للمستوى الرمادي (GLCM) وآلة المتجهات الداعمة (SVM). البحث الجامعي. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالنج. المشرف الأول: أوكنا قمر الدين عزيز، الماجستير. المشرف الثاني: أ. د. سوهارتونو، الماجستير.

الكلمات المفتاحية: أورام الدماغ، صور الرنين المغناطيسي، مصفوفة الحدوث المشترك للمستوى الرمادي، آلة المتجهات الداعمة.

تُعدّ أورام الدماغ من الاضطرابات التي تصيب الجهاز العصبي المركزي وقد تؤدي إلى زيادة خطر الوفاة، مما يتطلب تشخيصًا دقيقًا وسريعًا. ويُستخدم التصوير بالرنين المغناطيسي (MRI) على نطاق واسع لاكتشاف الأورام، إلا أن التفسير اليدوي للصور من قبل أطباء الأشعة لا يزال يستغرق وقتًا طويلاً ويكون عرضةً للذاتية، مما يستلزم استخدام أساليب حاسوبية لدعم عملية التصنيف. يهدف هذا البحث إلى تحليل نتائج دمج مصفوفة التشارك لمستويات الرمادي (GLCM) وآلة المتجهات الداعمة (SVM) باستخدام أربعة نوى في تصنيف صور الرنين المغناطيسي للدماغ إلى أربع فئات، وهي: الورم الدبقي (Glioma)، والورم السحائي (Meningioma)، وورم الغدة النخامية (Pituitary)، وعدم وجود ورم (No tumor) تُستخدم طريقة GLCM لاستخراج خصائص النسيج، في حين تُطبق خوارزمية SVM باستخدام نوى الخطي (Linear)، ومتعدد الحدود (Polynomial)، ودالة الأساس الشعاعي (RBF)، والسيجمويد (Sigmoid) على الصور من ثلاث زوايا عرض، وهي: المحورية (Axial)، والسهمية (Sagittal)، والإكليلية (Coronal)، وفي حالي توزيع البيانات المتوازنة وغير المتوازنة. تُظهر نتائج الاختبار أن دمج زاوية العرض الإكليلية (Coronal) مع نواة RBF على مجموعة البيانات المتوازنة يحقق أفضل أداء، حيث بلغت قيمة مقياس $F1$ -score نسبة 84% وتشير نتائج هذا البحث إلى أن دمج GLCM و SVM مع اختيار النواة وزاوية العرض المناسبة يمكن أن يُستخدم كنهج فعال لدعم عملية تصنيف أنواع أورام الدماغ اعتمادًا على صور الرنين المغناطيسي.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Otak merupakan organ vital dalam sistem saraf pusat manusia yang mengatur hampir seluruh fungsi tubuh, mulai dari sensorik, motorik, bahasa, ingatan, hingga pengambilan keputusan (Naz & Siddique, 2020). Karena perannya yang kompleks, otak sangat rentan terhadap berbagai gangguan yang dapat memengaruhi kinerjanya. Salah satu gangguan tersebut adalah tumor otak, yaitu pertumbuhan sel abnormal di dalam jaringan otak atau di area sekitarnya yang dapat bersifat jinak maupun ganas (Pichaivel *et al.*, 2022). Tumor otak memiliki karakteristik dan tingkat keparahan yang berbeda. Maka dari itu, *World Health Organization* (WHO) mengelompokkan tumor otak ke dalam beberapa jenis utama, yaitu *glioma*, *meningioma*, dan tumor kelenjar hipofisis (*pituitary*) (Louis *et al.*, 2021).

Menurut data *Global Cancer Observatory* (GLOBOCAN) tahun 2022, tumor otak dan sistem saraf pusat menempati peringkat ke-19 sebagai jenis kanker dengan kasus baru terbanyak di dunia, yaitu mencapai 321.731 kasus, serta peringkat ke-12 sebagai penyebab kematian akibat kanker dengan 248.500 kematian (Ferlay *et al.*, 2024). Tingginya angka tersebut menunjukkan perlunya deteksi dini dan diagnosis yang akurat untuk menekan angka kematian. Salah satu upaya dalam hal ini adalah pemanfaatan teknologi pencitraan medis yang mampu

menampilkan struktur otak secara rinci sehingga membantu proses klasifikasi tumor secara tepat.

Upaya ini sejalan dengan keyakinan bahwa setiap penyakit memiliki jalan penyembuhan yang datang dari Allah, sebagaimana firman-Nya:

وَإِذَا مَرِضْتُ فَهُوَ يَشْفِينِ

“Apabila aku sakit, Dialah yang menyembuhkanku.” (QS. Asy-Syu‘ara [26]: 80).

Ayat ini menegaskan bahwa segala bentuk kesembuhan datang atas kehendak Allah. Manusia tidak memiliki kuasa menyembuhkan, tetapi diberi akal untuk berikhtiar menemukan jalan yang mengantarkan pada kesembuhan tersebut. Dalam konteks ini, penelitian di bidang kesehatan dan teknologi medis, termasuk pengembangan sistem klasifikasi tumor otak, merupakan wujud ikhtiar ilmiah yang selaras dengan nilai-nilai keimanan dan tawakal kepada Allah.

Dalam proses diagnosis dan klasifikasi tumor otak, *Computed Tomography* (CT scan) dan *Magnetic Resonance Imaging* (MRI) merupakan modalitas pencitraan yang digunakan untuk mendeteksi dan mengevaluasi struktur otak. MRI lebih unggul dibandingkan CT scan karena mampu menghasilkan citra anatomi dengan kontras jaringan tinggi tanpa paparan radiasi pengion (Singh, 2021). MRI juga lebih efektif dalam menangkap detail jaringan lunak serta lebih sensitif terhadap perubahan akibat pertumbuhan tumor, edema, maupun perdarahan mikro yang sering tidak terdeteksi oleh CT scan (Martucci *et al.*, 2023).

Meskipun MRI telah menjadi alat utama dalam mendeteksi dan menganalisis tumor otak, proses interpretasinya masih banyak bergantung pada

kemampuan dan pengalaman radiolog. Proses manual ini tidak hanya memerlukan waktu yang lama, tetapi juga rentan terhadap kesalahan manusia yang dapat memengaruhi akurasi diagnosis maupun perencanaan pengobatan (Albalawi *et al.*, 2024). Kondisi tersebut menunjukkan adanya keterbatasan pada metode konvensional dalam menganalisis citra medis yang kompleks, sehingga diperlukan sistem berbasis komputer untuk meningkatkan akurasi dan konsistensi klasifikasi tumor otak melalui ekstraksi fitur dan pembelajaran mesin.

Dalam *machine learning*, khususnya pada klasifikasi citra medis, ekstraksi fitur merupakan tahap krusial sebelum proses klasifikasi dilakukan. Citra MRI mentah umumnya berdimensi besar, mengandung *noise*, dan memuat detail yang tidak selalu relevan, sehingga perlu diubah menjadi representasi fitur yang lebih ringkas dan informatif (Tamada, 2020). Berbagai metode ekstraksi fitur telah dikembangkan, seperti *Gabor filter* untuk analisis frekuensi spasial, *Wavelet transform* untuk merepresentasikan detail pada berbagai tingkat resolusi, *Local Binary Pattern* (LBP) untuk mendeskripsikan tekstur lokal, *Histogram of Oriented Gradients* (HOG) untuk menyoroti pola tepi, serta *Gray Level Co-Occurrence Matrix* (GLCM) yang mengevaluasi keterkaitan antar-intensitas piksel guna menangkap pola tekstur global pada citra *grayscale* (Alnaggar *et al.*, 2024) (Zahid *et al.*, 2025).

Di antara berbagai metode tersebut, GLCM dinilai paling relevan untuk analisis citra MRI tumor otak karena mampu menggambarkan variasi tingkat keabuan secara statistik pada jarak dan arah tertentu, sehingga dapat merepresentasikan heterogenitas jaringan otak (Hussain *et al.*, 2022). Penelitian

yang dilakukan oleh Vijithananda *et al.* (2022) juga menunjukkan bahwa penerapan GLCM pada citra MRI-ADC otak pasien tumor menghasilkan fitur seperti *contrast*, *correlation*, *energy*, *entropy*, *homogeneity*, *prominence*, dan *shade* yang terbukti informatif untuk membedakan karakteristik jaringan tumor otak.

Setelah fitur citra diekstraksi, tahap selanjutnya adalah klasifikasi, yang berfungsi memberikan label pada citra berdasarkan fitur yang diperoleh agar sistem dapat mengenali jenis tumor otak secara otomatis. Pemilihan algoritma klasifikasi yang tepat menjadi penting karena memengaruhi akurasi dan keandalan hasil diagnosis (Abdelfattah *et al.*, 2023). Berbagai algoritma telah digunakan dalam penelitian sebelumnya, seperti *K-Nearest Neighbor* (KNN) yang mengukur kemiripan jarak antar sampel, *Decision Tree* (DT) yang memanfaatkan struktur bercabang untuk pengambilan keputusan, serta *Naive Bayes* (NB) yang berbasis probabilistik dengan asumsi independensi antar fitur (Zulkarnain *et al.*, 2024). Namun, karakteristik data medis yang cenderung berdimensi tinggi, berukuran kecil, dan memiliki distribusi kelas tidak seimbang sering kali menyebabkan performa algoritma tersebut tidak konsisten (Cusworth *et al.*, 2024).

Beberapa studi melaporkan bahwa SVM efektif dalam menangani kondisi semacam ini, karena berfokus pada penentuan *support vector* untuk membangun batas keputusan yang optimal (Srivastava *et al.*, 2022). SVM dikenal memiliki performa yang baik meskipun bekerja pada data berukuran terbatas, serta fleksibel dalam menangani pola data *nonlinier* melalui penggunaan fungsi *kernel* (Amaya-Tejera *et al.*, 2024). Dengan keunggulan tersebut, SVM berpotensi mendukung pengembangan sistem klasifikasi medis yang lebih akurat.

Kombinasi antara GLCM dan SVM juga telah diterapkan oleh Febrianti *et al.* (2020) untuk mengklasifikasi citra MRI otak menjadi dua kelas, yaitu tumor dan non-tumor. Hasil penelitiannya menunjukkan akurasi tertinggi sebesar 76%, sehingga kombinasi kedua metode ini dinilai cukup efektif dalam mendeteksi keberadaan tumor otak berdasarkan pola tekstur citra.

Namun, penelitian tersebut masih memiliki beberapa keterbatasan. Pertama, klasifikasi yang dilakukan hanya membedakan citra menjadi dua kelas tanpa mengidentifikasi jenis tumor otak. Kedua, penelitian tersebut belum mempertimbangkan perbedaan orientasi citra MRI (*axial*, *sagittal*, dan *coronal*) yang berpotensi memengaruhi karakteristik tekstur dan hasil klasifikasi.

Keterbatasan tersebut menjadi dasar perlunya penelitian lanjutan yang memberikan manfaat lebih luas bagi bidang kesehatan. Dalam Islam, kemanfaatan ilmu pengetahuan dipandang sebagai salah satu bentuk amal yang paling mulia. Rasulullah ﷺ bersabda:

خَيْرُ النَّاسِ أَنْفَعُهُمْ لِلنَّاسِ

“Sebaik-baik manusia adalah yang paling bermanfaat bagi manusia” (HR. Ahmad, ath-Thabrani, ad-Daruqutni).

Hadis ini menegaskan bahwa nilai tertinggi seseorang tidak diukur dari ilmu yang dimilikinya semata, melainkan dari sejauh mana ilmu tersebut memberi manfaat bagi sesama. Dengan landasan ini, penelitian ini diharapkan menjadi salah satu wujud ikhtiar dalam menghadirkan manfaat nyata melalui pengembangan teknologi diagnostik yang mendukung proses deteksi dan penanganan tumor otak secara lebih efektif.

Berdasarkan latar belakang yang telah diuraikan, maka penelitian ini dikembangkan untuk mengatasi keterbatasan sebelumnya dengan menerapkan kombinasi GLCM dan SVM pada tiga orientasi citra MRI guna mengklasifikasikan jenis tumor otak. Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, *Recall*, dan *F1-score*, sehingga diharapkan dapat menghasilkan model klasifikasi yang lebih akurat, konsisten, dan mendukung proses diagnosis yang lebih cepat, objektif, serta andal.

1.2 Rumusan Masalah

Bagaimana analisis hasil ekstraksi fitur *Gray Level Co-occurrence Matrix* (GLCM) dan algoritma *Support Vector Machine* (SVM) dengan empat jenis kernel dalam mengklasifikasikan jenis tumor otak berdasarkan citra MRI pada tiga sudut pandang?

1.3 Batasan Masalah

Batasan masalah yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Data yang digunakan merupakan data sekunder berupa citra MRI otak yang dapat diakses secara publik melalui platform *Kaggle*, dengan judul *Brain Tumor Classification MRI* yang dikembangkan oleh Sartaj Bhuvaji.
2. Klasifikasi mencakup empat jenis tumor otak, yaitu *glioma*, *meningioma*, *pituitary tumor*, dan *no tumor*. Data di luar jenis tersebut tidak dianalisis.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk menganalisis hasil metode ekstraksi fitur *Gray Level Co-occurrence Matrix* (GLCM) dan algoritma *Support Vector Machine* (SVM) dengan empat jenis kernel dalam mengklasifikasikan jenis tumor otak berdasarkan citra MRI pada tiga sudut pandang.

1.5 Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini adalah sebagai berikut:

1. Membantu tenaga medis dalam mendukung proses diagnosis tumor otak melalui sistem klasifikasi yang lebih objektif.
2. Menjadi referensi bagi penelitian berikutnya yang berkaitan dengan klasifikasi tumor otak menggunakan citra MRI.

BAB II

STUDI PUSTAKA

2.1 Klasifikasi Tumor Otak

Penelitian mengenai klasifikasi tumor otak telah banyak dilakukan untuk mengembangkan metode klasifikasi yang lebih akurat dan efisien. Bagian ini membahas beberapa penelitian terdahulu yang menerapkan berbagai teknik ekstraksi fitur dan algoritma klasifikasi sebagai dasar pengembangan penelitian ini.

Penelitian yang dilakukan oleh Febrianti *et al.* (2020) membahas klasifikasi citra MRI otak menjadi *tumor* dan *non-tumor* menggunakan metode SVM dengan fitur tekstur hasil ekstraksi GLCM. Dataset yang digunakan berjumlah 100 citra MRI dari dua sumber *Kaggle*. Tahapan penelitian meliputi *pre-processing* (*grayscale, Gaussian blur, thresholding, dilasi, erosi, dan automatic Cropping*), kemudian dilakukan ekstraksi tujuh fitur GLCM: *contrast, correlation, energy, dissimilarity, homogeneity, ASM, dan entropy*. Fitur tersebut digunakan pada dua tipe model, yaitu C-SVM dan Nu-SVM dengan kernel *Linear, RBF, dan Polynomial*. Hasil terbaik diperoleh pada C-SVM dengan kernel *Linear* dan *RBF* yang mencapai akurasi 76%, sedangkan Nu-SVM *Polynomial* menghasilkan 72%.

Penelitian yang dilakukan oleh Kadam *et al.* (2021) membahas klasifikasi citra MRI otak menjadi empat kelas, yaitu *glioma, meningioma, pituitary, dan no tumor*, menggunakan beberapa arsitektur *deep learning*, yaitu *Artificial Neural Network* (ANN), *Convolutional Neural Network* (CNN) yang dilatih dari nol, dan *transfer learning* (VGG16) pada dataset *Brain Tumor Classification* (MRI) dari

Kaggle. Dataset yang digunakan terdiri atas 3.190 citra MRI *T1-weighted contrast-enhanced* yang melalui tahapan pra-pemrosesan berupa *Cropping*, *Resize* menjadi 224×224 piksel dengan 3 kanal, dan augmentasi data sebelum dibagi ke dalam data latih dan data uji. Hasil pengujian menunjukkan bahwa model CNN terbaik dengan tiga lapisan konvolusi menghasilkan akurasi 90% dan *F1-score* 91, sedangkan model VGG16 memberikan performa tertinggi dengan akurasi 94% dan *F1-score* 94%.

Penelitian yang dilakukan oleh Adilah dan Azizah (2022) bertujuan untuk mengklasifikasikan citra MRI otak menjadi empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*, menggunakan kombinasi HOG dan SVM. Dataset yang digunakan terdiri atas 3.064 citra MRI dari *Kaggle* yang telah dibagi ke dalam data latih dan data uji. Tahapan penelitian meliputi pra-pemrosesan (*Resize* dan *grayscale*), kemudian ekstraksi fitur HOG untuk menangkap informasi gradien pada citra, dan dilanjutkan dengan klasifikasi menggunakan SVM pada Kernel *Linear* dan RBF. Hasil pengujian menunjukkan bahwa kombinasi HOG dan SVM Kernel *Linear* menghasilkan akurasi tertinggi sebesar 91%, lebih unggul dibandingkan kernel RBF yang memperoleh 87%.

Penelitian yang dilakukan oleh Ardiantito *et al.* (2023) berfokus pada klasifikasi citra MRI otak untuk mendeteksi jenis tumor menggunakan kombinasi LBP sebagai ekstraksi fitur dan SVM sebagai algoritma klasifikasi. Dataset terdiri atas 2.044 citra MRI yang dibagi ke dalam tiga kelas, yaitu *meningioma*, *no tumor*, dan *pituitary*. Proses penelitian meliputi pra-pemrosesan (*Resize*, *grayscale*, dan normalisasi), kemudian ekstraksi fitur LBP dengan variasi radius dan jumlah

ketetanggaan. Fitur terbaik diperoleh pada konfigurasi radius = 1 dan tetangga = 8, yang kemudian digunakan dalam klasifikasi SVM dengan kernel RBF dan parameter $C = 50$. Hasil pengujian menunjukkan akurasi 88%, presisi 86%, dan *Recall* 87%.

Rangkuman penelitian terdahulu disajikan pada Tabel 2.1. Berdasarkan keempat penelitian tersebut, klasifikasi tumor otak pada citra MRI dilakukan menggunakan pendekatan berbasis fitur tekstur yang dikombinasikan dengan SVM (GLCM, HOG, dan LBP) serta pendekatan *deep learning* seperti CNN dan *transfer learning* (VGG16). Penelitian dengan GLCM dan SVM yang dikaji masih terbatas pada klasifikasi dua kelas, sedangkan penelitian *multiclass* menggunakan fitur lain atau model *deep learning* dan tidak secara eksplisit membahas perbedaan orientasi citra. Berdasarkan hal tersebut, penelitian ini menerapkan ekstraksi fitur GLCM pada tiga orientasi citra MRI (*axial*, *sagittal*, dan *coronal*) dan menguji beberapa kernel SVM untuk klasifikasi empat jenis tumor otak.

Tabel 2.1 Penelitian Terkait Klasifikasi Tumor Otak

No.	Sumber	Judul	Input	Metode	Akurasi
1.	Febrianti <i>et al.</i> (2020)	Klasifikasi Tumor Otak pada Citra <i>Magnetic Resonance Image</i> dengan Menggunakan Metode <i>Support Vector Machine</i>	100 citra MRI, 2 kelas (tumor / non-tumor)	GLCM dan SVM	76% (C-SVM <i>Linear</i> & RBF)
2.	(Kadam <i>et al.</i> , 2021)	<i>Brain Tumor Classification using Deep Learning Algorithms</i>	3.190 citra MRI, 4 kelas (<i>glioma</i> , <i>meningioma</i> , <i>no tumor</i> , <i>pituitary</i>)	ANN, CNN, dan <i>Transfer Learning</i> (VGG16)	94% (VGG 16)
3.	Adilah & Azizah (2022)	Klasifikasi Tumor Otak Menggunakan Ekstraksi Fitur HOG dan <i>Support Vector Machine</i>	3064 citra MRI, 4 kelas (<i>glioma</i> , <i>meningioma</i> , <i>pituitary</i> , <i>no tumor</i>)	HOG dan SVM	91% (SVM Kernel <i>Linear</i>)

No.	Sumber	Judul	Input	Metode	Akurasi
4.	Ardiantito <i>et al.</i> (2023)	Klasifikasi Tumor Otak Menggunakan <i>Local Binary Pattern</i> dan SVM <i>Classifier</i>	2044 citra MRI, 3 kelas (<i>meningioma</i> , <i>no tumor</i> , <i>pituitary</i>)	LBP dan SVM	88%, (SVM kernel RBF)

2.2 Tumor Otak

Tumor otak merupakan salah satu tantangan kesehatan global yang serius karena tingginya angka kematian yang ditimbulkan. Berdasarkan laporan *Global Burden of Disease* (GBD) tahun 2021 mencatat bahwa kanker sistem saraf pusat, termasuk tumor otak, menyebabkan lebih dari 250.000 kematian secara global (Zhao *et al.*, 2025). Secara medis, tumor otak ditandai oleh pertumbuhan sel abnormal yang tidak terkendali di dalam sistem saraf pusat, baik yang berasal dari jaringan otak itu sendiri (primer) maupun dari penyebaran kanker organ lain (metastasis) (Mitchell *et al.*, 2022).

Terbentuknya tumor otak berawal dari perubahan genetik pada sel normal yang mengganggu mekanisme pengendalian pertumbuhan. Perubahan ini umumnya melibatkan aktivasi gen onkogen serta inaktivasi gen penekan tumor, yang pada akhirnya memicu proliferasi sel berlebihan hingga membentuk massa tumor (Eisenbarth & Wang, 2023). Dalam kasus tumor ganas, sel-sel abnormal tidak hanya menekan jaringan otak sehat tetapi dapat menyebar melalui pembuluh darah maupun cairan serebrospinal, sehingga memperburuk kondisi klinis pasien (Sajjadi *et al.*, 2024).

Faktor yang berperan dalam terjadinya tumor otak antara lain predisposisi genetik, paparan radiasi, serta zat karsinogenik. Kondisi tersebut kemudian dapat

memicu berbagai gejala klinis, yang bervariasi tergantung pada lokasi dan ukuran tumor, seperti sakit kepala, gangguan penglihatan, kejang, gangguan bicara, hingga perubahan perilaku (Smith *et al.*, 2024). Berdasarkan karakteristik biologisnya, tumor otak dapat diklasifikasikan menurut asal jaringan dan sifat pertumbuhannya. Beberapa jenis utama yang sering ditemukan antara lain *glioma*, *meningioma*, dan *pituitary tumor*.

2.2.1 Glioma

Glioma merupakan tumor otak yang berasal dari sel glia, yaitu sel penunjang sistem saraf yang berfungsi mendukung dan melindungi neuron. Jenis ini mencakup beberapa subtype, seperti *astrocitoma*, *oligodendroglioma*, dan *ependimoma*, dengan tingkat keganasan yang bervariasi mulai dari jinak hingga sangat agresif. *Glioma* umumnya ditemukan pada usia dewasa dan dapat menimbulkan gejala berupa sakit kepala, kejang, kelemahan motorik, serta gangguan fungsi kognitif (Byun & Park, 2022).

2.2.2 Meningioma

Meningioma adalah tumor otak yang berasal dari meninges, yaitu selaput pelindung otak dan sumsum tulang belakang. Sebagian besar *meningioma* bersifat jinak dan tumbuh perlahan, tetapi sebagian dapat berkembang menjadi atipikal atau ganas dengan kecenderungan kambuh setelah terapi. Tumor ini merupakan jenis primer yang paling sering ditemukan, lebih dominan pada wanita dewasa, serta memiliki kaitan dengan faktor hormonal. Gejala klinis yang muncul dapat berupa

sakit kepala, gangguan penglihatan, kejang, atau perubahan perilaku akibat tekanan massa tumor terhadap jaringan otak sekitarnya (Ogasawara *et al.*, 2021).


2.2.3 Pituitary Tumor

Pituitary tumor berkembang di kelenjar pituitari, kelenjar kecil di dasar otak yang berperan penting dalam pengaturan hormon tubuh. Sebagian besar berbentuk adenoma yang jinak dan tumbuh lambat, namun dapat berdampak signifikan melalui produksi hormon berlebih atau penekanan terhadap produksi hormon normal. Tumor ini sering ditemukan pada pria maupun wanita dewasa. Gejalanya bervariasi, mulai dari sakit kepala dan gangguan penglihatan akibat tekanan pada saraf optik hingga kelainan endokrinologis, seperti infertilitas, gangguan menstruasi, atau perubahan metabolisme tubuh (Casar Borota, 2024).

2.3 Gray Level Co-Occurrence Matrix (GLCM)

GLCM pertama kali diperkenalkan oleh Haralick pada tahun 1973 sebagai metode statistik orde kedua yang digunakan untuk mendeskripsikan tekstur citra (Haralick *et al.*, 1973). GLCM didefinisikan sebagai matriks yang merepresentasikan distribusi spasial intensitas piksel dengan menghitung seberapa sering pasangan nilai keabuan tertentu muncul pada jarak dan arah tertentu. Metode ini menekankan pada hubungan antar piksel dalam suatu citra, sehingga dapat merepresentasikan pola tekstur yang tidak ditangkap oleh histogram tingkat keabuan yang hanya menggambarkan distribusi intensitas piksel secara keseluruhan (Alibabaei *et al.*, 2023).

Pembentukan GLCM dilakukan dengan menghitung frekuensi kemunculan pasangan piksel dengan nilai keabuan tertentu pada jarak dan arah yang ditentukan. Arah standar yang digunakan meliputi 0° , 45° , 90° , dan 135° , yang masing-masing merepresentasikan orientasi horizontal, diagonal, dan vertikal (Sadad *et al.*, 2023). Ilustrasi arah GLCM ditunjukkan pada Gambar 2.1.



Gambar 2. 1 Sudut pada GLCM

Untuk mengurangi kompleksitas citra, biasanya dilakukan proses kuantisasi, yaitu pengelompokan nilai keabuan ke dalam sejumlah tingkat tertentu sehingga matriks yang terbentuk lebih sederhana. Setelah itu dilakukan normalisasi agar setiap elemen matriks mencerminkan probabilitas kemunculan pasangan piksel. Variasi jarak dan arah yang digunakan pada GLCM akan menghasilkan informasi tekstur yang berbeda sesuai skala dan orientasi yang dianalisis (Alibabaei *et al.*, 2023).

Dari matriks GLCM dapat diturunkan berbagai fitur statistik yang berfungsi untuk merepresentasikan karakteristik tekstur citra. Dalam penelitian yang dilakukan oleh Christaki *et al.*, (2022), fitur-fitur tersebut dikelompokkan menjadi empat yang paling umum digunakan, yaitu *contrast*, *correlation*, *energy* atau *angular second moment (ASM)*, dan *homogeneity*.

2.3.1 Contrast

Contrast menggambarkan tingkat perbedaan intensitas antara piksel dan tetangganya dalam citra. Nilai *contrast* yang tinggi menunjukkan adanya variasi intensitas lokal yang besar, sehingga tekstur terlihat kasar, sedangkan nilai rendah menandakan tekstur lebih halus. Persamaan untuk menghitung nilai *contrast* dapat dilihat pada Persamaan 2.1.

$$Contrast = \sum_{i,j} |i - j|^2 p(i,j) \quad (2.1)$$

2.3.2 Correlation

Correlation menggambarkan seberapa kuat keterkaitan *Linear* antara pasangan piksel dalam citra. Nilai *correlation* yang tinggi menunjukkan adanya hubungan intensitas yang kuat dan teratur antar piksel, sedangkan nilai rendah menunjukkan keterkaitan yang lemah atau acak. Persamaan untuk menghitung nilai *correlation* dapat dilihat pada Persamaan 2.2.

$$Correlation = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j) \times p(i,j)}{\sigma_i \times \sigma_j} \quad (2.2)$$

Dimana:

$$\mu_i = \sum_{i,j} i \times p(i,j) \quad (2.3)$$

$$\mu_j = \sum_{i,j} j \times p(i,j) \quad (2.4)$$

$$\sigma_i = \sqrt{\sum_{i,j} (i - \mu)^2 \times p(i,j)} \quad (2.5)$$

$$\sigma_j = \sqrt{\sum_{i,j} (j - \mu)^2 \times p(i,j)} \quad (2.6)$$

Persamaan 2.3 dan 2.4 digunakan untuk menghitung nilai rata-rata (*mean*) tingkat keabuan pada baris (μ_i) dan kolom (μ_j) matriks GLCM, sedangkan Persamaan 2.5 dan 2.6 digunakan untuk menghitung simpangan baku (*standard deviation*) masing-masing pada baris (σ_i) dan kolom (σ_j). Nilai rata-rata menggambarkan kecenderungan intensitas piksel, sedangkan simpangan baku menunjukkan tingkat penyebaran nilai keabuan terhadap rata-ratanya. Keempat parameter tersebut digunakan dalam Persamaan 2.2 untuk mengukur tingkat hubungan *Linear* antar pasangan piksel dalam citra.

2.3.3 *Energy*

Energy mengukur keseragaman distribusi nilai GLCM. Nilai *energy* yang tinggi menunjukkan tekstur yang homogen dengan distribusi intensitas yang seragam, sedangkan nilai rendah menunjukkan tekstur yang lebih acak. Persamaan untuk menghitung nilai *energy* dapat dilihat pada Persamaan 2.7.

$$Energy = \sum_{i,j} p(i,j)^2 \quad (2.7)$$

2.3.4 *Homogeneity*

Homogeneity menggambarkan kedekatan distribusi nilai pada GLCM terhadap diagonal utamanya. Nilai *homogeneity* yang tinggi menunjukkan bahwa perbedaan intensitas antar piksel relatif kecil, sedangkan nilai rendah menandakan perbedaan yang besar. Persamaan untuk menghitung *homogeneity* dapat dilihat pada Persamaan 2.8.


$$Homogeneity = \sum_{i,j} \frac{p(i,j)}{1 + |i - j|} \quad (2.8)$$

Dimana dari seluruh persamaan fitur tersebut, i dan j merupakan indeks baris dan kolom dari matriks GLCM, sedangkan $p(i,j)$ adalah probabilitas kemunculan pasangan nilai keabuan. Seluruh fitur GLCM berfungsi merangkum informasi kompleks dari tekstur ke dalam nilai numerik yang dapat dimanfaatkan pada analisis maupun klasifikasi citra (Iqbal *et al.*, 2021).

2.4 *Support Vector Machine (SVM)*

SVM pertama kali diperkenalkan oleh *Vladimir Vapnik* dan koleganya pada awal tahun 1990-an sebagai bagian dari pengembangan metode pembelajaran mesin berbasis teori margin (Guido *et al.*, 2024). SVM merupakan algoritma *supervised learning* yang dirancang untuk menyelesaikan permasalahan klasifikasi dan regresi dengan memanfaatkan konsep pemisahan data ke dalam kelas yang berbeda (Piccialli & Sciandrone, 2022).

Prinsip kerja SVM didasarkan pada pencarian *hyperplane* yang berfungsi sebagai pemisah antara dua kelas data. *Hyperplane* tersebut ditentukan dengan mempertimbangkan *margin* atau jarak terhadap data dari masing-masing kelas. Data yang berada paling dekat dengan *hyperplane* disebut *support vector* dan menjadi acuan dalam menentukan posisi serta orientasi pemisah kelas. Dengan pendekatan ini, SVM menghasilkan model klasifikasi yang dapat membedakan kelas secara optimal (Montesinos López *et al.*, 2022). Ilustrasi konsep SVM dapat dilihat pada Gambar 2.2.



Gambar 2. 2 SVM

Secara matematis, *hyperplane* dinyatakan dalam Persamaan 2.9.

$$w \cdot x + b = 0 \quad (2.9)$$

Keterangan:

w = vektor bobot
 x = vektor fitur dari data
 b = bias

Pada proses klasifikasi, setiap data x_i dengan label kelas y_i (+1 atau -1) dievaluasi terhadap posisi *hyperplane* menggunakan fungsi pada Persamaan 2.10.

$$y_1(w \cdot x_1 + b) \quad (2.10)$$

Keterangan:

y_i = label kelas dari data ke- i (+1 atau -1)
 x_i = vektor fitur ke- i
 w = vektor bobot
 b = bias

Jika data salah diklasifikasikan atau tidak memenuhi margin, maka dilakukan pembaruan bobot dan bias secara iteratif agar *hyperplane* semakin optimal, dengan Persamaan 2.11 untuk bobot dan Persamaan 2.12 untuk bias.

$$w = w + \eta \times y_1 \times x_1 \quad (2.11)$$

$$b = b + \eta \times y_1 \quad (2.12)$$

Keterangan:

w = vektor bobot
 b = bias
 η = learning rate
 y_I = label kelas dari data ke- i (+1 atau -1)
 x_I = vektor fitur ke- i

Apabila semua data telah memenuhi margin, maka tahap terakhir adalah proses prediksi, di mana data baru diklasifikasikan menggunakan fungsi keputusan. Pada kasus *multiclass*, SVM diperluas dengan membangun beberapa model biner seperti menggunakan pendekatan *One vs All*. Keputusan akhir ditentukan berdasarkan skor fungsi keputusan tertinggi sebagaimana Persamaan 2.13.

$$\text{prediksi}(x) = \arg \max_k (f_k(x)) = \arg \max_k (w_k \cdot x + b_k) \quad (2.13)$$

Keterangan:

w_k = Vektor bobot untuk kelas ke- k
 b_k = Vektor bias untuk kelas ke- k
 $f_k(x)$ = Nilai fungsi Keputusan

Melalui proses tersebut, SVM mampu menentukan garis pemisah terbaik yang memaksimalkan margin antar kelas, sehingga diperoleh model klasifikasi dengan performa yang kuat terhadap berbagai jenis data, termasuk citra MRI tumor otak. Namun, pada kenyataannya tidak semua data dapat dipisahkan secara *Linear*. Untuk mengatasi hal tersebut, SVM menggunakan fungsi kernel yang berfungsi memetakan data ke ruang fitur berdimensi lebih tinggi sehingga dapat dipisahkan dengan lebih baik. Terdapat beberapa jenis kernel yang digunakan, antara lain kernel *Linear*, *Polynomial*, *Radial Basis Function* (RBF), dan *Sigmoid*, yang dijelaskan sebagai berikut:

2.4.1 Kernel *Linear*

Kernel *Linear* merupakan kernel paling sederhana yang bekerja dengan memanfaatkan hubungan langsung antar data tanpa mengubah representasi aslinya. Kernel ini sesuai digunakan pada kasus data yang dapat dipisahkan secara *Linear* serta umum dipakai dalam klasifikasi dengan dimensi tinggi. Secara matematis, fungsi Kernel *Linear* didefinisikan pada Persamaan 2.4.

$$k(x, y) = x \cdot y \quad (2.14)$$

Keterangan:

x, y = vektor fitur

2.4.2 Kernel *Polynomial*

Kernel *Polynomial* digunakan untuk memetakan data ke ruang berdimensi lebih tinggi agar pola nonlinier dapat dipisahkan. Kernel ini mampu membentuk batas keputusan yang lebih kompleks sehingga sering diterapkan pada permasalahan pengenalan pola. Bentuk umum dari fungsi Kernel *Polynomial* disajikan dalam Persamaan 2.15.

$$k(x, y) = (\gamma(x \cdot y) + c)^d \quad (2.15)$$

Keterangan:

x, y = vektor fitur

γ = parameter skalar

c = konstanta

d = derajat *Polynomial*

2.4.3 Kernel *Radial Basis Function (RBF)*

Kernel RBF atau *Gaussian* merupakan salah satu kernel yang paling banyak digunakan untuk data nonlinier. Kernel ini bekerja dengan memetakan data ke ruang berdimensi lebih tinggi sehingga dapat menghasilkan batas keputusan yang

fleksibel untuk berbagai distribusi data. Secara matematis, Kernel RBF didefinisikan melalui Persamaan 2.16.

$$k(x, y) = \exp(-\gamma \|x - y\|^2) \quad (2.16)$$

Keterangan:

x, y = vektor fitur
 γ = parameter scalar

2.4.4 Kernel *Sigmoid*

Kernel *Sigmoid* memiliki karakteristik yang mirip dengan fungsi aktivasi pada jaringan saraf tiruan. Kernel ini dapat menggambarkan hubungan nonlinier yang lebih kompleks, meskipun pada beberapa kondisi performanya tidak selalu sebaik kernel lain. Fungsi Kernel *Sigmoid* ini dapat dinyatakan dalam Persamaan 2.17.

$$k(x, y) = \tanh(\gamma(x \cdot y) + c) \quad (2.17)$$

Keterangan:


x, y = vektor fitur
 γ = parameter scalar
 c = konstanta

BAB III

METODE PENELITIAN

3.1 Alur Penelitian

Alur penelitian adalah rangkaian tahapan yang menggambarkan proses penelitian secara sistematis. Penyusunan alur penelitian bertujuan untuk memberikan kerangka kerja yang jelas dan terarah sehingga penelitian dapat dilakukan sesuai dengan tujuan yang telah ditetapkan. Berikut alur yang digunakan dalam penelitian klasifikasi jenis tumor otak berdasarkan citra MRI menggunakan GLCM dan SVM:



Gambar 3. 1 Alur Penelitian

Berdasarkan Gambar 3.1, Penelitian diawali dengan studi literatur untuk mengumpulkan teori dan penelitian sebelumnya yang relevan dengan topik penelitian. Tahap kedua adalah pengumpulan data, dimana data yang digunakan dalam penelitian ini adalah citra MRI jenis tumor otak yang diperoleh dari *platform Kaggle*. Tahap ketiga adalah praproses data untuk meningkatkan kualitas citra dan menyiapkannya agar siap diolah. Tahap keempat yaitu ekstraksi fitur menggunakan metode GLCM guna memperoleh ciri tekstur yang merepresentasikan karakteristik tumor otak. Tahap kelima adalah klasifikasi menggunakan algoritma SVM untuk

menentukan jenis tumor berdasarkan fitur yang telah diekstrak. Tahap terakhir yaitu evaluasi, dimana kinerja model diukur menggunakan *Confusion matrix*.












3.2 Pengumpulan Data

Tahap pengumpulan data dilakukan untuk memperoleh sumber informasi yang sesuai dengan kebutuhan penelitian. Data yang digunakan pada penelitian ini berupa data sekunder yang berasal dari dataset publik *Brain Tumor Classification* (MRI) yang tersedia di *platform Kaggle* ([brain-tumor-classification-mri](https://www.kaggle.com/brain-tumor-classification-mri))

Pada penelitian ini, dataset dikelompokkan ulang berdasarkan sudut pandang pengambilan citra, yaitu atas (*axial*), samping (*sagittal*), dan belakang (*coronal*). Sudut pandang *axial* menampilkan potongan otak dari arah atas kepala, *sagittal* dari samping, dan *coronal* dari belakang. Pembagian ini menghasilkan tiga subset data dengan jumlah yang berbeda. Pada sudut pandang atas terdapat 1.256 citra (333 *glioma*, 361 *meningioma*, 289 *pituitary*, dan 273 *no tumor*). Sudut pandang samping memiliki 986 citra (295 *glioma*, 291 *meningioma*, 306 *pituitary*, dan 94 *no tumor*). Sedangkan sudut pandang belakang berjumlah 946 citra (298 *glioma*, 285 *meningioma*, 318 *pituitary*, dan 45 *no tumor*).


Perbedaan sudut pandang ini mencerminkan variasi kondisi nyata pengambilan citra MRI otak, yang dapat dilakukan dari arah *axial*, *sagittal*, maupun *coronal* sesuai kebutuhan pemeriksaan. Oleh karena itu, pengujian pada penelitian ini dilakukan secara terpisah untuk setiap sudut pandang agar hasil klasifikasi dapat dibandingkan berdasarkan perbedaan orientasi citra. Contoh citra MRI dari masing-masing sudut pandang dapat dilihat pada Tabel 3.1.

Tabel 3. 1 Contoh Citra MRI Jenis Tumor Otak

No	Keterangan	Citra MRI		
1.	<i>Glioma tumor</i>			
2.	<i>Meningioma tumor</i>			
3.	<i>Pituitary tumor</i>			
4.	<i>No tumor</i>			

3.3 Desain Sistem

Desain sistem digunakan untuk menggambarkan alur kerja klasifikasi jenis tumor otak berdasarkan citra MRI menggunakan metode *Gray Level Co-Occurrence Matrix* (GLCM) dan *Support Vector Machine* (SVM). Desain ini memperlihatkan tahapan proses secara berurutan dari pengolahan citra hingga menghasilkan keluaran berupa hasil klasifikasi.



Gambar 3. 2 Desain Sistem


Gambar 3.2 menunjukkan alur kerja sistem klasifikasi tumor otak yang diawali dari input dataset citra MRI. Selanjutnya dilakukan tahap praproses yang meliputi *Cropping* untuk memfokuskan area otak, *Noise Reduction* untuk mengurangi *noise* pada citra, serta *Resize* untuk menyeragamkan ukuran citra. Setelah itu, dilakukan ekstraksi fitur tekstur menggunakan GLCM sehingga citra direpresentasikan dalam bentuk fitur numerik. Data fitur tersebut kemudian dibagi menjadi data *training* dan data *testing*. Data *training* digunakan untuk melatih model SVM, sedangkan data *testing* digunakan pada tahap klasifikasi SVM untuk menghasilkan prediksi kelas serta mengevaluasi kinerja model.

3.4 Preprocessing Citra

Preprocessing citra merupakan tahap awal yang dilakukan untuk mempersiapkan data citra. Tujuan *preprocessing* adalah menyesuaikan citra agar memiliki kualitas dan format yang seragam sehingga dapat digunakan pada tahap ekstraksi fitur.

3.4.1 *Cropping*


Pada tahap awal *preprocessing*, citra MRI otak akan melalui tahap *cropping* untuk memfokuskan area otak dan menghilangkan bagian latar belakang yang tidak diperlukan. Proses ini dilakukan dengan mendeteksi area otak melalui metode *thresholding* untuk memisahkan objek dari background hitam, kemudian menentukan *bounding box* yang melingkupi area otak, dan selanjutnya memotong citra sesuai *bounding box* tersebut. Tahap *cropping* ini bertujuan agar citra yang diperoleh hanya berisi bagian otak yang relevan, sehingga data yang digunakan pada proses ekstraksi fitur menjadi lebih terarah dan konsisten. Hasil citra sebelum dan setelah dilakukan proses *cropping* ditunjukkan pada Gambar 3.3.



Gambar 3. 3 Hasil *Cropping*

3.4.2 Noise Reduction

Setelah melalui tahap *cropping*, citra MRI otak akan melalui tahap reduksi noise (*Noise Reduction*) untuk mengurangi gangguan berupa bintik-bintik acak atau variasi intensitas yang tidak diinginkan. Pada penelitian ini digunakan metode *Gaussian filter* dengan ukuran kernel 3×3 , yang bekerja dengan cara melakukan perataan nilai intensitas piksel berdasarkan distribusi *Gaussian* di sekitar piksel tersebut. Pendekatan ini dipilih karena mampu mengurangi *noise* halus pada citra tanpa menghilangkan detail penting pada struktur jaringan otak maupun area tumor. Dengan demikian, hasil citra yang diperoleh menjadi lebih bersih dan stabil untuk tahap pengolahan selanjutnya, Contoh hasil citra sebelum dan sesudah dilakukan *noise reduction* ditunjukkan pada Gambar 3.4.




Gambar 3. 4 Hasil *Noise Reduction*

3.4.3 Resize

Tahap ketiga adalah melakukan *resize* pada citra hasil potongan otak. Tujuan *resize* adalah menyeragamkan ukuran seluruh citra agar memiliki dimensi yang konsisten sebelum masuk ke tahap ekstraksi fitur. Pada penelitian ini, ukuran citra ditetapkan menjadi 256×256 piksel.

Agar struktur otak tidak mengalami distorsi akibat perbedaan rasio panjang dan lebar pada citra hasil *Cropping*, proses *resize* dilakukan dengan metode *aspect ratio preserving*, artinya citra diubah ukurannya dengan tetap mempertahankan perbandingan panjang dan lebar aslinya. Apabila setelah di *resize* ukuran citra belum sesuai dengan target 256×256 , maka ditambahkan *padding* berwarna hitam pada sisi citra hingga mencapai ukuran yang seragam. Pendekatan ini dipilih karena latar belakang citra MRI umumnya berwarna hitam, sehingga penambahan *padding* tidak memengaruhi informasi utama pada area otak.

Dengan demikian, hasil *resize* yang diperoleh memiliki ukuran dan format yang seragam, sehingga memudahkan proses ekstraksi fitur tekstur dan meningkatkan konsistensi hasil klasifikasi. Contoh hasil citra sebelum dan sesudah dilakukan proses *resize* ditunjukkan pada Gambar 3.5.




Gambar 3. 5 Hasil *Resize*

3.5 Ekstraksi Fitur GLCM

Ekstraksi fitur dalam penelitian ini dilakukan dengan metode *Gray Level Co-occurrence Matrix* (GLCM) yang digunakan untuk memperoleh karakteristik tekstur dari citra MRI otak. Proses ini bertujuan untuk mengubah informasi visual citra menjadi representasi numerik berupa fitur tekstur yang lebih mudah diolah

oleh algoritma klasifikasi. Tahapan proses ekstraksi fitur GLCM ditunjukkan pada Gambar 3.6.



Gambar 3. 6 Blok Diagram GLCM

3.5.1 Pembentukan Matriks *Co-Occurrence*

Pada tahap ini, citra hasil praproses digunakan sebagai masukan untuk perhitungan GLCM. Proses dimulai dengan pembentukan matriks *co-occurrence*, yaitu penghitungan frekuensi kemunculan pasangan nilai keabuan antar-piksel pada jarak tertentu. Sebelum dilakukan perhitungan, nilai intensitas citra disesuaikan ke dalam sejumlah level tertentu agar ukuran matriks lebih efisien untuk dihitung.

Sebagai ilustrasi perhitungan GLCM, digunakan sebuah citra berukuran 3×3 piksel dengan rentang intensitas abu-abu 0–255. Potongan citra tersebut ditampilkan dalam bentuk matriks berikut:

$$\begin{bmatrix} 98 & 173 & 255 \\ 67 & 148 & 37 \\ 221 & 108 & 187 \end{bmatrix}$$

Matriks ini mewakili nilai intensitas *grayscale* dari masing-masing piksel pada citra. Nilai terkecil dalam matriks adalah 37 dan nilai terbesar adalah 255. Selanjutnya dilakukan kuantisasi untuk menyederhanakan nilai intensitas 0–255 menjadi level tertentu agar ukuran GLCM lebih kecil (Barburiceanu *et al.*, 2021). Pada ilustrasi ini digunakan 8 level untuk contoh perhitungan, sedangkan pada implementasi penelitian secara keseluruhan digunakan 16 level keabuan. Dengan demikian, rentang intensitas pada ilustrasi dibagi dalam interval yang ditunjukkan pada tabel 3.2 berikut:

Tabel 3. 2 Tabel Level Kuantisasi

Level	Rentang Nilai Intensitas
0	0 – 31
1	32 – 63
2	64 – 95
3	96 – 127
4	128 – 159
5	160 – 191
6	192 – 223
7	224 – 255

Maka matriks setelah kuantisasi menjadi

$$\begin{bmatrix} 3 & 5 & 7 \\ 2 & 4 & 1 \\ 6 & 3 & 5 \end{bmatrix}$$

Perhitungan GLCM pada ilustrasi ini dilakukan pada arah 0 (horizontal ke kanan) dengan jarak $d = 1$. Artinya, setiap piksel akan dipasangkan dengan piksel yang berada tepat di sebelah kanannya dalam satu baris. Pada implementasi penelitian, GLCM tidak hanya dihitung pada satu arah, tetapi pada empat orientasi sudut, yaitu 0° , 45° , 90° , dan 135° dengan jarak piksel yang sama, yaitu $d = 1$ untuk setiap sudut. Jarak $d = 1$ dipilih untuk menangkap detail tekstur yang paling halus, sedangkan empat orientasi sudut digunakan karena pola jaringan tumor otak tidak

tumbuh satu arah, sehingga perlu dihitung dari berbagai sisi agar karakteristik teksturnya tertangkap secara utuh.

Dengan konfigurasi pada ilustrasi, pasangan-pasangan piksel (i, j) yang diperoleh dari matriks kuantisasi adalah (3, 5) (5, 7) (2, 4) (4, 1) (6, 3) (3, 5), kemudian dihitung jumlah kemunculan masing masing pasangan. Hasil perhitungan frekuensi ditunjukkan pada matriks berikut:

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 2 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Kemudian dilakukan penjumlahan dengan matriks transpose nya, sehingga mendapatkan hasil:

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 2 & 1 & 0 \\ 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 2 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

3.5.2 Normalisasi

Setelah matriks *co-occurrence* terbentuk, langkah berikutnya adalah melakukan normalisasi. Normalisasi bertujuan untuk mengubah nilai frekuensi pada GLCM menjadi nilai probabilitas, sehingga setiap elemen matriks berada pada rentang 0 hingga 1 dan jumlah total seluruh elemen bernilai satu. Dengan demikian,

setiap elemen pada matriks hasil normalisasi merepresentasikan peluang relatif kemunculan pasangan intensitas piksel pada jarak dan arah tertentu.

Proses normalisasi dilakukan dengan cara membagi setiap nilai pada elemen matriks GLCM dengan jumlah total keseluruhan nilai GLCM. Pada ilustrasi ini jumlah total frekuensi adalah 12. Sehingga diperoleh matriks normalisasi GLCM berikut:

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1/12 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1/12 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 2/12 & 1/12 & 0 \\ 0 & 1/12 & 1/12 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 2/12 & 0 & 0 & 0 & 1/12 \\ 0 & 0 & 0 & 1/12 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1/12 & 0 & 0 \end{bmatrix}$$

Normalisasi ini memastikan bahwa nilai GLCM dapat dibandingkan antar citra dengan skala yang berbeda, karena semua nilai telah dikonversi ke bentuk probabilitas. Hasil normalisasi inilah yang kemudian digunakan pada tahap perhitungan fitur tekstur.

3.5.3 Ekstraksi Fitur Tekstur

Setelah matriks GLCM dinormalisasi, langkah berikutnya adalah menghitung nilai fitur tekstur yang akan digunakan sebagai representasi citra. Pada penelitian ini digunakan empat fitur yang umum dipakai dalam analisis tekstur, yaitu *Contrast*, *Correlation*, *Energy (ASM)*, dan *Homogeneity*. Pemilihan keempat fitur ini mengacu pada penelitian Dixon *et al.* (2024), yang menggunakan kombinasi fitur tersebut dalam klasifikasi citra MRI tumor otak dan memperoleh

akurasi sebesar 99,19% sehingga menunjukkan bahwa keempat fitur ini sudah representatif dalam menggambarkan pola tekstur jaringan otak.

1. *Contrast*

Fitur *contrast* dihitung menggunakan konsep pada Persamaan 2.1. Sebagai contoh, pada matriks normalisasi terdapat pasangan (1,4) dengan probabilitas $\frac{1}{12}$. Maka kontribusinya terhadap nilai *contrast* adalah:

$$Contr_{(1,4)} = (1 - 4)^2 \times \frac{1}{12} = \frac{9}{12}$$

Begitu pula untuk seluruh pasangan (i,j) yang ada pada matriks. Jika semua pasangan dihitung dan dijumlahkan, maka diperoleh total nilai *Contrast*:

$$Contrast = \frac{9 + 8 + 4 + 9 + 4 + 9 + 8 + 4 + 9 + 4}{12} = \frac{68}{12} = 5,66$$

2. *Correlation*

Perhitungan *correlation* dilakukan berdasarkan Persamaan 2.2, dengan langkah awal menghitung rata-rata (μ) dan simpangan baku (σ) sesuai Persamaan (2.3) sampai (2.6). Dari matriks GLCM diperoleh:

$$\begin{aligned} \mu &= \frac{(1 \times 1) + (2 \times 1) + (3 \times 2) + (4 \times 2) + (5 \times 2) + (6 \times 1) + (7 \times 1)}{12} \\ &= \frac{48}{12} \end{aligned}$$

Sebagai contoh, untuk pasangan (3,5) dengan probabilitas $\frac{2}{12}$, kontribusinya adalah:

$$\sigma_{(3,5)} = (3 - \frac{48}{12})^2 \times \frac{2}{12} = \frac{2}{12}$$

Jika seluruh pasangan dihitung dan dijumlahkan, maka diperoleh:

$$\sigma = \sqrt{\frac{32}{12}} = 1.633$$

Dengan μ dan σ yang telah diketahui, perhitungan *correlation* dapat dilakukan. Sebagai contoh, untuk pasangan (3,5) diperoleh:

$$corr_{(3,5)} = \frac{(3 - \frac{48}{12}) \times (5 - \frac{48}{12}) \times \frac{2}{12}}{\frac{32}{12} \times \frac{32}{12}} = -\frac{24}{1024}$$

Sehingga nilai akhir *correlation* adalah:

$$\begin{aligned} correlation &= \frac{(-24) + (-24) + (-24) + (-24) + 36 + 36}{1024} = -\frac{64}{1024} \\ &= -0,0625 \end{aligned}$$

3. *Energy*

Fitur *energy* dihitung menggunakan Persamaan 2.7. Pada matriks normalisasi terdapat delapan elemen bernilai $1/12$ dan dua elemen bernilai $2/12$ sehingga nilai *energy* dihitung sebagai:

$$energy = \frac{1^2 + 1^2 + 1^2 + 1^2 + 1^2 + 1^2 + 1^2 + 1^2 + 2^2 + 2^2}{12^2} = 0,111$$

4. *Homogeneity*

Perhitungan *homogeneity* berdasarkan Persamaan 2.8. Sebagai contoh, untuk pasangan (1,4) dengan probabilitas $1/12$ kontribusinya terhadap *Homogeneity* dihitung sebagai:

$$Hom_{(1,4)} = \frac{\frac{1}{12}}{1 + |(1 - 4)|} = \frac{1}{48}$$

Jika semua pasangan dihitung dan dijumlahkan, maka diperoleh:

$$Homogeneity = \frac{1}{48} + \frac{1}{48} + \frac{1}{48} + \frac{1}{48} + \frac{2}{36} + \frac{2}{36} + \frac{1}{36} + \frac{1}{36} = 0,305$$


Dengan demikian, dari ilustrasi perhitungan GLCM ini diperoleh keempat fitur tekstur yaitu:

$$x_1 = [5.66, -0.0625, 0.111, 0.305]$$

Keempat fitur tersebut selanjutnya digunakan sebagai representasi numerik citra MRI untuk tahap klasifikasi menggunakan algoritma SVM. Pada implementasi penelitian, perhitungan empat fitur tekstur ini dilakukan pada empat sudut GLCM (0° , 45° , 90° , dan 135°), sehingga setiap citra direpresentasikan oleh total 16 fitur tekstur ($4 \text{ fitur} \times 4 \text{ sudut}$) yang menjadi masukan bagi model SVM.

3.6 Implementasi Metode SVM

Tahap ini merupakan implementasi algoritma SVM sebagai metode klasifikasi jenis tumor otak berdasarkan fitur tekstur hasil ekstraksi GLCM. Proses ini bertujuan untuk membangun model klasifikasi yang mampu mengenali jenis tumor otak secara otomatis berdasarkan pola tekstur citra MRI. Blok diagram tahapan metode SVM ditunjukkan pada Gambar 3.7.



Gambar 3. 7 Blok Diagram SVM

3.6.1 Strategi Klasifikasi *One vs All*

Implementasi metode SVM pada penelitian ini menggunakan pendekatan *One-vs-All* dengan data hasil ekstraksi fitur GLCM dari citra MRI otak. Pendekatan ini dipilih karena *One-vs-All* lebih ringan secara komputasi. Setiap kelas diperlakukan sebagai kelas positif (+1), sementara tiga kelas lainnya dianggap sebagai kelas negatif (-1), sehingga proses klasifikasi dilakukan melalui pembentukan beberapa model SVM biner. Dengan strategi tersebut, terbentuk empat *classifier*, yaitu:

- a. *Glioma vs All*
- b. *Meningioma vs All*
- c. *Pituitary vs All*
- d. *No. Tumor vs All*

Setiap *classifier* menghasilkan parameter w_k dan b_k yang berbeda, yang selanjutnya digunakan untuk menghitung nilai fungsi keputusan $f_k(x)$. Pada tahap akhir, hasil klasifikasi ditentukan berdasarkan nilai fungsi keputusan terbesar dari keempat *classifier* tersebut.

3.6.2 Proses Pelatihan Model

Setelah strategi klasifikasi ditentukan, tahap berikutnya adalah proses pelatihan model SVM untuk memperoleh parameter optimal pada setiap *classifier*. Proses ini dilakukan menggunakan data hasil ekstraksi fitur GLCM dari citra MRI otak. Masing-masing citra direpresentasikan dalam bentuk vektor fitur yang memuat empat parameter tekstur, yaitu *contrast*, *correlation*, *energy*, dan *homogeneity*. Digunakan empat citra MRI yang masing-masing mewakili satu kelas berbeda. Vektor fitur dari keempat citra tersebut ditunjukkan sebagai berikut:

$$x_1 = [5.66, -0.06, 0.11, 0.31] \quad (Glioma)$$

$$x_2 = [4.12, 0.02, 0.10, 0.29] \quad (Meningioma)$$

$$x_3 = [3.45, -0.03, 0.08, 0.25] \quad (Pituitary)$$

$$x_4 = [2.70, 0.00, 0.05, 0.20] \quad (No Tumor)$$

Pada ilustrasi ini, ditunjukkan proses pelatihan SVM *linear* untuk *classifier* *Glioma* (+1) dengan kelas lainnya (-1). Setiap sampel diberi label kelas sebagai berikut:

$$x_1 = [5.66, -0.06, 0.11, 0.31], \quad y_1 = +1 \quad (Glioma)$$

$$x_2 = [4.12, 0.02, 0.10, 0.29], \quad y_2 = -1 \quad (Meningioma)$$

$$x_3 = [3.45, -0.03, 0.08, 0.25], \quad y_3 = -1 \quad (Pituitary)$$

$$x_4 = [2.70, 0.00, 0.05, 0.20], \quad y_4 = -1 \quad (No Tumor)$$

Sebelum proses pelatihan dimulai, dilakukan inisialisasi parameter awal berupa bobot dan bias agar model memiliki titik awal pembelajaran. Nilai inisialisasi yang digunakan adalah:

$$w = [0.5, 0.5, 0.5, 0.5], \quad b = 0.5, \quad \eta = 1$$

Langkah pertama adalah menghitung margin untuk x_1 (*glioma* $y_1 = +1$).

Perhitungan margin dilakukan berdasarkan Persamaan 2.10:

$$\begin{aligned} y_1(w \cdot x_1 + b) &= 1 \times ([0.5, 0.5, 0.5, 0.5] \cdot [5.66, -0.06, 0.11, 0.31] + 0.5) \\ &= 1 \times ((0.5 \times 5.66) + (0.5 \times -0.06) + (0.5 \times 0.11) + \\ &\quad (0.5 \times 0.31) + 0.5) \\ &= 1 \times (2.83 - 0.03 + 0.06 + 0.16 + 0.5) \\ &= 1 \times 3.52 \\ &= 3.52 \end{aligned}$$

Nilai margin $3.52 \geq 1$, sehingga x_1 telah memenuhi margin dan tidak memerlukan pembaruan. Kemudian dilanjutkan dengan menghitung margin untuk x_2 (*meningioma* $y_1 = -1$) dengan menggunakan parameter yang sama.

$$\begin{aligned}
y_2(w \cdot x_2 + b) &= -1 \times ([0.5, 0.5, 0.5, 0.5] \cdot [4.12, 0.02, 0.10, 0.29] + 0.5) \\
&= -1 \times ((0.5 \times 4.12) + (0.5 \times 0.02) + (0.5 \times 0.10) + \\
&\quad (0.5 \times 0.29) + 0.5) \\
&= -1 \times (2.06 + 0.01 + 0.05 + 0.15 + 0.5) \\
&= -1 \times 2.77 \\
&= -2.77
\end{aligned}$$

Karena hasilnya lebih kecil daripada 1, maka data x_2 melanggar margin sehingga dilakukan pembaruan parameter berdasarkan Persamaan 2.11 dan 2.12:

$$\begin{aligned}
w &= w + \eta \times y_2 \times x_2 \\
&= [0.5, 0.5, 0.5, 0.5] + 1 \times (-1) \times [4.12, 0.02, 0.10, 0.29] \\
&= [0.5 - 4.12, 0.5 - 0.02, 0.5 - 0.10, 0.5 - 0.29] \\
&= [-3.62, 0.48, 0.4, 0.21] \\
b &= b + \eta \times y_2 \\
&= 0.5 + 1 \times (-1) \\
&= -0.5
\end{aligned}$$

Setelah terjadi pembaruan, dilakukan verifikasi agar x_1 tetap berada pada sisi yang benar dari hyperplane menggunakan Persamaan 2.10:

$$\begin{aligned}
y_1(w \cdot x_1 + b) &= 1 \times ([-3.62, 0.48, 0.4, 0.21] \cdot [5.66, -0.06, 0.11, 0.31] - 0.5) \\
&= 1 \times ((-3.62 \times 5.66) + (0.48 \times -0.06) + (0.4 \times 0.11) + \\
&\quad (0.21 \times 0.31) - 0.5) \\
&= 1 \times (-20.49 - 0.03 + 0.05 + 0.07 - 0.5) \\
&= 1 \times -20.9 \\
&= -20.9
\end{aligned}$$

Karena -20.9 kurang dari 1, maka dilakukan pembaruan dengan $y_1 = +1$ dengan menggunakan Persamaan 2.11 dan Persamaan 2.12.

$$\begin{aligned}
w &= w + \eta \times y_1 \times x_1 \\
&= [-3.62, 0.48, 0.4, 0.21] + 1 \times 1 \times [5.66, -0.06, 0.11, 0.31] \\
&= [-3.62 + 5.66, 0.48 - 0.06, 0.4 + 0.11, 0.21 + 0.31] \\
&= [2.04, 0.42, 0.51, 0.52]
\end{aligned}$$

$$\begin{aligned}
b &= b + \eta \times y_1 \\
&= 0.5 + 1 \times 1 \\
&= 0.5
\end{aligned}$$

Setelah terjadi pembaruan, dilakukan verifikasi ulang pada x_1 dengan menggunakan Persamaan 2.10.

$$\begin{aligned}
y_1(w \cdot x_1 + b) &= 1 \times ([2.04, 0.42, 0.51, 0.52] \cdot [5.66, -0.06, 0.11, 0.31] + 0.5) \\
&= 1 \times ((2.04 \times 5.66) + (0.42 \times -0.06) + (0.51 \times 0.11) + \\
&\quad (0.52 \times 0.31) + 0.5) \\
&= 1 \times (11.55 - 0.03 + 0.06 + 0.16 + 0.5) \\
&= 12.24
\end{aligned}$$

Hasil nilai margin melebihi 1, sehingga telah memenuhi margin dan tidak memerlukan pembaruan. Setelah itu, proses pelatihan dilanjutkan pada data selanjutnya menggunakan Persamaan 2.10.

$$\begin{aligned}
y_3(w \cdot x_3 + b) &= -1 \times ([2.04, 0.42, 0.51, 0.52] \cdot [3.45, -0.03, 0.08, 0.25] \\
&\quad + 0.5) \\
&= -1 \times ((2.04 \times 3.45) + (0.42 \times -0.03) + (0.51 \times 0.08) \\
&\quad + (0.52 \times 0.25) + 0.5) \\
&= -1 \times (5.49 - 0.01 + 0.04 + 0.13 + 0.5) \\
&= -1 \times 6.15 \\
&= -6.15
\end{aligned}$$

Karena hasil margin kurang dari 1 maka dilakukan pembaruan parameter berdasarkan Persamaan 2.11 dan Persamaan 2.12.

$$\begin{aligned}
w &= w + \eta \times y_3 \times x_3 \\
&= [2.04, 0.42, 0.51, 0.52] + 1 \times (-1) \times [3.45, -0.03, 0.08, 0.25] \\
&= [2.04 - 3.45, 0.42 + 0.03, 0.51 - 0.08, 0.52 - 0.25] \\
&= [-1.41, 0.45, 0.43, 0.27] \\
b &= b + \eta \times y_3 \\
&= 0.5 + 1 \times (-1) \\
&= -0.5
\end{aligned}$$

Kemudian dilakukan pemeriksaan untuk x_4 menggunakan persamaan 2.10.

$$\begin{aligned}
 y_4(w \cdot x_4 + b) &= -1 \times ([-1.41, 0.45, 0.43, 0.27] \cdot [2.70, 0, 0.05, 0.20] - 0.5) \\
 &= -1 \times ((-1.41 \times 2.70) + (0.45 \times 0) + (0.43 \times 0.05) + \\
 &\quad (0.27 \times 0.20) - 0.5) \\
 &= -1 \times (-3.81 + 0 + 0.02 + 0.05 - 0.5) \\
 &= -1 \times -4.24 \\
 &= 4.24
 \end{aligned}$$

Karena margin lebih dari 1, maka tidak dilakukan pembaruan. Dengan demikian parameter akhir untuk *classifier Glioma vs All* adalah

$$w = [-1.41, 0.45, 0.43, 0.27], \quad b = 0.5$$

Dengan prosedur yang sama dengan menggunakan Persamaan 2.10 hingga 2.12 dan urutan data x_1 hingga x_4 sesuai label masing-masing *classifier*, diperoleh hasil parameter akhir sebagai berikut:

$$\begin{aligned}
 C_1 &= \text{Glioma vs All}, & w_1 &= [-1.41, 0.45, 0.43, 0.27], & b_1 &= 0.5 \\
 C_2 &= \text{Meningioma vs All}, & w_2 &= [-1.04, 0.58, 0.49, 0.48], & b_2 &= 0.5 \\
 C_3 &= \text{Pituitary vs All}, & w_3 &= [-1.71, 0.53, 0.47, 0.45], & b_3 &= 0.5 \\
 C_4 &= \text{No Tumor vs All}, & w_4 &= [-2.46, 0.56, 0.44, 0.39], & b_4 &= 0.5
 \end{aligned}$$

3.6.3 Proses Prediksi

Tahap terakhir adalah proses prediksi, yang bertujuan untuk menentukan kelas citra uji berdasarkan nilai fungsi keputusan dari masing-masing *classifier* yang telah dilatih pada tahap sebelumnya. Prediksi dilakukan menggunakan fungsi keputusan SVM sesuai Persamaan 2.13, di mana setiap *classifier* akan menghasilkan satu nilai keputusan. Nilai fungsi keputusan tertinggi akan

menunjukkan kelas akhir citra uji sesuai pendekatan *One-vs-All*. Sebagai ilustrasi, diberikan satu vektor uji sebagai masukan:

$$x_t = [4.50, -0.01, 0.09, 0.28]$$

Nilai fungsi Keputusan dari masing masing *classifier* dihitung sebagai berikut:

$$\begin{aligned} f_1(x_t) &= [-1.41, 0.45, 0.43, 0.27] \cdot [4.50, -0.01, 0.09, 0.28] + 0.5 \\ &= (-1.41 \times 4.50) + (0.45 \times (-0.01)) + (0.43 \times 0.09) + (0.27 \times 0.28) \\ &\quad + 0.5 \\ &= -6.35 - 0.01 + 0.04 + 0.07 + 0.5 \\ &= -6.75 \end{aligned}$$

$$\begin{aligned} f_2(x_t) &= [-1.04, 0.58, 0.49, 0.48] \cdot [4.50, -0.01, 0.09, 0.28] + 0.5 \\ &= (-1.04 \times 4.50) + (0.58 \times (-0.01)) + (0.49 \times 0.09) + (0.48 \times 0.28) \\ &\quad + 0.5 \\ &= -4.68 - 0.01 + 0.04 + 0.13 + 0.5 \\ &= -4.02 \end{aligned}$$

$$\begin{aligned} f_3(x_t) &= [-1.71, 0.53, 0.47, 0.45] \cdot [4.50, -0.01, 0.09, 0.28] + 0.5 \\ &= (-1.71 \times 4.50) + (0.53 \times (-0.01)) + (0.47 \times 0.09) + (0.45 \times 0.28) \\ &\quad + 0.5 \\ &= -7.7 - 0.01 + 0.04 + 0.13 + 0.5 \\ &= -7.04 \end{aligned}$$

$$\begin{aligned} f_4(x_t) &= [-2.46, 0.56, 0.44, 0.39] \cdot [4.50, -0.01, 0.09, 0.28] + 0.5 \\ &= (-2.46 \times 4.50) + (0.56 \times (-0.01)) + (0.44 \times 0.09) + (0.39 \times 0.28) \\ &\quad + 0.5 \\ &= -11.07 - 0.01 + 0.04 + 0.11 \\ &= -10.93 \end{aligned}$$

Selanjutnya, penentuan kelas dilakukan dengan membandingkan nilai fungsi keputusan dari masing-masing *classifier*. Kelas yang memiliki nilai fungsi

keputusan tertinggi akan menjadi hasil prediksi akhir. Pada contoh ini, diperoleh bahwa:

$$\max \{f_1, f_2, f_3, f_4\} = f_2(x_t)$$

Sehingga citra uji diklasifikasikan ke dalam kelas *meningioma*.

3.7 Evaluasi

Evaluasi dilakukan untuk menilai kinerja model SVM dalam mengklasifikasikan citra MRI tumor otak ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*. Tahap ini bertujuan untuk mengetahui tingkat ketepatan prediksi model melalui pengukuran berbasis *Confusion matrix* serta perhitungan metrik akurasi, presisi, *Recall*, dan *F1-score*.

Confusion matrix digunakan untuk menggambarkan distribusi hasil prediksi model terhadap label aktual pada klasifikasi *multiclass*. Pada penelitian ini, *Confusion matrix* berbentuk matriks 4×4 yang merepresentasikan empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor* yang ditunjukkan pada Tabel 3.3.

Tabel 3. 3 *Confusion matrix* 4 Kelas

Actual Class	Predicted Class			
	<i>Glioma</i>	<i>Meningioma</i>	<i>Pituitary</i>	<i>No tumor</i>
<i>Glioma</i>	TP			
<i>Meningioma</i>		TP		
<i>Pituitary</i>			TP	
<i>No tumor</i>				TP

Setiap baris menunjukkan jumlah data aktual dari masing-masing kelas, sedangkan setiap kolom menunjukkan hasil prediksi model. Nilai pada diagonal utama menyatakan jumlah data yang diprediksi dengan benar sesuai kelasnya,

sedangkan nilai di luar diagonal menunjukkan jumlah data yang salah diprediksi sebagai kelas lain.

Dalam analisis *Confusion matrix*, digunakan empat istilah utama:

- a. *True Positive* (TP) adalah jumlah data dari suatu kelas yang diprediksi benar oleh model sebagai kelas tersebut.
- b. *True Negative* (TN) adalah jumlah data yang bukan dari kelas tertentu dan diprediksi dengan benar bukan sebagai kelas tersebut.
- c. *False Positive* (FP) adalah jumlah data dari kelas lain tetapi salah diprediksi sebagai kelas tertentu.
- d. *False Negative* (FN) adalah jumlah data dari suatu kelas yang salah diprediksi sebagai kelas lain.

Keempat komponen ini menjadi dasar perhitungan metrik evaluasi model.

Dengan memanfaatkan nilai TP, TN, FP, dan FN, dapat dihitung ukuran performa seperti akurasi, presisi, *Recall*, dan *F1-score*.

1. Akurasi

Akurasi mengukur proporsi prediksi yang benar terhadap seluruh citra uji dari keempat kelas tumor otak. Metrik ini menunjukkan seberapa baik model mengklasifikasikan citra MRI secara keseluruhan. Adapun rumus untuk menghitung nilai akurasi dinyatakan dalam Persamaan 3.1.

$$Akurasi = \frac{\sum_{i=1}^K TP_i}{N} \quad (3.1)$$

Dimana:

K = Jumlah kelas

TP_i = Jumlah data yang benar per kelas

N = Total seluruh data uji

Nilai akurasi tinggi menunjukkan bahwa sebagian besar citra (*glioma*, *meningioma*, *pituitary*, dan *no tumor*) berhasil diprediksi dengan benar. Namun, akurasi saja tidak selalu cukup menggambarkan kinerja model pada klasifikasi medis, terutama jika distribusi data antar kelas tidak seimbang (Hicks *et al.*, 2022).

2. Presisi

Presisi menggambarkan tingkat ketepatan model dalam memprediksi suatu kelas tertentu, misalnya seberapa tepat model dalam mengklasifikasikan citra sebagai *meningioma*. Nilai presisi yang tinggi menunjukkan bahwa sebagian besar citra yang diprediksi sebagai *meningioma* memang benar berasal dari kelas *meningioma*. Secara matematis, presisi dihitung berdasarkan Persamaan 3.2.

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

Pada kasus medis, presisi penting untuk meminimalkan jumlah positif palsu (FP), yaitu kondisi ketika pasien sehat salah diprediksi memiliki tumor. Meskipun demikian, nilai presisi yang rendah masih dapat ditoleransi jika *Recall* tinggi, karena lebih baik melakukan pemeriksaan tambahan daripada melewatkan pasien yang benar-benar menderita tumor.

3. Recall

Recall, atau sensitivitas, mengukur kemampuan model dalam menemukan seluruh citra dari suatu kelas, misalnya mendeteksi seluruh citra *pituitary* dengan benar. Nilai *Recall* didefinisikan dalam Persamaan 3.3.

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

Dalam penelitian medis seperti klasifikasi tumor otak, *Recall* menjadi metrik utama karena mendeteksi sebagian besar kasus positif dan meminimalkan negatif palsu (FN), yang dapat menyebabkan keterlambatan diagnosis dan memperburuk kondisi pasien (Kocak *et al.*, 2025).

4. *F1-score*

F1-score merupakan rata-rata harmonik antara presisi dan *Recall*, yang memberikan gambaran seimbang antara ketepatan prediksi dan kemampuan model menemukan citra dari suatu kelas. Perhitungan *F1-score* disajikan dalam Persamaan 3.4.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3.4)$$

Dalam klasifikasi tumor otak, *F1-score* memberikan gambaran apakah model tidak hanya mampu mendeteksi kasus tumor dengan baik (*Recall* tinggi), tetapi juga mampu menghindari terlalu banyak salah deteksi (presisi tinggi). Nilai *F1-score* yang baik menunjukkan model seimbang antara mendeteksi sebanyak mungkin kasus tumor dan menjaga ketepatan hasil prediksi.

Setelah penjelasan mengenai masing-masing metrik evaluasi, dilakukan ilustrasi perhitungan berdasarkan *Confusion matrix* hasil klasifikasi yang ditampilkan pada Tabel 3.4. Bagian ini menunjukkan implementasi proses evaluasi model untuk memperoleh nilai akurasi, presisi, *Recall*, dan *F1-score* dari data hasil prediksi.

Tabel 3. 4 Data *Confusion matrix*

<i>Actual Class</i>	<i>Predicted Class</i>			
	<i>Glioma</i>	<i>Meningioma</i>	<i>Pituitary</i>	<i>No tumor</i>
<i>Glioma</i>	10	2	6	1
<i>Meningioma</i>	3	15	2	3
<i>Pituitary</i>	7	1	12	5

<i>Actual Class</i>	<i>Predicted Class</i>			
	<i>Glioma</i>	<i>Meningioma</i>	<i>Pituitary</i>	<i>No tumor</i>
<i>No tumor</i>	5	2	0	18

Berdasarkan Tabel 3.4, jumlah keseluruhan data uji adalah sebanyak 92 citra MRI, dengan total prediksi benar (nilai diagonal utama) sebanyak 55 citra. Nilai akurasi dihitung menggunakan Persamaan 3.1 sebagai berikut:

$$Akurasi = \frac{55}{92} = 0,598$$

Selanjutnya, perhitungan presisi, *Recall*, dan *F1-score* dilakukan untuk masing-masing kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*, menggunakan Persamaan 3.2 untuk presisi, Persamaan 3.3 untuk *Recall* dan Persamaan 3.4 untuk *F1-score*. Sebagai contoh, perhitungan untuk kelas *glioma* adalah sebagai berikut:

$$Presisi_{glioma} = \frac{10}{10 + 15} = \frac{10}{25} = 0,4$$

$$Recall_{glioma} = \frac{10}{10 + 9} = \frac{10}{19} = 0,526$$

$$F1 - Score_{glioma} = \frac{2 \times 0,4 \times 0,526}{0,4 + 0,526} = \frac{0,421}{0,926} = 0,455$$

Prosedur yang sama diterapkan untuk tiga kelas lainnya. Nilai rata-rata antar kelas diperoleh sebagai berikut:

$$Presisi = \frac{0,4 + 0,75 + 0,6 + 0,667}{4} = \frac{2,417}{4} = 0,604$$

$$Recall = \frac{0,526 + 0,652 + 0,48 + 0,72}{4} = \frac{2,378}{4} = 0,595$$

$$F1 - Score = \frac{0,455 + 0,698 + 0,533 + 0,692}{4} = \frac{2,378}{4} = 0,594$$

Berdasarkan hasil perhitungan tersebut, model SVM memperoleh akurasi sebesar 0,598, presisi rata-rata sebesar 0,604, *Recall* rata-rata sebesar 0,595, dan *F1-score* rata-rata sebesar 0,594.

3.8 Skenario Uji Coba

Skenario uji coba pada penelitian ini difokuskan untuk mengevaluasi kinerja metode klasifikasi SVM berdasarkan fitur tekstur yang diekstraksi menggunakan GLCM dari citra MRI otak. Dataset yang digunakan memiliki empat kelas utama, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*. Setiap kelas memiliki variasi citra berdasarkan sudut pandang berbeda, yaitu atas (*axial*), samping (*sagittal*), dan belakang (*coronal*).

Untuk memperoleh hasil yang komprehensif, pengujian dilakukan secara terpisah pada masing-masing sudut pandang. Selain itu, setiap sudut pandang diuji menggunakan dua kondisi dataset, yaitu dataset seimbang (*balanced dataset*) yang jumlah citranya disamakan tiap kelas yaitu 45, dan dataset tidak seimbang (*imbalanced dataset*) yang mempertahankan jumlah asli sesuai distribusi awal.

Setiap kondisi dataset kemudian diuji menggunakan empat jenis kernel pada algoritma SVM, yaitu *Linear*, *RBF*, *Sigmoid*, dan *Polynomial*. Pemilihan parameter mengacu pada penelitian Faradisya dan Pakereng (2025) yang menerapkan metode *grid search* dengan rentang $C = \{0.1, 1, 10\}$, $\gamma = \{0.01, 0.1, 1\}$, $\text{degree} = \{2, 3, 4\}$, dan $\text{coef0} = \{0, 0.1, 1\}$ pada algoritma SVM. Rentang parameter yang sama digunakan dalam penelitian ini untuk mencari kombinasi hyperparameter terbaik pada setiap kernel dan kondisi dataset.

Dengan demikian, total terdapat 24 skenario pengujian, yang merupakan hasil kombinasi antara tiga sudut pandang citra MRI, dua kondisi dataset, dan empat jenis kernel SVM. Rincian kombinasi skenario pengujian disajikan pada Tabel 3.5.

Tabel 3. 5 Skenario Pengujian

No.	Kondisi Dataset	Dataset (Sudut Pandang Citra)	Kernel SVM
1.	<i>Balanced</i>	Sudut Pandang Atas	<i>Linear</i>
2.			<i>Polynomial</i>
3.			RBF
4.			<i>Sigmoid</i>
5.		Sudut Pandang Samping	<i>Linear</i>
6.			<i>Polynomial</i>
7.			RBF
8.			<i>Sigmoid</i>
9.		Sudut Pandang Belakang	<i>Linear</i>
10.			<i>Polynomial</i>
11.			RBF
12.			<i>Sigmoid</i>
13.	<i>Imbalanced</i>	Sudut Pandang Atas	<i>Linear</i>
14.			<i>Polynomial</i>
15.			RBF
16.			<i>Sigmoid</i>
17.		Sudut Pandang Samping	<i>Linear</i>
18.			<i>Polynomial</i>
19.			RBF
20.			<i>Sigmoid</i>
21.		Sudut Pandang Belakang	<i>Linear</i>
22.			<i>Polynomial</i>
23.			RBF
24.			<i>Sigmoid</i>

BAB IV


HASIL DAN PEMBAHASAN

4.1 Hasil Uji Coba

Uji coba dilakukan untuk mengukur performa metode GLCM dan SVM dalam mengklasifikasikan jenis tumor otak berdasarkan citra MRI. Pengujian dilakukan dengan membandingkan empat kernel SVM (*Linear*, *Polynomial*, *RBF*, dan *Sigmoid*) yang telah melalui tahap optimasi parameter (*Grid Search*) pada tiga sudut pandang citra (*axial*, *sagittal*, dan *coronal*) serta dua kondisi dataset (*balanced* dan *imbalanced*). Seluruh skenario menggunakan pembagian data latih dan data uji sebesar 80% : 20%. Performa model dievaluasi menggunakan *Confusion matrix*.

4.1.1 Hasil Skenario Uji 1

Hasil skenario uji 1 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang atas (*axial*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan Kernel *Linear* serta nilai *hyperparameter C* yang diperoleh dari hasil proses *tuning* dengan nilai terbaik, yaitu 10. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.1.

Gambar 4. 1 *Confusion matrix* Skenario Uji 1

Berdasarkan Gambar 4.1, model SVM dengan kernel *Linear* menghasilkan 28 data uji yang diklasifikasikan dengan benar dan 8 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *precision*, *recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 78%, sedangkan nilai *precision*, *recall*, dan *F1-score* ditunjukkan pada Tabel 4.1.

Tabel 4. 1 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 1


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	73%	89%	80%
<i>Meningioma tumor</i>	70%	78%	74%
<i>No tumor</i>	83%	56%	67%
<i>Pituitary tumor</i>	89%	89%	89%

Berdasarkan Tabel 4.1 dan Gambar 4.1, nilai *F1-score* pada skenario ini berada pada rentang 67% hingga 89%. Kelas *pituitary tumor* menunjukkan kinerja terbaik dengan *F1-score* sebesar 89% dari 9 citra *pituitary*, 8 citra berhasil diklasifikasikan dengan benar sebagai *pituitary tumor* dan hanya 1 citra yang salah diprediksi sebagai *glioma tumor*, sehingga *Precision* dan *Recall* sama-sama tinggi. Kelas *glioma tumor* memiliki *F1-score* sebesar 80%, dengan 8 dari 9 citra *glioma*

terklasifikasi tepat, sedangkan 1 citra *glioma* salah diprediksi sebagai *meningioma tumor*; selain itu masih terdapat 3 citra dari kelas lain yang ikut diprediksi sebagai *glioma* sehingga *Precision* tidak mencapai 100%. Pada kelas *meningioma tumor*, nilai *F1-score* sebesar 74% diperoleh dari 7 citra yang dikenali dengan benar dari total 9 citra, sementara 1 citra *meningioma* salah diklasifikasikan sebagai *glioma tumor* dan 1 citra lainnya sebagai *no tumor*. Sementara itu, kelas *no tumor* memiliki *F1-score* terendah yaitu 67%; hanya 5 dari 9 citra otak sehat yang terklasifikasi benar, sedangkan 4 citra lainnya masing-masing salah diprediksi sebagai *glioma tumor*, *meningioma tumor*, dan *pituitary tumor*.

4.1.2 Hasil Skenario Uji 2

Hasil skenario uji 2 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang atas (*axial*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel *Polynomial*. Parameter terbaik diperoleh pada kombinasi $C = 1$, $coef0 = 0.1$, $degree = 2$, dan $gamma = 1$. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.2.



Gambar 4. 2 *Confusion matrix* Skenario Uji 2

Berdasarkan Gambar 4.2, model SVM dengan kernel *Polynomial* menghasilkan 25 data uji yang diklasifikasikan dengan benar dan 11 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 69%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.2.

Tabel 4. 2 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 2


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	67%	89%	76%
<i>Meningioma tumor</i>	67%	67%	67%
<i>No tumor</i>	100%	56%	71%
<i>Pituitary tumor</i>	60%	67%	63%

Berdasarkan Tabel 4.2 dan Gambar 4.2, kinerja model SVM dengan kernel *Polynomial* pada dataset *balanced* sudut pandang *axial* menunjukkan variasi performa antar kelas dengan nilai *F1-score* berada pada kisaran 63% hingga 76%. Kelas *glioma tumor* memiliki *F1-score* tertinggi sebesar 76% dengan *Precision* 67% dan *Recall* 89%; sebanyak 8 dari 9 citra *glioma* terklasifikasi dengan benar sebagai *glioma tumor*, sedangkan 1 citra lainnya salah diprediksi sebagai *meningioma tumor*. Pada kelas *meningioma tumor*, *F1-score* yang diperoleh sebesar 67% dengan 6 dari 9 citra *meningioma* dikenali sesuai kelasnya, sementara 3 citra lain masih salah diklasifikasikan sebagai *glioma tumor* dan *pituitary tumor*. Kelas *no tumor* memiliki *F1-score* 71% dengan *Precision* 100% dan *Recall* 56%, yang berarti seluruh prediksi *no tumor* berasal dari citra *no tumor*, namun hanya 5 dari 9 citra otak sehat yang berhasil dikenali dengan benar, sedangkan 4 citra lainnya diprediksi sebagai *glioma tumor*, *meningioma tumor*, dan *pituitary tumor*. Sementara itu, kelas *pituitary tumor* memiliki *F1-score* sebesar 63% dengan 6 dari

9 citra *pituitary* yang terklasifikasi benar dan 3 citra lainnya salah diprediksi sebagai *glioma tumor* dan *meningioma tumor*.

4.1.3 Hasil Skenario Uji 3

Hasil skenario uji 3 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang atas (*axial*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel RBF. Parameter terbaik diperoleh pada kombinasi $C = 10$, dan $\gamma = 0.1$. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.3.



Gambar 4. 3 *Confusion matrix* Skenario Uji 3

Berdasarkan Gambar 4.3, model SVM dengan kernel RBF menghasilkan 27 data uji yang diklasifikasikan dengan benar dan 9 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 75%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.3.

Tabel 4. 3 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 3

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	88%	78%	82%
<i>Meningioma tumor</i>	64%	78%	70%
<i>No tumor</i>	86%	67%	75%
<i>Pituitary tumor</i>	70%	78%	74%


Berdasarkan Tabel 4.3 dan Gambar 4.3, nilai *F1-score* pada skenario ini berada pada kisaran 70 persen hingga 82 persen. Kelas *glioma tumor* memiliki *F1-score* tertinggi yaitu 82 persen dengan *Precision* 88 persen dan *Recall* 78 persen. Sebanyak 7 dari 9 citra *glioma* terklasifikasi dengan benar sebagai *glioma tumor*, sedangkan 2 citra lainnya masih salah diprediksi sebagai *meningioma tumor*. Kelas *no tumor* memperoleh *F1-score* sebesar 75 persen dengan 6 dari 9 citra *no tumor* dikenali sesuai kelasnya dan 3 citra lainnya diprediksi sebagai *meningioma tumor* dan *pituitary tumor*. Kelas *pituitary tumor* memiliki *F1-score* 74 persen, di mana 7 dari 9 citra *pituitary* terklasifikasi benar, sementara 1 citra salah diprediksi sebagai *glioma tumor* dan 1 citra sebagai *meningioma tumor*. Sementara itu, kelas *meningioma tumor* menunjukkan *F1-score* terendah yaitu 70 persen. Dari 9 citra *meningioma*, 7 citra berhasil dikenali dengan benar, sedangkan 1 citra salah diklasifikasikan sebagai *no tumor* dan 1 citra lainnya sebagai *pituitary tumor*.

4.1.4 Hasil Skenario Uji 4

Hasil skenario uji 4 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang atas (*axial*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel *Sigmoid*. Parameter terbaik diperoleh pada kombinasi $C = 10$, $coef0 = 0$ dan $gamma = 0.01$. Proses pengujian dilakukan

terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan.

Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.4.



Gambar 4. 4 *Confusion matrix* Skenario Uji 4

Berdasarkan Gambar 4.4, model SVM dengan kernel *Sigmoid* menghasilkan 21 data uji yang diklasifikasikan dengan benar dan 15 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 58%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.4.

Tabel 4. 4 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 4


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	60%	67%	63%
<i>Meningioma</i> tumor	60%	67%	63%
<i>No tumor</i>	44%	44%	44%
<i>Pituitary</i> tumor	71%	56%	63%

Berdasarkan Tabel 4.4 dan Gambar 4.4, nilai *F1-score* pada skenario ini berada pada kisaran 44% sampai 63%, sehingga kinerja model SVM dengan kernel *Sigmoid* pada sudut pandang *axial* masih tergolong rendah. Tiga kelas bertumor, yaitu *glioma*, *meningioma*, dan *pituitary*, masing-masing memperoleh nilai *F1-*

score sebesar 63%. Pada kelas *glioma tumor*, 6 dari 9 citra berhasil diprediksi dengan benar, sedangkan 3 citra lainnya salah diklasifikasikan sebagai *meningioma tumor* dan *pituitary tumor*. Kelas *meningioma tumor* menunjukkan pola yang hampir sama, dengan 6 dari 9 citra dikenali sesuai kelasnya dan 3 citra lainnya bergeser ke kelas *glioma tumor* dan *no tumor*. Pada kelas *pituitary tumor*, hanya 5 dari 9 citra yang terklasifikasi dengan benar, sementara citra selebihnya diprediksi sebagai *glioma tumor* dan *no tumor*. Berbeda dengan ketiga kelas tersebut, kelas *no tumor* memiliki nilai *F1-score* terendah yaitu 44%; dari 9 citra otak tanpa tumor, hanya 4 citra yang dikenali dengan benar sebagai *no tumor*, sedangkan 5 citra lainnya salah diprediksi sebagai *glioma tumor*, *meningioma tumor*, maupun *pituitary tumor*.

4.1.5 Hasil Skenario Uji 5

Hasil skenario uji 5 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang samping (*sagital*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel *Linear* serta nilai *hyperparameter C* yang diperoleh dari hasil proses *tuning* dengan nilai terbaik, yaitu 10. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.5.

Gambar 4. 5 *Confusion matrix* Skenario Uji 5

Berdasarkan Gambar 4.5, model SVM dengan kernel *Linear* menghasilkan 27 data uji yang diklasifikasikan dengan benar dan 9 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 75%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.5.

Tabel 4. 5 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 5


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	100%	67%	80%
<i>Meningioma</i> tumor	57%	44%	50%
<i>No tumor</i>	69%	100%	82%
<i>Pituitary</i> tumor	80%	89%	84%

Berdasarkan Tabel 4.5 dan Gambar 4.5, kelas *pituitary tumor* memiliki nilai *F1-score* tertinggi, yaitu 84%, dengan *Precision* 80% dan *Recall* 89%. Pada kelas ini, 8 dari 9 citra *pituitary* berhasil diklasifikasikan dengan benar dan hanya 1 citra yang salah diprediksi sebagai *meningioma*. Kelas *no tumor* memperoleh *F1-score* sebesar 82% dengan *Recall* 100%, yang berarti seluruh citra *no tumor* dikenali dengan benar, sementara *Precision* 69% dipengaruhi oleh adanya 4 citra

meningioma yang diklasifikasikan sebagai *no tumor*. Kelas *glioma tumor* memiliki *Precision* 100% dan *Recall* 67% dengan *F1-score* sebesar 80%; semua prediksi *glioma* berasal dari citra *glioma*, namun 3 dari 9 citra *glioma* masih terklasifikasi sebagai *meningioma* atau *pituitary*. Sementara itu, kelas *meningioma tumor* menunjukkan *F1-score* terendah, yaitu 50%, karena hanya 4 dari 9 citra *meningioma* yang teridentifikasi dengan benar, sedangkan sisanya salah diprediksi sebagai *no tumor* (4 citra) dan *pituitary tumor* (1 citra).

4.1.6 Hasil Skenario Uji 6

Hasil skenario uji 6 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang samping (*sagital*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel *Polynomial*. Parameter terbaik diperoleh pada kombinasi $C = 10$, $coef0 = 1$, $degree = 2$, dan $gamma = 0.1$. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.6.



Gambar 4. 6 *Confusion matrix* Skenario Uji 6

Berdasarkan Gambar 4.6, model SVM dengan kernel *Polynomial* menghasilkan 30 data uji yang diklasifikasikan dengan benar dan 6 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 83%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.6.


Tabel 4. 6 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 6

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	88%	78%	82%
<i>Meningioma tumor</i>	75%	67%	71%
<i>No tumor</i>	82%	100%	90%
<i>Pituitary tumor</i>	89%	89%	89%

Berdasarkan Tabel 4.6 dan Gambar 4.6, kelas *no tumor* memiliki nilai *F1-score* tertinggi, yaitu 90%, dengan *Precision* 82% dan *Recall* 100%. Seluruh 9 citra *no tumor* terklasifikasi dengan benar, meskipun terdapat dua citra tumor (satu *glioma* dan satu *meningioma*) yang salah diprediksi sebagai *no tumor*. Kelas *pituitary tumor* juga menunjukkan kinerja yang sangat baik dengan *F1-score* 89%; dari 9 citra *pituitary*, 8 citra diklasifikasikan dengan benar dan 1 citra salah diprediksi sebagai *meningioma*. Pada kelas *glioma tumor*, nilai *F1-score* sebesar 82% berasal dari 7 dari 9 citra yang terklasifikasi benar, sementara 1 citra *glioma* salah diprediksi sebagai *meningioma* dan 1 citra lainnya sebagai *no tumor*. Sementara itu, kelas *meningioma tumor* memiliki *F1-score* terendah, yaitu 71%, dengan 6 dari 9 citra *meningioma* terklasifikasi benar dan tiga citra lainnya masing-masing salah diprediksi sebagai *glioma*, *no tumor*, dan *pituitary tumor*.

4.1.7 Hasil Skenario Uji 7

Hasil skenario uji 7 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang samping (*sagital*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel RBF. Parameter terbaik diperoleh pada kombinasi $C = 10$ dan $\gamma = 0.1$. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.7.



Gambar 4. 7 *Confusion matrix* Skenario Uji 7

Berdasarkan Gambar 4.7, model SVM dengan kernel RBF menghasilkan 27 data uji yang diklasifikasikan dengan benar dan 9 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 75%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.7

Tabel 4. 7 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 7


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	75%	67%	71%
<i>Meningioma</i> tumor	50%	56%	53%
<i>No tumor</i>	89%	89%	89%

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Pituitary tumor</i>	89%	89%	89%

Berdasarkan Tabel 4.7 dan Gambar 4.7, kelas *no tumor* dan *pituitary tumor* memiliki nilai *F1-score* tertinggi, masing-masing sebesar 89% dengan *Precision* dan *Recall* yang sama-sama 89%. Pada kelas *no tumor*, 8 dari 9 citra *no tumor* diklasifikasikan dengan benar, sedangkan 1 citra lainnya salah diprediksi sebagai *meningioma tumor*. Pada kelas *pituitary tumor*, 8 dari 9 citra *pituitary* juga terklasifikasi dengan benar dan 1 citra salah diprediksi sebagai *meningioma tumor*. Kelas *glioma tumor* memiliki *F1-score* sebesar 71% dengan *Precision* 75% dan *Recall* 67%; dari 9 citra *glioma*, 6 citra dikenali dengan benar, sedangkan 3 citra lainnya salah diklasifikasikan sebagai *meningioma tumor*. Sementara itu, kelas *meningioma tumor* menunjukkan *F1-score* terendah, yaitu 53%, dengan 5 dari 9 citra *meningioma* terklasifikasi benar dan 4 citra lainnya masing-masing salah diprediksi sebagai *glioma tumor* (2 citra), *no tumor* (1 citra), dan *pituitary tumor* (1 citra).

4.1.8 Hasil Skenario Uji 8

Hasil skenario uji 8 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang samping (*sagital*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel *Sigmoid*. Parameter terbaik diperoleh pada kombinasi $C = 10$, $\text{coef0} = 0$ dan $\text{gamma} = 0.01$. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.8.



Gambar 4. 8 *Confusion matrix* Skenario Uji 8

Berdasarkan Gambar 4.8, model SVM dengan kernel *Sigmoid* menghasilkan 25 data uji yang diklasifikasikan dengan benar dan 11 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 70%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.8

Tabel 4. 8 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 8


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	62%	89%	73%
<i>Meningioma tumor</i>	0%	0%	0%
<i>Pituitary tumor</i>	69%	100%	82%
<i>No tumor</i>	80%	89%	84%

Berdasarkan Tabel 4.8 dan Gambar 4.8, kinerja model SVM dengan kernel *Sigmoid* pada dataset *balanced* sudut pandang sagital belum merata pada setiap kelas. Kelas *glioma tumor* memperoleh nilai *F1-score* sebesar 73%, di mana 8 dari 9 citra *glioma* terklasifikasi dengan benar sebagai *glioma*, sedangkan 1 citra lainnya salah diprediksi sebagai *pituitary tumor*. Kelas *meningioma tumor* menunjukkan performa terendah dengan nilai *Precision*, *Recall*, dan *F1-score* sebesar 0%, karena

tidak ada satu pun dari 9 citra *meningioma* yang dikenali dengan benar; citra-citra tersebut tersebar salah prediksi sebagai *glioma*, *no tumor*, maupun *pituitary tumor*. Kelas *no tumor* memiliki *F1-score* yang cukup tinggi, yaitu 84%, dengan sebagian besar citra *no tumor* yang dapat dikenali dengan benar, meskipun masih terdapat sejumlah kecil citra otak sehat yang salah diklasifikasikan sebagai kelas bertumor. Sementara itu, kelas *pituitary tumor* juga menunjukkan kinerja yang baik dengan nilai *F1-score* sebesar 82%; seluruh 9 citra *pituitary* berhasil terklasifikasi sebagai *pituitary tumor*, meskipun masih terdapat beberapa citra dari kelas lain yang ikut terprediksi sebagai *pituitary* sehingga nilai *Precision* tidak mencapai 100%.

4.1.9 Hasil Skenario Uji 9

Hasil skenario uji 9 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang belakang (*coronal*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel *Linear* serta nilai *hyperparameter C* yang diperoleh dari hasil proses *tuning* dengan nilai terbaik, yaitu 10. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.9.

Gambar 4. 9 *Confusion matrix* Skenario Uji 9

Berdasarkan Gambar 4.9, model SVM dengan kernel *Linear* menghasilkan 28 data uji yang diklasifikasikan dengan benar dan 8 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 78%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.9.

Tabel 4. 9 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 9


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	86%	67%	75%
<i>Meningioma tumor</i>	60%	67%	63%
<i>No tumor</i>	78%	78%	78%
<i>Pituitary tumor</i>	90%	100%	95%

Berdasarkan Tabel 4.9 dan Gambar 4.9, kelas *pituitary tumor* menunjukkan kinerja paling baik dengan nilai *F1-score* sebesar 95%; seluruh 9 citra *pituitary* terklasifikasi dengan benar sebagai *pituitary tumor* tanpa ada kesalahan prediksi ke kelas lain. Kelas *no tumor* juga memiliki performa yang cukup tinggi dengan *F1-score* 78%, di mana 7 dari 9 citra *no tumor* dikenali dengan tepat, sedangkan 2 citra lainnya salah diprediksi sebagai *meningioma tumor*. Pada kelas *glioma tumor*, nilai

F1-score sebesar 75% diperoleh dari 6 citra yang terklasifikasi benar, sementara 2 citra *glioma* salah diprediksi sebagai *meningioma tumor* dan 1 citra lainnya sebagai *pituitary tumor*. Sementara itu, kelas *meningioma tumor* memiliki *F1-score* terendah, yaitu 63%; dari 9 citra *meningioma*, 6 citra terklasifikasi dengan benar, sedangkan satu citra salah diprediksi sebagai *glioma tumor* dan dua citra lainnya sebagai *no tumor*.

4.1.10 Hasil Skenario Uji 10

Hasil skenario uji 10 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang belakang (*coronal*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel *Polynomial*. Parameter terbaik diperoleh pada kombinasi $C = 10$, $coef0 = 1$, $degree = 2$, dan $gamma = 1$. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.10.



Gambar 4. 10 *Confusion matrix* Skenario Uji 10

Berdasarkan Gambar 4.10, model SVM dengan kernel *Polynomial* menghasilkan 30 data uji yang diklasifikasikan dengan benar dan 6 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 83%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.10.


Tabel 4. 10 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 10

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	71%	56%	63%
<i>Meningioma tumor</i>	89%	89%	89%
<i>No tumor</i>	80%	89%	84%
<i>Pituitary tumor</i>	90%	100%	95%

Berdasarkan Tabel 4.10 dan Gambar 4.10, kelas *pituitary tumor* memiliki nilai *F1-score* tertinggi, yaitu 95%. Seluruh 9 citra *pituitary* terklasifikasi dengan benar sebagai *pituitary tumor*, namun masih terdapat satu citra dari kelas lain yang ikut diprediksi sebagai *pituitary* sehingga *Precision* bernilai 90% dan *Recall* 100%. Kelas *meningioma tumor* juga menunjukkan kinerja yang tinggi dengan *F1-score* sebesar 89%; dari 9 citra *meningioma*, 8 citra dikenali dengan benar sebagai *meningioma tumor*, sedangkan 1 citra lainnya salah diprediksi sebagai *glioma tumor*. Kelas *no tumor* memiliki *F1-score* sebesar 84% dengan *Precision* 80% dan *Recall* 89%. Sebagian besar citra *no tumor* dapat diklasifikasikan dengan tepat, meskipun masih terdapat beberapa citra tumor yang ikut terprediksi sebagai *no tumor* sehingga *Precision* tidak mencapai 100%. Sementara itu, kelas *glioma tumor* memiliki *F1-score* terendah, yaitu 63%. Hanya 5 dari 9 citra *glioma* yang terklasifikasi benar, sedangkan 4 citra lainnya menyebar sebagai *meningioma tumor*, *no tumor*, dan *pituitary tumor*.

4.1.11 Hasil Skenario Uji 11

Hasil skenario uji 11 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang belakang (*coronal*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel RBF. Parameter terbaik diperoleh pada kombinasi $C = 10$ dan $\gamma = 1$. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.11.



Gambar 4. 11 *Confusion matrix* Skenario Uji 11

Berdasarkan Gambar 4.11, model SVM dengan kernel RBF menghasilkan 31 data uji yang diklasifikasikan dengan benar dan 5 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 86%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.11

Tabel 4. 11 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 11


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	100%	44%	62%
<i>Meningioma</i> tumor	75%	100%	86%
<i>No tumor</i>	90%	100%	95%

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Pituitary tumor</i>	90%	100%	95%

Berdasarkan Tabel 4.11 dan Gambar 4.11, kelas *no tumor* dan *pituitary tumor* menunjukkan kinerja terbaik dengan nilai *F1-score* masing-masing sebesar 95%. Pada kelas *no tumor*, seluruh 9 citra *no tumor* diklasifikasikan dengan benar, sedangkan terdapat 1 citra *glioma* yang salah diprediksi sebagai *no tumor* sehingga *Precision* mencapai 90% dan *Recall* 100%. Pola serupa terlihat pada kelas *pituitary tumor*, di mana seluruh 9 citra *pituitary* berhasil dikenali dengan benar dan terdapat 1 citra *glioma* yang ikut terklasifikasi sebagai *pituitary tumor*, sehingga *Precision* bernilai 90% dengan *Recall* 100%. Kelas *meningioma tumor* memiliki *F1-score* sebesar 86%; semua 9 citra *meningioma* terklasifikasi tepat, namun masih terdapat 3 citra *glioma* yang keliru diklasifikasikan sebagai *meningioma* sehingga *Precision* turun menjadi 75%. Sementara itu, kelas *glioma tumor* menunjukkan *F1-score* terendah yaitu 62%, dengan hanya 4 dari 9 citra *glioma* yang dikenali dengan benar, sedangkan 5 citra lainnya salah diprediksi sebagai *meningioma tumor*, *no tumor*, dan *pituitary tumor*.

4.1.12 Hasil Skenario Uji 12

Hasil skenario uji 12 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang belakang (*coronal*) yang telah diseimbangkan. Model klasifikasi menggunakan algoritma SVM dengan kernel *Sigmoid*. Parameter terbaik diperoleh pada kombinasi $C = 10$, $\text{coef0} = 0$ dan $\text{gamma} = 0.01$. Proses pengujian dilakukan terhadap 36 data uji dari total 180 citra, dengan 144 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.12.

Gambar 4. 12 *Confusion matrix* Skenario Uji 12

Berdasarkan Gambar 4.12, model SVM dengan kernel *Sigmoid* menghasilkan 25 data uji yang diklasifikasikan dengan benar dan 11 data uji yang diklasifikasikan salah dari total 36 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 69%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.12

Tabel 4. 12 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 12


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	55%	67%	60%
<i>Meningioma</i> tumor	67%	22%	33%
<i>No tumor</i>	75%	100%	86%
<i>Pituitary</i> tumor	80%	89%	84%

Berdasarkan Tabel 4.12 dan Gambar 4.12, kinerja model SVM dengan kernel *Sigmoid* pada dataset *balanced* sudut pandang *coronal* menunjukkan variasi performa antar kelas. Kelas *no tumor* memiliki nilai *F1-score* tertinggi yaitu 86% dengan *Precision* 75% dan *Recall* 100%. Seluruh 9 citra *no tumor* terklasifikasi dengan benar sebagai *no tumor*, namun masih terdapat 3 citra *meningioma* yang ikut diprediksi sebagai *no tumor* sehingga *Precision* tidak mencapai 100%. Kelas

pituitary tumor juga menunjukkan performa yang baik dengan *F1-score* 84%. Dari 9 citra *pituitary*, 8 citra dikenali dengan benar sebagai *pituitary tumor*, sedangkan 1 citra *pituitary* salah diprediksi sebagai *glioma tumor*, dan 2 citra *glioma* turut terklasifikasi sebagai *pituitary* sehingga *Precision* bernilai 80% dan *Recall* 89%. Pada kelas *glioma tumor*, nilai *F1-score* yang diperoleh sebesar 60% dengan *Precision* 55% dan *Recall* 67%; sebanyak 6 dari 9 citra *glioma* terklasifikasi benar, sedangkan 3 citra lainnya salah diprediksi terutama sebagai *meningioma* dan *pituitary tumor*. Sementara itu, kelas *meningioma tumor* memiliki *F1-score* terendah yaitu 33%. Hanya 2 dari 9 citra *meningioma* yang dikenali dengan benar, sedangkan 4 citra *meningioma* salah diklasifikasikan sebagai *glioma tumor* dan 3 citra lainnya sebagai *no tumor*.

4.1.13 Hasil Skenario Uji 13

Hasil skenario uji 13 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang atas (*axial*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Linear* serta nilai *hyperparameter C* yang diperoleh dari hasil proses *tuning* dengan nilai terbaik, yaitu 10. Proses pengujian dilakukan terhadap 252 data uji dari total 1256 citra, dengan 1004 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.13.



Gambar 4. 13 *Confusion matrix* Skenario Uji 13

Berdasarkan Gambar 4.13, model SVM dengan kernel *Linear* menghasilkan 160 data uji yang diklasifikasikan dengan benar dan 92 data uji yang diklasifikasikan salah dari total 252 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 63%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.13.

Tabel 4. 13 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 13


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	66%	52%	58%
<i>Meningioma</i> tumor	56%	69%	62%
<i>No tumor</i>	69%	53%	60%
<i>Pituitary</i> tumor	69%	80%	74%

Berdasarkan Tabel 4.13 dan Gambar 4.13, nilai *F1-score* pada skenario ini berada pada rentang 58% hingga 74%. Kelas *pituitary tumor* memberikan kinerja terbaik dengan *F1-score* sebesar 74%, didukung *Precision* 69% dan *Recall* 80%; dari 55 citra *pituitary*, 44 citra diklasifikasikan dengan benar, sedangkan 11 citra lainnya masih salah diprediksi ke kelas *glioma*, *meningioma*, atau *no tumor*. Kelas *meningioma tumor* memiliki *F1-score* 62% dengan 50 dari 72 citra teridentifikasi

dengan benar, sementara 22 citra *meningioma* lainnya salah diklasifikasikan sebagai *glioma*, *no tumor*, maupun *pituitary tumor*. Pada kelas *no tumor*, nilai *F1-score* sebesar 60% diperoleh dari 31 citra yang terklasifikasi benar dari total 58 citra, dengan kesalahan klasifikasi yang sebagian besar mengarah ke kelas *meningioma tumor*. Sementara itu, kelas *glioma tumor* memiliki *F1-score* terendah yaitu 58%; hanya 35 dari 67 citra *glioma* yang dikenali dengan benar, sedangkan 32 citra lainnya tersebar salah prediksi terutama sebagai *meningioma tumor*, serta sebagian sebagai *no tumor* dan *pituitary tumor*.

4.1.14 Hasil Skenario Uji 14

Hasil skenario uji 14 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang atas (*axial*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Polynomial*. Parameter terbaik diperoleh pada kombinasi $C = 1$, $coef0 = 1$, $degree = 3$, dan $gamma = 1$. Proses pengujian dilakukan terhadap 252 data uji dari total 1256 citra, dengan 1004 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.14.



Gambar 4. 14 *Confusion matrix* Skenario Uji 14

Berdasarkan Gambar 4.14, model SVM dengan kernel *Polynomial* menghasilkan 186 data uji yang diklasifikasikan dengan benar dan 66 data uji yang diklasifikasikan salah dari total 252 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 74%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.14.


Tabel 4. 14 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 14

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	69%	69%	69%
<i>Meningioma tumor</i>	78%	69%	73%
<i>No tumor</i>	74%	78%	76%
<i>Pituitary tumor</i>	75%	84%	79%

Berdasarkan Tabel 4.14 dan Gambar 4.14, nilai *F1-score* pada skenario ini berada pada kisaran 69% hingga 79%. Kelas *pituitary tumor* memiliki nilai *F1-score* tertinggi, yaitu 79%, dengan 46 dari 55 citra *pituitary* terklasifikasi dengan benar sebagai *pituitary tumor*. Sebanyak 9 citra lainnya masih salah diprediksi sebagai *glioma tumor*, *meningioma tumor*, atau *no tumor* sehingga *Precision* bernilai 75% dan *Recall* 84%. Kelas *no tumor* memperoleh *F1-score* sebesar 76% dengan 45 dari 58 citra *no tumor* dikenali dengan benar, sedangkan 13 citra lainnya salah diklasifikasikan terutama sebagai *glioma tumor* dan *meningioma tumor*. Pada kelas *meningioma tumor*, nilai *F1-score* sebesar 73% berasal dari 49 citra yang terklasifikasi benar dari total 72 citra, sementara citra yang lain masih menyebar sebagai *glioma tumor*, *no tumor*, dan *pituitary tumor*. Sementara itu, kelas *glioma tumor* memiliki *F1-score* terendah yaitu 69%, dengan 46 dari 67 citra *glioma* dikenali dengan benar dan 21 citra lainnya salah diprediksi ke tiga kelas yang lain.

4.1.15 Hasil Skenario Uji 15

Hasil skenario uji 15 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang atas (*axial*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel RBF. Parameter terbaik diperoleh pada kombinasi $C = 1$, dan $\gamma = 1$. Proses pengujian dilakukan terhadap 252 data uji dari total 1256 citra, dengan 1004 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.15.



Gambar 4. 15 *Confusion matrix* Skenario Uji 15

Berdasarkan Gambar 4.15, model SVM dengan kernel RBF menghasilkan 179 data uji yang diklasifikasikan dengan benar dan 73 data uji yang diklasifikasikan salah dari total 252 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 71%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.15.

Tabel 4. 15 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 15

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	72%	57%	63%
<i>Meningioma</i> tumor	69%	75%	72%
<i>No tumor</i>	75%	74%	75%


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Pituitary tumor</i>	69%	80%	74%

Berdasarkan Tabel 4.15 dan Gambar 4.15, kelas *no tumor* memiliki nilai *F1-score* tertinggi yaitu 75% dengan *Precision* 75% dan *Recall* 74%. Dari 58 citra *no tumor*, 43 citra diklasifikasikan dengan benar, sedangkan 3 citra salah diprediksi sebagai *glioma tumor*, 8 citra sebagai *meningioma tumor*, dan 4 citra sebagai *pituitary tumor*. Kelas *pituitary tumor* menunjukkan *F1-score* sebesar 74% dengan *Precision* 69% dan *Recall* 80%. Pada kelas ini, 44 dari 55 citra *pituitary* terklasifikasi dengan benar, sementara 6 citra diprediksi sebagai *glioma tumor*, 4 citra sebagai *meningioma tumor*, dan 1 citra sebagai *no tumor*. Kelas *meningioma tumor* memiliki *F1-score* 72% dengan 54 dari 72 citra yang dikenali sesuai kelasnya, sedangkan 18 citra lainnya masih tersebar salah prediksi ke kelas *glioma tumor*, *no tumor*, dan *pituitary tumor*. Sementara itu, kelas *glioma tumor* menunjukkan *F1-score* terendah yaitu 63%. Hanya 38 dari 67 citra *glioma* yang terklasifikasi dengan benar, sedangkan 12 citra salah diprediksi sebagai *meningioma tumor*, 8 citra sebagai *no tumor*, dan 9 citra sebagai *pituitary tumor*.

4.1.16 Hasil Skenario Uji 16

Hasil skenario uji 16 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang atas (*axial*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Sigmoid*. Parameter terbaik diperoleh pada kombinasi $C = 1$, $coef0 = 0$ dan $gamma = 0.01$. Proses pengujian dilakukan terhadap 252 data uji dari total 1256 citra, dengan 1004 data digunakan untuk

pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.16.



Gambar 4. 16 *Confusion matrix* Skenario Uji 16

Berdasarkan Gambar 4.16, model SVM dengan kernel *Sigmoid* menghasilkan 130 data uji yang diklasifikasikan dengan benar dan 122 data uji yang diklasifikasikan salah dari total 252 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 52%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.16.

Tabel 4. 16 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 16


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	58%	52%	55%
<i>Meningioma</i> tumor	50%	64%	56%
<i>No tumor</i>	63%	10%	15%
<i>Pituitary</i> tumor	48%	80%	60%

Berdasarkan Tabel 4.16 dan Gambar 4.16, kinerja model SVM dengan kernel *Sigmoid* pada dataset *axial* yang tidak seimbang tergolong rendah, dengan nilai *F1-score* per kelas berkisar antara 15% hingga 60%. Kelas *pituitary tumor* memiliki nilai *F1-score* tertinggi yaitu 60% dengan *Precision* 48% dan *Recall* 80%.

Dari 55 citra *pituitary*, 44 citra berhasil diklasifikasikan dengan benar, sedangkan 7 citra salah diprediksi sebagai *glioma tumor*, 3 citra sebagai *meningioma tumor*, dan 1 citra sebagai *no tumor*. Kelas *meningioma tumor* memperoleh *F1-score* sebesar 56% dengan *Precision* 50% dan *Recall* 64%; sebanyak 46 dari 72 citra *meningioma* terklasifikasi dengan benar, sementara 26 citra lainnya tersebar salah prediksi ke kelas *glioma tumor*, *no tumor*, dan *pituitary tumor*. Pada kelas *glioma tumor*, nilai *F1-score* sebesar 55% diperoleh dari 35 citra yang dikenali dengan benar dari total 67 citra, sedangkan 32 citra *glioma* masih salah diklasifikasikan terutama sebagai *meningioma tumor* dan *pituitary tumor*. Kelas *no tumor* menunjukkan kinerja paling rendah dengan nilai *F1-score* hanya 15%. Dari 58 citra *no tumor*, hanya 5 citra yang terklasifikasi tepat, sementara sebagian besar citra lainnya salah diprediksi sebagai *meningioma tumor* dan *pituitary tumor*.

4.1.17 Hasil Skenario Uji 17

Hasil skenario uji 17 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang samping (*sagital*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Linear* serta nilai *hyperparameter C* yang diperoleh dari hasil proses *tuning* dengan nilai terbaik, yaitu 10. Proses pengujian dilakukan terhadap 198 data uji dari total 986 citra, dengan 788 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.17.

Gambar 4. 17 *Confusion matrix* Skenario Uji 17

Berdasarkan Gambar 4.17, model SVM dengan kernel *Linear* menghasilkan 121 data uji yang diklasifikasikan dengan benar dan 77 data uji yang diklasifikasikan salah dari total 198 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 61%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.17.

Tabel 4. 17 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 17


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	56%	68%	62%
<i>Meningioma</i> tumor	60%	26%	36%
<i>No tumor</i>	72%	68%	70%
<i>Pituitary</i> tumor	63%	86%	73%

Berdasarkan Tabel 4.17 dan Gambar 4.17, nilai *F1-score* pada skenario ini berada pada kisaran 36% sampai 73%. Kelas *pituitary tumor* memiliki nilai *F1-score* tertinggi yaitu 73% dengan *Precision* 63% dan *Recall* 86%. Dari 62 citra *pituitary*, 53 citra diklasifikasikan dengan benar sebagai *pituitary tumor*, sedangkan 9 citra lainnya masih salah diprediksi terutama sebagai *glioma tumor* dan *meningioma tumor*. Kelas *no tumor* menunjukkan *F1-score* sebesar 70% dengan 13

dari 19 citra *no tumor* dikenali dengan tepat, sementara beberapa citra lainnya salah diklasifikasikan sebagai *glioma tumor*, *meningioma tumor*, dan *pituitary tumor*. Pada kelas *glioma tumor*, nilai *F1-score* yang diperoleh sebesar 62% dengan 40 dari 59 citra terklasifikasi benar, sedangkan sisanya banyak berpindah ke kelas *meningioma tumor* dan *pituitary tumor*. Sementara itu, kelas *meningioma tumor* memiliki *F1-score* terendah yaitu 36%. Hanya 15 dari 58 citra *meningioma* yang dikenali dengan benar, sedangkan 43 citra lainnya tersebar salah prediksi ke kelas *glioma tumor*, *no tumor*, dan *pituitary tumor*.

4.1.18 Hasil Skenario Uji 18

Hasil skenario uji 18 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang samping (*sagital*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Polynomial*. Parameter terbaik diperoleh pada kombinasi $C = 10$, $coef0 = 1$, $degree = 4$, dan $gamma = 0.1$. Proses pengujian dilakukan terhadap 198 data uji dari total 986 citra, dengan 788 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.18.



Gambar 4. 18 *Confusion matrix* Skenario Uji 18

Berdasarkan Gambar 4.18, model SVM dengan kernel *Polynomial* menghasilkan 141 data uji yang diklasifikasikan dengan benar dan 57 data uji yang diklasifikasikan salah dari total 198 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 71%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.18.


Tabel 4. 18 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 18

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	69%	63%	66%
<i>Meningioma tumor</i>	64%	67%	66%
<i>No tumor</i>	79%	79%	79%
<i>Pituitary tumor</i>	78%	81%	79%

Berdasarkan Tabel 4.18 dan Gambar 4.18, nilai *F1-score* pada skenario ini berada pada rentang 66% sampai 79%. Kelas *no tumor* dan *pituitary tumor* menunjukkan kinerja paling baik dengan nilai *F1-score* masing-masing sebesar 79%. Pada kelas *no tumor*, 15 dari 19 citra berhasil diklasifikasikan dengan benar sebagai *no tumor*, sedangkan 4 citra lainnya salah diklasifikasikan sebagai *glioma tumor* dan *meningioma tumor*. Kelas *pituitary tumor* memiliki 50 dari 62 citra yang teridentifikasi dengan benar, sementara 12 citra *pituitary* masih diprediksi sebagai *glioma tumor* atau *meningioma tumor*. Kelas *glioma tumor* memperoleh nilai *F1-score* 66%, dengan 37 dari 59 citra yang dikenali sesuai kelasnya dan 22 citra lainnya menyebar salah prediksi terutama ke kelas *meningioma tumor* serta sebagian ke *no tumor* dan *pituitary tumor*. Kelas *meningioma tumor* juga memiliki nilai *F1-score* 66%, dengan 39 dari 58 citra yang terklasifikasi benar dan 19 citra lainnya salah diklasifikasikan sebagai *glioma tumor*, *no tumor*, maupun *pituitary tumor*.

4.1.19 Hasil Skenario Uji 19

Hasil skenario uji 19 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang samping (*sagital*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel RBF. Parameter terbaik diperoleh pada kombinasi $C = 10$ dan $\gamma = 0.1$. Proses pengujian dilakukan terhadap 198 data uji dari total 986 citra, dengan 788 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.19.



Gambar 4. 19 *Confusion matrix* Skenario Uji 19

Berdasarkan Gambar 4.19, model SVM dengan kernel RBF menghasilkan 136 data uji yang diklasifikasikan dengan benar dan 62 data uji yang diklasifikasikan salah dari total 198 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 69%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.19

Tabel 4. 19 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 19

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	67%	63%	64%


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Meningioma tumor</i>	60%	64%	62%
<i>No tumor</i>	65%	68%	67%
<i>Pituitary tumor</i>	82%	79%	80%

Berdasarkan Tabel 4.19 dan Gambar 4.19, kelas *pituitary tumor* menunjukkan kinerja terbaik dengan nilai *F1-score* sebesar 80%. Dari 62 citra *pituitary*, 49 citra diklasifikasikan dengan benar sebagai *pituitary tumor*, sedangkan 6 citra salah diprediksi sebagai *glioma tumor* dan 7 citra sebagai *meningioma tumor*, sehingga *Precision* mencapai 82% dan *Recall* 79%. Kelas *no tumor* memiliki nilai *F1-score* 67% dengan *Precision* 65% dan *Recall* 68%. Pada kelas ini, 13 dari 19 citra *no tumor* terklasifikasi dengan benar, sedangkan 2 citra salah diprediksi sebagai *glioma tumor* dan 4 citra sebagai *meningioma tumor*. Kelas *glioma tumor* memperoleh *F1-score* sebesar 64% dengan 37 dari 59 citra yang dikenali sesuai kelasnya, sementara 14 citra *glioma* salah diklasifikasikan sebagai *meningioma tumor*, 3 citra sebagai *no tumor*, dan 5 citra sebagai *pituitary tumor*. Sementara itu, kelas *meningioma tumor* memiliki *F1-score* terendah yaitu 62%. Dari 58 citra *meningioma*, 37 citra terklasifikasi dengan benar, sedangkan 11 citra salah diprediksi sebagai *glioma tumor*, 4 citra sebagai *no tumor*, dan 6 citra sebagai *pituitary tumor*.

4.1.20 Hasil Skenario Uji 20

Hasil skenario uji 20 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang samping (*sagital*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Sigmoid*. Parameter terbaik diperoleh pada kombinasi $C = 10$, $\text{coef0} = 0$ dan $\text{gamma} = 0.01$. Proses pengujian

dilakukan terhadap 198 data uji dari total 986 citra, dengan 788 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.20.



Gambar 4. 20 *Confusion matrix* Skenario Uji 20

Berdasarkan Gambar 4.20, model SVM dengan kernel *Sigmoid* menghasilkan 112 data uji yang diklasifikasikan dengan benar dan 86 data uji yang diklasifikasikan salah dari total 198 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 57%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.20

Tabel 4. 20 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 20


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	62%	54%	58%
<i>Meningioma</i> tumor	48%	41%	44%
<i>No tumor</i>	36%	47%	41%
<i>Pituitary</i> tumor	65%	76%	70%

Berdasarkan Tabel 4.20 dan Gambar 4.20, kinerja model SVM dengan kernel *Sigmoid* pada dataset sudut pandang sagital yang tidak seimbang cenderung rendah, dengan nilai *F1-score* yang berkisar antara 41% hingga 70%. Kelas

pituitary tumor memiliki nilai *F1-score* tertinggi yaitu 70% dengan *Precision* 65% dan *Recall* 76%. Dari 62 citra *pituitary*, 47 citra diklasifikasikan dengan benar sebagai *pituitary tumor*, sedangkan sisanya masih salah diprediksi sebagai *glioma tumor* sebanyak 3 citra dan *meningioma tumor* sebanyak 12 citra. Kelas *glioma tumor* memperoleh nilai *F1-score* 58% dengan *Precision* 62% dan *Recall* 54%. Pada kelas ini, 32 dari 59 citra *glioma* dikenali dengan tepat, sementara 27 citra lainnya menyebar salah klasifikasi terutama ke kelas *meningioma tumor* dan *pituitary tumor* serta sebagian kecil ke kelas *no tumor*. Kelas *meningioma tumor* memiliki *F1-score* 44% dengan 24 dari 58 citra yang terklasifikasi benar, sedangkan 34 citra *meningioma* lainnya salah diprediksi sebagai *glioma tumor*, *no tumor*, maupun *pituitary tumor*. Sementara itu, kelas *no tumor* menunjukkan *F1-score* terendah yaitu 41%. Dari 19 citra *no tumor*, hanya 9 citra yang dikenali sesuai kelasnya, sedangkan 10 citra lainnya salah diklasifikasikan ke tiga kelas tumor.

4.1.21 Hasil Skenario Uji 21

Hasil skenario uji 21 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang belakang (*coronal*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Linear* serta nilai *hyperparameter C* yang diperoleh dari hasil proses *tuning* dengan nilai terbaik, yaitu 10. Proses pengujian dilakukan terhadap 190 data uji dari total 946 citra, dengan 756 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.21.

Gambar 4. 21 *Confusion matrix* Skenario Uji 21

Berdasarkan Gambar 4.21, model SVM dengan kernel *Linear* menghasilkan 142 data uji yang diklasifikasikan dengan benar dan 48 data uji yang diklasifikasikan salah dari total 190 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 75%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.21.

Tabel 4. 21 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 21


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	74%	70%	72%
<i>Meningioma tumor</i>	64%	77%	70%
<i>No tumor</i>	100%	11%	20%
<i>Pituitary tumor</i>	87%	86%	87%

Berdasarkan Tabel 4.21 dan Gambar 4.21, nilai *F1-score* pada skenario ini berada pada rentang 20% hingga 87%. Kelas *pituitary tumor* menunjukkan kinerja terbaik dengan nilai *F1-score* sebesar 87%. Dari 64 citra *pituitary*, 55 citra diklasifikasikan dengan benar sebagai *pituitary tumor*, sedangkan 4 citra salah diprediksi sebagai *glioma tumor* dan 5 citra sebagai *meningioma tumor*. Kelas *glioma tumor* memiliki *F1-score* sebesar 72% dengan 42 dari 60 citra yang

terklasifikasi benar, sementara 15 citra *glioma* salah diprediksi sebagai *meningioma tumor* dan 3 citra sebagai *pituitary tumor*. Pada kelas *meningioma tumor*, nilai *F1-score* yang diperoleh sebesar 70%; dari 57 citra *meningioma*, 44 citra dikenali sesuai kelasnya, sedangkan 9 citra salah diklasifikasikan sebagai *glioma tumor* dan 4 citra sebagai *pituitary tumor*. Sementara itu, kelas *no tumor* menunjukkan *F1-score* terendah yaitu 20%. Hanya 1 dari 9 citra *no tumor* yang terklasifikasi dengan benar sebagai *no tumor*, sedangkan citra lainnya salah diprediksi sebagai *glioma tumor*, *meningioma tumor*, maupun *pituitary tumor*

4.1.22 Hasil Skenario Uji 22

Hasil skenario uji 22 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang belakang (*coronal*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Polynomial*. Parameter terbaik diperoleh pada kombinasi $C = 10$, $coef0 = 1$, $degree = 2$, dan $gamma = 1$. Proses pengujian dilakukan terhadap 190 data uji dari total 946 citra, dengan 756 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.22.



Gambar 4. 22 *Confusion matrix* Skenario Uji 22

Berdasarkan Gambar 4.22, model SVM dengan kernel *Polynomial* menghasilkan 147 data uji yang diklasifikasikan dengan benar dan 43 data uji yang diklasifikasikan salah dari total 190 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 77%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.22.

Tabel 4. 22 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 22


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	73%	72%	72%
<i>Meningioma tumor</i>	72%	75%	74%
<i>No tumor</i>	100%	56%	71%
<i>Pituitary tumor</i>	85%	88%	86%

Berdasarkan Tabel 4.22 dan Gambar 4.22, nilai *F1-score* pada skenario ini berada pada rentang 71% hingga 86%. Kelas *pituitary tumor* menunjukkan kinerja paling baik dengan *F1-score* 86%, *Precision* 85% dan *Recall* 88%. Dari 64 citra *pituitary*, 56 citra terklasifikasi dengan benar sebagai *pituitary tumor*, sedangkan 8 citra lainnya masih diprediksi sebagai *glioma tumor* dan *meningioma tumor*. Kelas *no tumor* memiliki *F1-score* 71% dengan *Precision* 100% dan *Recall* 56%. Pada kelas ini, 5 dari 9 citra *no tumor* dikenali dengan tepat, sementara 1 citra *no tumor* salah diklasifikasikan sebagai *glioma tumor*, 2 citra sebagai *meningioma tumor*, dan 1 citra sebagai *pituitary tumor* sehingga setiap prediksi *no tumor* selalu benar tetapi sebagian citra *no tumor* belum terdeteksi. Kelas *glioma tumor* memiliki *F1-score* 72% dengan 43 dari 60 citra yang terklasifikasi benar, sedangkan 12 citra *glioma* diprediksi sebagai *meningioma tumor* dan 5 citra sebagai *pituitary tumor*. Kelas *meningioma tumor* juga memiliki kinerja yang cukup baik dengan *F1-score* 74%.

Dari 57 citra *meningioma*, 43 citra dikenali sesuai kelasnya, sedangkan 10 citra salah diprediksi sebagai *glioma tumor* dan 4 citra sebagai *pituitary tumor*.

4.1.23 Hasil Skenario Uji 23

Hasil skenario uji 23 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang belakang (*coronal*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel RBF. Parameter terbaik diperoleh pada kombinasi $C = 10$ dan $\gamma = 0.1$. Proses pengujian dilakukan terhadap 190 data uji dari total 946 citra, dengan 756 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.23.



Gambar 4. 23 *Confusion matrix* Skenario Uji 23

Berdasarkan Gambar 4.23, model SVM dengan kernel RBF menghasilkan 138 data uji yang diklasifikasikan dengan benar dan 52 data uji yang diklasifikasikan salah dari total 190 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan

F1-score. Nilai akurasi yang diperoleh sebesar 73%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.23

Tabel 4. 23 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 23


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma tumor</i>	64%	70%	67%
<i>Meningioma tumor</i>	70%	70%	70%
<i>No tumor</i>	50%	11%	18%
<i>Pituitary tumor</i>	84%	86%	85%

Berdasarkan Tabel 4.23 dan Gambar 4.23, nilai *F1-score* pada skenario ini berkisar antara 18% hingga 85%, sehingga tampak perbedaan kinerja yang cukup jelas antar kelas. Kelas *pituitary tumor* menunjukkan performa terbaik dengan *F1-score* 85%; dari 64 citra *pituitary*, 55 citra terklasifikasi dengan benar sebagai *pituitary tumor*, sedangkan sebagian kecil citra lainnya masih diprediksi sebagai *glioma* dan *meningioma*. Kelas *glioma tumor* dan *meningioma tumor* berada pada kisaran menengah dengan *F1-score* masing-masing 67% dan 70%, di mana 42 dari 60 citra *glioma* serta 40 dari 57 citra *meningioma* dikenali dengan tepat, sementara sisanya menyebar salah prediksi terutama ke kelas satu sama lain maupun ke kelas *pituitary tumor*. Sebaliknya, kelas *no tumor* memperlihatkan kinerja terendah dengan *F1-score* 18%; hanya 1 dari 9 citra *no tumor* yang terklasifikasi benar, sedangkan sebagian besar citra otak tanpa tumor teridentifikasi sebagai *glioma* atau *meningioma*.

4.1.24 Hasil Skenario Uji 24

Hasil skenario uji 24 diperoleh dari proses klasifikasi citra MRI dengan sudut pandang belakang (*coronal*) pada dataset yang tidak seimbang. Model klasifikasi menggunakan algoritma SVM dengan kernel *Sigmoid*. Parameter terbaik

diperoleh pada kombinasi $C = 1$, $\text{coef0} = 0$ dan $\text{gamma} = 0.01$. Proses pengujian dilakukan terhadap 190 data uji dari total 946 citra, dengan 756 data digunakan untuk pelatihan. Hasil pengujian ditunjukkan melalui *Confusion matrix* pada Gambar 4.24.



Gambar 4. 24 *Confusion matrix* Skenario Uji 24

Berdasarkan Gambar 4.24, model SVM dengan kernel *Sigmoid* menghasilkan 127 data uji yang diklasifikasikan dengan benar dan 63 data uji yang diklasifikasikan salah dari total 190 data uji. Hasil *Confusion matrix* tersebut kemudian menjadi dasar dalam perhitungan nilai akurasi, *Precision*, *Recall*, dan *F1-score*. Nilai akurasi yang diperoleh sebesar 67%, sedangkan nilai *Precision*, *Recall*, dan *F1-score* ditunjukkan pada Tabel 4.24

Tabel 4. 24 Nilai *Precision*, *Recall*, dan *F1-score* pada Skenario Uji 24

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Glioma</i> tumor	71%	50%	59%
<i>Meningioma</i> tumor	56%	75%	64%
<i>No tumor</i>	0%	0%	0%
<i>Pituitary</i> tumor	76%	84%	80%

Berdasarkan Tabel 4.24 dan Gambar 4.24, nilai *F1-score* pada skenario ini berkisar antara 0% sampai 80%. Kelas *pituitary tumor* menunjukkan kinerja terbaik

dengan *F1-score* sebesar 80%, didukung oleh *Precision* 76% dan *Recall* 84%. Dari 64 citra *pituitary*, 54 citra diklasifikasikan dengan benar sebagai *pituitary tumor*, sedangkan 10 citra lainnya masih salah diprediksi terutama sebagai *glioma tumor* dan *meningioma tumor*. Kelas *glioma tumor* memiliki *F1-score* sebesar 59% dengan *Precision* 71% dan *Recall* 50%; pada kelas ini, 30 dari 60 citra *glioma* terklasifikasi benar, sedangkan 30 citra lainnya menyebar salah prediksi terutama ke kelas *meningioma tumor* dan *pituitary tumor*. Kelas *meningioma tumor* memperoleh *F1-score* sebesar 64% dengan 43 dari 57 citra yang dikenali sesuai kelasnya, sementara citra lain salah diklasifikasikan sebagai *glioma tumor*, maupun *pituitary tumor*. Sementara itu, kelas *no tumor* memiliki nilai *Precision*, *Recall*, dan *F1-score* sebesar 0% karena tidak ada satupun dari 9 citra *no tumor* yang diprediksi sebagai *no tumor*; seluruh citra pada kelas ini salah diklasifikasikan sebagai *glioma tumor*, *meningioma tumor*, atau *pituitary tumor*.

4.2 Pembahasan

Hasil pengujian 24 skenario digunakan untuk menganalisis performa metode GLCM dan SVM dalam mengklasifikasikan jenis tumor otak. Setiap skenario merupakan kombinasi dari sudut pandang citra, kondisi dataset, dan jenis kernel. Ringkasan dari seluruh hasil dapat dilihat pada Tabel 4.25.

Tabel 4. 25 Ringkasan Hasil Pengujian 24 Skenario

Skenario	Dataset	Sudut Pandang	Kernel	Evaluasi			
				Accuracy	Precision	Recall	F1-score
Skenario 1	Balanced	Atas	Linear	78%	79%	78%	77%
Skenario 2		Atas	Polynomial	69%	73%	69%	69%
Skenario 3		Atas	RBF	75%	77%	75%	75%
Skenario 4		Atas	Sigmoid	58%	59%	58%	58%
Skenario 5		Samping	Linear	75%	77%	75%	74%
Skenario 6		Samping	Polynomial	83%	83%	83%	83%
Skenario 7		Samping	RBF	75%	76%	75%	75%


Skenario	Dataset	Sudut Pandang	Kernel	Evaluasi			
				Accuracy	Precision	Recall	F1-score
Skenario 8		Samping	<i>Sigmoid</i>	69%	53%	69%	60%
Skenario 9		Belakang	<i>Linear</i>	78%	78%	78%	78%
Skenario 10		Belakang	<i>Polynomial</i>	83%	83%	83%	83%
Skenario 11		Belakang	RBF	86%	89%	86%	84%
Skenario 12		Belakang	<i>Sigmoid</i>	69%	69%	69%	66%
Skenario 13		Atas	<i>Linear</i>	63%	65%	64%	64%
Skenario 14	Imbalanced	Atas	<i>Polynomial</i>	74%	74%	75%	74%
Skenario 15		Atas	RBF	71%	71%	71%	71%
Skenario 16		Atas	<i>Sigmoid</i>	52%	55%	51%	47%
Skenario 17		Samping	<i>Linear</i>	61%	63%	62%	60%
Skenario 18		Samping	<i>Polynomial</i>	71%	72%	72%	72%
Skenario 19		Samping	RBF	69%	68%	69%	68%
Skenario 20		Samping	<i>Sigmoid</i>	57%	53%	55%	53%
Skenario 21		Belakang	<i>Linear</i>	75%	81%	61%	62%
Skenario 22		Belakang	<i>Polynomial</i>	77%	82%	73%	76%
Skenario 23		Belakang	RBF	73%	67%	59%	60%
Skenario 24		Belakang	<i>Sigmoid</i>	67%	51%	53%	51%

Berdasarkan Tabel 4.25, kombinasi terbaik dapat diidentifikasi pada kondisi dataset *balanced* maupun *imbalanced*. Pada dataset *balanced*, performa tertinggi diperoleh pada Skenario 11 (sudut pandang belakang, kernel RBF) dengan nilai *F1-score* sebesar 84%. Sementara itu, pada dataset *imbalanced*, hasil terbaik ditunjukkan oleh Skenario 22 (sudut pandang belakang, kernel *Polynomial*) dengan *F1-score* sebesar 76%. Kedua hasil ini menunjukkan bahwa sudut pandang belakang memberikan informasi tekstur yang paling kuat, baik pada kondisi data seimbang maupun tidak seimbang.

Jika dilihat lebih rinci berdasarkan sudut pandang, pola yang muncul juga konsisten. Pada dataset *balanced*, sudut pandang atas menghasilkan nilai terbaik dengan kernel *Linear* dengan *F1-score* sebesar 77%. Sudut pandang samping mencapai hasil tertinggi ketika menggunakan kernel *Polynomial* dengan *F1-score* sebesar 83%, sedangkan sudut pandang belakang memperoleh performa terbaik dengan kernel RBF dengan *F1-score* sebesar 84%. Pada dataset *imbalanced*, sudut

pandang atas memberikan hasil terbaik ketika menggunakan kernel *Polynomial* dengan *F1-score* sebesar 74%. Sudut pandang samping juga memperoleh nilai tertinggi pada kernel *Polynomial* dengan *F1-score* sebesar 72%, dan sudut pandang belakang kembali menunjukkan performa terbaik melalui kernel *Polynomial* dengan *F1-score* sebesar 76%.

Untuk memperjelas perbandingan hasil pada seluruh skenario, disajikan Gambar 4.25 yang menampilkan nilai *F1-score* dari masing-masing skenario. Penggunaan *F1-score* mengacu pada penelitian Christen *et al.* (2023) yang menjelaskan bahwa metrik ini mempertimbangkan keseimbangan antara *Precision* dan *Recall*, sehingga lebih representatif untuk menilai performa model dibandingkan hanya menggunakan akurasi yang cenderung kurang peka terhadap kelas dengan jumlah data lebih sedikit.



Gambar 4. 25 Diagram Batang Perbandingan *F1-score* Seluruh Skenario Pengujian

Berdasarkan Gambar 4.25, nilai *F1-score* dari 24 skenario tersebar dalam kisaran sekitar 47% hingga 84%, yang menunjukkan adanya variasi kinerja model pada setiap kombinasi sudut pandang, kondisi dataset, dan kernel. Secara visual, diagram batang yang merepresentasikan skenario dengan dataset seimbang

cenderung memiliki nilai *F1-score* yang lebih tinggi dan lebih terkonsentrasi pada rentang menengah hingga tinggi, sedangkan skenario dengan dataset tidak seimbang lebih sering berada pada rentang nilai yang lebih rendah.

Pola ini menunjukkan bahwa pengujian dengan dataset seimbang menghasilkan performa yang lebih baik dan lebih konsisten dibandingkan dengan dataset tidak seimbang. Dengan kata lain, penyeimbangan jumlah citra pada setiap kelas membantu model mempelajari karakteristik tekstur secara lebih proporsional sehingga kemampuan klasifikasi menjadi lebih stabil.

Dataset *Brain Tumor Classification MRI* pada penelitian ini juga digunakan oleh Kadam *et al.* (2021) dengan pendekatan ANN, CNN yang dilatih dari nol, dan *transfer learning* menggunakan arsitektur VGG16. Tabel 4.26 menyajikan ringkasan hasil penelitian yang menggunakan dataset *Brain Tumor Classification MRI* yang sama.

Tabel 4. 26 Penelitian dengan Data yang Sama

No.	Sumber	Judul	Input	Metode	Hasil
1.	(Kadam <i>et al.</i> , 2021)	<i>Brain Tumor Classification using Deep Learning Algorithms</i>	3190 citra MRI (Kaggle Brain Tumor Classification MRI), 4 kelas (glioma, meningioma, pituitary, no tumor)	ANN CNN <i>Transfer Learning</i> (VGG 16)	ANN: akurasi 78%, <i>F1-score</i> 78% CNN: akurasi 90%, <i>F1-score</i> 91% VGG16: akurasi 94% <i>F1-score</i> 94%

Berdasarkan Tabel 4.26, Kadam *et al.* (2021) mencapai performa tertinggi menggunakan *transfer learning* VGG16. Pada konteks dataset yang sama, penelitian ini berkontribusi dengan memetakan faktor-faktor yang memengaruhi performa klasifikasi berbasis tekstur melalui ekstraksi fitur GLCM, sehingga citra MRI direpresentasikan ke dalam fitur yang eksplisit dan terukur serta dapat ditinjau

nilainya dan makna statistiknya. Berbeda dengan CNN yang mengekstraksi fitur secara otomatis (*end-to-end*) di dalam lapisan jaringan sehingga tidak langsung berupa indikator statistik yang dapat ditinjau satu per satu, penelitian ini mengamati perubahan performa pada tiga sudut pandang citra MRI, dua kondisi distribusi data, serta empat kernel SVM, sehingga diperoleh gambaran yang lebih spesifik mengenai kombinasi kondisi yang cenderung menghasilkan performa lebih baik. Pendekatan ini juga relatif lebih ringan secara komputasi karena pelatihan dilakukan pada vektor fitur berdimensi lebih rendah, tanpa pembaruan bobot berlapis dan iterasi pelatihan panjang seperti pada model *deep learning*.

Performa penelitian ini berada di bawah hasil Kadam *et al.* (2021) dan dapat dipengaruhi oleh perbedaan karakter pendekatan. Pada *deep learning* (terutama *transfer learning*), model mempelajari representasi fitur secara otomatis melalui lapisan konvolusi serta memanfaatkan bobot *pretrained*, sehingga mampu menangkap variasi pola citra yang lebih kompleks. Sementara itu, penelitian ini menggunakan fitur statistik GLCM yang merepresentasikan tekstur melalui ringkasan ciri, sehingga informasi yang digunakan model dibatasi pada fitur-fitur tersebut. Faktor lain yang turut memengaruhi adalah skala data latih efektif. Pada penelitian ini, data dipisahkan berdasarkan tiga sudut pandang, sehingga jumlah sampel pada masing-masing kelompok data menjadi lebih kecil dan variasi pola yang dipelajari model pada tiap kelompok menjadi lebih terbatas.

4.2.1 Performa Berdasarkan Keseimbangan Dataset

Keseimbangan data berperan penting dalam menentukan hasil klasifikasi. Perbandingan antara dua kondisi data, yaitu seimbang dan tidak seimbang,

dilakukan untuk melihat perbedaan performa metode pada masing-masing kondisi.


Ringkasan hasil pengujian ditunjukkan pada Tabel 4.27.

Tabel 4. 27 Rata-Rata Hasil Pengujian Pada Setiap Kondisi Dataset

Kondisi Dataset	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Seimbang	75%	75%	75%	75%
Tidak Seimbang	68%	67%	64%	65%

Berdasarkan Tabel 4.27, dataset seimbang menghasilkan performa yang lebih baik dibandingkan dataset tidak seimbang pada seluruh metrik evaluasi. Pada kondisi seimbang, rata-rata akurasi, *Precision*, *Recall*, dan *F1-score* masing-masing mencapai 75%, sedangkan pada kondisi tidak seimbang nilai tersebut menurun menjadi 68%, 67%, 64%, dan 65%. Dengan demikian, ketika model dilatih pada data yang tidak seimbang, penurunan terbesar pada *Recall* dan *F1-score* menunjukkan bahwa ketidakseimbangan jumlah data antar kelas membuat model lebih sering gagal mengenali sebagian kelas, khususnya kelas dengan jumlah sampel lebih sedikit, sehingga kemampuan model dalam membedakan citra MRI ke dalam empat kelas menjadi kurang konsisten.

Perbedaan pengaruh keseimbangan data juga terlihat ketika membandingkan skenario dengan sudut pandang dan kernel yang sama, tetapi menggunakan kondisi dataset yang berbeda. Perbandingan nilai *F1-score* per kelas pada kondisi *balanced* dan *imbalanced* tersebut ditunjukkan pada Gambar 4.26.



Gambar 4. 26 Perbandingan $F1$ -score Skenario 9 dan Skenario 21

Pada sudut pandang belakang (*coronal*) dengan kernel *Linear*, nilai $F1$ -score keseluruhan menurun dari 78% pada Skenario 9 (dataset seimbang) menjadi 62% pada Skenario 21 (dataset tidak seimbang). Pada Skenario 9, seluruh kelas masih menunjukkan nilai $F1$ -score yang relatif baik, termasuk kelas *no tumor* yang mencapai 78%. Namun pada Skenario 21, $F1$ -score kelas *no tumor* turun tajam menjadi hanya 20%, sementara tiga kelas tumor masih berada pada kisaran 70–87%. Hal ini mengindikasikan bahwa ketika distribusi data sangat tidak seimbang, model cenderung tetap mampu mengenali kelas mayoritas, tetapi mengalami kesulitan membedakan kelas dengan jumlah sampel yang jauh lebih sedikit.

Pengaruh ketidakseimbangan data paling jelas terlihat pada kelas *no tumor* di sudut pandang belakang (*coronal*), yang hanya memiliki 45 citra, sementara kelas *glioma*, *meningioma*, dan *pituitary* masing-masing memiliki 298, 285, dan 318 citra. Kondisi ini tercermin pada beberapa skenario dengan dataset tidak seimbang, khususnya skenario 21, 23, dan 24, di mana $F1$ -score kelas *no tumor* masing-masing hanya mencapai 20%, 18%, dan bahkan 0%. Pada skenario 24, tidak

ada satu pun citra *no tumor* yang berhasil diprediksi dengan benar sebagai *no tumor*, sehingga nilai *Precision*, *Recall*, dan *F1-score* semuanya bernilai 0%. Pola tersebut menunjukkan bahwa proses pembelajaran model lebih didominasi oleh informasi dari kelas tumor, sehingga citra otak sehat cenderung digolongkan ke dalam salah satu kelas tumor.

Secara teori, kondisi ini sejalan dengan karakteristik SVM yang membentuk *hyperplane* pemisah berdasarkan distribusi data pada masing-masing kelas. Ketika jumlah sampel pada kelas mayoritas jauh lebih besar, posisi *hyperplane* cenderung lebih dipengaruhi oleh kelas mayoritas, sehingga banyak sampel dari kelas minoritas berada di sisi yang salah dan terklasifikasi sebagai kelas mayoritas.

Hasil pengujian ini menegaskan bahwa keseimbangan jumlah data antar kelas berkaitan erat dengan kinerja kombinasi metode GLCM dan SVM. Pada dataset seimbang, fitur tekstur dari setiap kelas baik tumor maupun *no tumor* terwakili secara lebih proporsional, sehingga model dapat membentuk batas keputusan yang lebih seimbang dan tidak terlalu bias terhadap kelas mayoritas. Sebaliknya, pada dataset tidak seimbang, model cenderung belajar lebih banyak dari kelas dengan jumlah data besar dan kurang menangkap pola pada kelas minoritas.

4.2.2 Performa Berdasarkan Sudut Pandang Citra MRI

Sudut pandang citra menjadi salah satu faktor yang memengaruhi hasil klasifikasi karena menentukan bagian otak yang terlihat pada citra MRI. Setiap sudut pandang atas (*axial*), samping (*sagittal*), dan belakang (*coronal*) menampilkan struktur jaringan otak dari sisi yang berbeda, sehingga menghasilkan

variasi pola tekstur yang terekstraksi oleh metode GLCM. Perbedaan tekstur ini dapat memengaruhi kemampuan SVM dalam membedakan jenis tumor otak. Untuk melihat perbedaan performa pada masing-masing sudut, dilakukan perbandingan hasil pengujian pada ketiga sudut pandang tersebut, baik pada kondisi dataset seimbang maupun tidak seimbang. Perbandingan hasil pengujian pada ketiga sudut pandang citra tersebut ditunjukkan pada Tabel 4.28 untuk dataset seimbang dan Tabel 4.29 untuk dataset tidak seimbang.

Tabel 4. 28 Rata-Rata Hasil Pengujian Pada Setiap Sudut Pandang Citra (Dataset Seimbang)

Sudut Pandang Citra	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Atas	70%	72%	70%	71%
Samping	76%	72%	76%	74%
Belakang	79%	80%	79%	79%

Tabel 4. 29 Rata-Rata Hasil Pengujian Pada Setiap Sudut Pandang Citra (Dataset Tidak Seimbang)

Sudut Pandang Citra	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Atas	65%	66%	65%	65%
Samping	65%	64%	65%	64%
Belakang	73%	70%	62%	66%

Tabel 4.28 menunjukkan bahwa pada dataset seimbang, sudut pandang belakang (*coronal*) memberikan performa terbaik di antara ketiga sudut pandang. Sudut pandang ini menghasilkan rata-rata akurasi sebesar 79%, *Precision* 80%, *Recall* 79%, dan *F1-score* 79%. Nilai tersebut lebih tinggi dibandingkan sudut pandang samping dengan akurasi 76%, *Precision* 72%, *Recall* 76%, dan *F1-score* 74%, maupun sudut pandang atas dengan akurasi 70%, *Precision* 72%, *Recall* 70%, dan *F1-score* 71%. Kondisi ini menunjukkan bahwa informasi tekstur pada citra *coronal* lebih mudah dipisahkan oleh model SVM sehingga batas keputusan yang

terbentuk lebih jelas dalam membedakan empat kelas tumor otak maupun kondisi *no tumor*.

Pada sudut pandang samping (*sagittal*), kinerja model berada pada posisi menengah. Rata-rata *F1-score* sebesar 74% masih mencerminkan performa yang baik dan relatif stabil, meskipun sedikit di bawah sudut pandang belakang. Hal ini sejalan dengan hasil per skenario pada dataset seimbang, di mana kombinasi sudut samping dengan kernel *Polynomial* (Skenario 6) dan RBF (Skenario 7) memberikan nilai *F1-score* yang relatif tinggi dan mendekati hasil pada sudut pandang belakang, walaupun secara rata-rata masih belum melampauinya. Sementara itu, sudut pandang atas (*axial*) cenderung menghasilkan rata-rata *F1-score* terendah (70%), yang mengindikasikan bahwa pola tekstur pada sudut ini relatif lebih sulit dipisahkan dibandingkan dua sudut pandang lainnya ketika hanya menggunakan fitur GLCM.

Pada dataset tidak seimbang (Tabel 4.29), pola yang muncul tetap konsisten. Sudut pandang belakang (*coronal*) kembali menghasilkan nilai evaluasi tertinggi secara umum, dengan akurasi sebesar 73%, *Precision* 70%, *Recall* 62%, dan *F1-score* 66%. Dua sudut lainnya berada di bawahnya, yaitu sudut atas (*axial*) dengan akurasi 65%, *Precision* 66%, *Recall* 65%, dan *F1-score* 65%, serta sudut samping (*sagittal*) dengan akurasi 65%, *Precision* 64%, *Recall* 65%, dan *F1-score* 64%.

Secara keseluruhan, hasil pengujian pada kedua kondisi dataset menunjukkan bahwa sudut pandang belakang (*coronal*) merupakan sudut yang paling menguntungkan karena secara konsisten menghasilkan nilai akurasi, *Precision*, *Recall*, dan *F1-score* yang lebih tinggi dibandingkan sudut *axial* dan

sagittal. Hal ini menunjukkan bahwa informasi tekstur yang terekstraksi dari citra *coronal* dapat dimanfaatkan dengan lebih baik oleh kombinasi metode GLCM dan SVM dalam membedakan empat kelas citra MRI.

Pada sudut ini, bagian kiri, kanan, dan tengah otak terlihat secara bersamaan, sehingga area yang sering menjadi lokasi masing-masing jenis tumor, seperti tumor *pituitary* di bagian tengah bawah otak, *meningioma* pada selaput otak, dan *glioma* yang menyebar di jaringan otak, cenderung dapat teramati dengan lebih jelas dalam satu tampilan. Kondisi ini membuat perbedaan pola terang-gelap pada citra lebih mudah ditangkap oleh fitur GLCM, sehingga model SVM dapat membentuk batas keputusan yang lebih tepat dan menghasilkan performa klasifikasi yang lebih baik pada sudut *coronal* dibandingkan dua sudut pandang lainnya.

4.2.3 Performa Berdasarkan Jenis Kernel

Kernel pada algoritma SVM berperan penting dalam menentukan cara pemisahan data pada ruang fitur. Setiap jenis kernel memiliki karakteristik berbeda dalam memetakan data non-*Linear* agar dapat dipisahkan secara optimal. Pada penelitian ini, digunakan empat jenis kernel yaitu *Linear*, *Polynomial*, RBF, dan *Sigmoid*. Perbandingan hasil pengujian rata-rata performa keempat kernel tersebut ditunjukkan pada Tabel 4.30 untuk dataset seimbang dan Tabel 4.31 untuk dataset tidak seimbang.

Tabel 4. 30 Rata-Rata Hasil Pengujian Pada Setiap Kernel (Dataset Seimbang)

Kernel	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Linear</i>	77%	78%	77%	77%
<i>Polynomial</i>	78%	80%	78%	79%
RBF	79%	81%	79%	80%

Kernel	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Sigmoid</i>	65%	60%	65%	62%

Tabel 4. 31 Rata-Rata Hasil Pengujian Pada Setiap Kernel (Dataset Tidak Seimbang)

Kernel	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Linear</i>	66%	70%	62%	66%
<i>Polynomial</i>	74%	76%	73%	74%
RBF	71%	69%	66%	67%
<i>Sigmoid</i>	59%	53%	53%	53%

Pada dataset seimbang (Tabel 4.30), kernel RBF memberikan performa terbaik di antara keempat kernel yang diuji. Kernel ini menghasilkan rata-rata akurasi sebesar 79%, *Precision* 81%, *Recall* 79%, dan *F1-score* 80%. Nilai tersebut sedikit lebih tinggi dibandingkan kernel *Polynomial* dan *Linear* yang berada pada kisaran *F1-score* 77–79%. Sementara itu, kernel *Sigmoid* menunjukkan performa paling rendah dengan akurasi 65%, *Precision* 60%, *Recall* 65%, dan *F1-score* 62%.

Hasil ini menunjukkan bahwa pada kondisi data yang seimbang, kernel RBF paling mampu memanfaatkan variasi fitur tekstur GLCM untuk membentuk batas pemisah yang sesuai dengan pola sebaran empat kelas citra MRI. Sifatnya yang lebih fleksibel dalam memodelkan pemisahan non-*Linear* membuat RBF dapat mengikuti pola batas antar kelas yang lebih kompleks ketika setiap kelas memiliki jumlah sampel yang relatif seimbang.

Pada dataset tidak seimbang (Tabel 4.31), pengaruh kernel masih terlihat jelas, namun dengan urutan yang berbeda. Kernel *Polynomial* memberikan performa terbaik dengan akurasi rata-rata 74%, *Precision* 76%, *Recall* 73%, dan *F1-score* 74%. Kernel RBF berada di posisi berikutnya dengan akurasi 71%, *Precision* 69%, *Recall* 66%, dan *F1-score* 67%, disusul kernel *Linear* dengan

akurasi 66%, *Precision* 70%, *Recall* 62%, dan *F1-score* 66%. Kernel *Sigmoid* kembali menjadi yang terendah dengan akurasi 59%, *Precision* 53%, *Recall* 53%, dan *F1-score* 53%.

Hasil ini menunjukkan bahwa pada kondisi data yang tidak seimbang, kernel *Polynomial* lebih stabil dibandingkan RBF. *Polynomial* masih membentuk batas keputusan non-*Linear*, tetapi dengan bentuk yang lebih halus dan bersifat lebih global, sehingga tidak terlalu sensitif terhadap dominasi kelas mayoritas. Sebaliknya, fleksibilitas RBF yang tinggi cenderung lebih mudah terpengaruh oleh kelas dengan jumlah data besar, sehingga performanya sedikit menurun ketika distribusi data antar kelas tidak merata.

Konsistennya performa kernel *Sigmoid* yang selalu berada pada posisi terendah pada kedua kondisi dataset menunjukkan bahwa kernel ini kurang sesuai untuk pola fitur tekstur GLCM pada penelitian ini. Kernel *Sigmoid* bersifat lebih sensitif terhadap pemilihan parameter dan skala data sehingga pemisahan antar kelas menjadi kurang optimal, hal ini juga terlihat pada beberapa skenario pengujian yang menggunakan kernel *Sigmoid*. Misalnya, pada Skenario 16 (dataset tidak seimbang, sudut pandang atas, kernel *Sigmoid*) *F1-score* keseluruhan hanya mencapai 47%, dan pada Skenario 24 (dataset tidak seimbang, sudut pandang belakang, kernel *Sigmoid*) kelas *no tumor* sama sekali tidak terdeteksi sehingga nilai *Precision*, *Recall*, dan *F1-score* untuk kelas tersebut bernilai 0%.

Berdasarkan hasil percobaan, kernel RBF lebih cocok digunakan pada data dengan pola pemisahan non-*Linear* dan distribusi kelas yang relatif seimbang, sedangkan kernel *Polynomial* lebih sesuai untuk kondisi data yang masih

mengandung ketidakseimbangan antar kelas. Sementara itu, kernel *Sigmoid* menjadi pilihan yang paling tidak efektif pada konfigurasi fitur GLCM dan distribusi data yang digunakan dalam penelitian ini.

4.3 Integrasi Islam

Penelitian mengenai klasifikasi jenis tumor otak pada citra MRI menggunakan metode GLCM dan SVM dapat dipandang sebagai bagian dari ikhtiar ilmiah dalam membaca keteraturan ciptaan Allah. Pola tekstur pada citra MRI, perbedaan antara jaringan normal dan jaringan tumor, serta proses pemodelan matematika yang dilakukan dalam penelitian ini menunjukkan bahwa segala sesuatu di alam semesta memiliki ukuran dan ketentuan yang jelas. Hal ini sejalan dengan firman Allah dalam QS. Al-Qamar ayat 49:

إِنَّا كُلَّ شَيْءٍ خَلَقْنَاهُ بِقَدَرٍ

“*Sesungguhnya Kami menciptakan segala sesuatu menurut ukuran.*”
(Al-Qamar: 49)

Ayat tersebut menegaskan bahwa setiap makhluk dan setiap fenomena memiliki ukuran, aturan, dan ketentuan yang telah ditetapkan oleh Allah. Dalam konteks penelitian ini, pemanfaatan teknik ekstraksi ciri menggunakan GLCM dan pemodelan klasifikasi dengan SVM merupakan upaya untuk membaca dan memanfaatkan keteraturan tersebut secara sistematis. Dengan demikian, penggunaan teknologi tidak dimaksudkan untuk menandingi kekuasaan Allah, tetapi justru menjadi sarana untuk mengelola ilmu yang telah Allah anugerahkan demi kemaslahatan di bidang kesehatan.

Islam juga mendorong umatnya untuk berusaha mencari jalan terbaik dalam pengobatan dan penjagaan kesehatan. Pengembangan sistem klasifikasi jenis tumor otak pada penelitian ini termasuk salah satu bentuk ikhtiar untuk membantu proses diagnosis agar lebih cepat dan lebih tepat. Hal ini sejalan dengan sabda Rasulullah shallallahu ‘alaihi wasallam:

دَاءٌ دَوَاءٌ فَإِذَا أُصِيبَ دَوَاءُ الدَّاءِ بَرَأَ بِإِذْنِ اللَّهِ

“Setiap penyakit ada obatnya. Apabila obat tersebut sesuai dengan penyakitnya, maka ia akan sembuh dengan izin Allah.” (HR. Muslim, no. 2204)

Hadis ini mengajarkan bahwa penyakit perlu dikenali dan ditangani dengan cara yang tepat. Sistem klasifikasi yang dikembangkan dalam penelitian ini dapat digunakan sebagai alat bantu bagi tenaga medis dalam membedakan jenis tumor otak berdasarkan citra MRI, sehingga terapi yang diberikan dapat lebih sesuai dengan kondisi pasien. Namun demikian, hasil sistem tetap berada pada ranah ikhtiar manusia, sedangkan kesembuhan sepenuhnya berada dalam kekuasaan Allah.

Di sisi lain, penelitian ini juga dapat dipandang sebagai bentuk muamalah manusia dengan alam, yaitu memanfaatkan ciptaan Allah secara bijak untuk kemaslahatan. Melalui analisis citra MRI, penelitian ini berupaya memahami struktur dan kondisi tubuh manusia yang merupakan bagian dari ciptaan-Nya. Hal ini sejalan dengan firman Allah dalam QS. Al-Mulk ayat 15:

هُوَ الَّذِي جَعَلَ لَكُمُ الْأَرْضَ ذَلُولًا فَامْشُوا فِي مَنَاكِبِهَا وَكُلُوا مِن رِّزْقِهِ وَإِلَيْهِ النُّشُورُ

“Dialah yang menjadikan bumi untuk kamu dalam keadaan mudah dimanfaatkan. Maka, jelajahilah segala penjurunya dan makanlah sebagian dari rezeki-Nya. Hanya kepada-Nya kamu (kembali setelah) dibangkitkan.” (Al-Mulk: 15)

Ayat ini menunjukkan bahwa eksplorasi ilmu pengetahuan, termasuk pemanfaatan citra medis untuk mendukung diagnosis, merupakan bagian dari upaya memanfaatkan karunia Allah di bumi secara bertanggung jawab.

Penelitian ini juga mencerminkan perintah untuk saling tolong-menolong dalam kebaikan, termasuk dalam pengembangan layanan kesehatan. Kolaborasi antara bidang teknik informatika, kedokteran, dan ilmu kesehatan dalam merancang dan menguji sistem klasifikasi tumor otak merupakan bentuk kerja sama yang bertujuan memberikan manfaat bagi pasien, rumah sakit, dan peneliti di masa mendatang. Hal ini sejalan dengan firman Allah dalam QS. Al-Mā'idah:2

وَتَعَاوَنُوا عَلَى الْبِرِّ وَالتَّقْوَىٰ وَلَا تَعَاوَنُوا عَلَى الْإِثْمِ وَالْعُدْوَانِ وَاتَّقُوا اللَّهَ إِنَّ اللَّهَ شَدِيدُ الْعِقَابِ

“Tolong-menolonglah kamu dalam kebajikan dan takwa, dan jangan tolong-menolong dalam berbuat dosa dan permusuhan. Bertakwalah kepada Allah, sesungguhnya Allah sangat berat siksaan-Nya.” (QS. Al-Mā'idah: 2)

Tujuan penelitian yang berorientasi pada peningkatan kualitas diagnosis menunjukkan bahwa teknologi yang dikembangkan diarahkan untuk mendukung kebajikan dan kemaslahatan. Dengan tetap menjaga etika penelitian, dan tanggung jawab dalam pemanfaatan teknologi, penelitian ini tidak hanya bernilai akademik, tetapi juga menjadi wujud penerapan nilai-nilai Islam dalam bentuk ikhtiar ilmiah dan tolong-menolong dalam kebaikan di bidang kesehatan.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM) dan *Support Vector Machine* (SVM) pada citra MRI tumor otak, beberapa kesimpulan yang dapat diambil adalah sebagai berikut:

1. Kombinasi ekstraksi fitur tekstur GLCM dan klasifikasi SVM memberikan kinerja yang baik dalam mengklasifikasikan jenis tumor otak berbasis citra MRI.
2. Dataset seimbang menghasilkan kinerja model yang lebih baik dan lebih konsisten, sedangkan dataset tidak seimbang cenderung menurunkan kemampuan model dalam mengenali kelas dengan jumlah data lebih sedikit.
3. Sudut pandang *coronal* menghasilkan performa yang paling stabil dibandingkan sudut pandang *axial* dan *sagittal*.
4. Jenis kernel memengaruhi hasil klasifikasi. Kernel RBF lebih sesuai pada dataset seimbang, sedangkan kernel *Polynomial* lebih stabil pada dataset tidak seimbang.
5. Kernel *Sigmoid* memberikan kinerja paling rendah dibandingkan kernel lainnya sehingga kurang sesuai digunakan pada penelitian ini.

5.2 Saran

Berdasarkan hasil penelitian dan keterbatasan yang ditemui, beberapa saran yang dapat diberikan untuk pengembangan penelitian selanjutnya adalah sebagai berikut:

1. Mengembangkan metode ekstraksi fitur yang lebih beragam, seperti *Local Binary Patterns* (LBP), *Haralick features* yang lebih lengkap, atau kombinasi beberapa metode tekstur, sehingga representasi fitur yang dihasilkan lebih baik dan dapat meningkatkan performa klasifikasi.
2. Menerapkan metode klasifikasi yang lebih kompleks, seperti ensemble SVM, atau pendekatan *deep learning* seperti *Convolutional Neural Network* (CNN), untuk mendapatkan hasil pembandingan dan melihat apakah performanya dapat melampaui kombinasi GLCM dan SVM.
3. Menambah ukuran dan variasi dataset, baik dengan memperbesar jumlah citra dari setiap kelas maupun menggunakan dataset MRI dari sumber lain, agar model mampu melakukan generalisasi yang lebih baik dan mengurangi risiko penurunan performa pada kelas tertentu.

DAFTAR PUSTAKA

- Abdelfattah, S., Baza, M., Mahmoud, M., Fouda, M. M., Abualsaud, K., Yaacoub, E., Alsabaan, M., & Guizani, M. (2023). Lightweight Multi-Class Support Vector Machine-Based Medical Diagnosis System with Privacy Preservation. *Sensors*, 23(22), 1–25. <https://doi.org/10.3390/s23229033>
- Albalawi, E., Thakur, A., Dorai, D. R., Bhatia Khan, S., Mahesh, T. R., Almusharraf, A., Aurangzeb, K., & Anwar, M. S. (2024). Enhancing brain tumor classification in MRI scans with a multi-layer customized convolutional neural network approach. *Frontiers in Computational Neuroscience*, 18(June), 1–19. <https://doi.org/10.3389/fncom.2024.1418546>
- Alibabaei, S., Rahmani, M., Tahmasbi, M., Tahmasebi Birgani, M. J., & Razmjoo, S. (2023). Evaluating the gray level co-occurrence matrix-based texture features of magnetic resonance images for glioblastoma multiform patients' treatment response assessment. *Journal of Medical Signals and Sensors*, 13(4), 261–271. https://doi.org/10.4103/jmss.jmss_50_22
- Alnaggar, O. A. M. F., Jagadale, B. N., Saif, M. A. N., Ghaleb, O. A. M., Ahmed, A. A. Q., Aqlan, H. A. A., & Al-Ariki, H. D. E. (2024). Efficient artificial intelligence approaches for medical image processing in healthcare: comprehensive review, taxonomy, and analysis. In *Artificial Intelligence Review* (Vol. 57, Issue 8). Springer Netherlands. <https://doi.org/10.1007/s10462-024-10814-2>
- Amaya-Tejera, N., Gamarra, M., Vélez, J. I., & Zurek, E. (2024). A distance-based kernel for classification via Support Vector Machines. *Frontiers in Artificial Intelligence*, 7. <https://doi.org/10.3389/frai.2024.1287875>
- Barburiceanu, S., Terebes, R., & Meza, S. (2021). 3D Texture Feature Extraction and Classification Using Glcm and Lbp-Based Descriptors. *Applied Sciences (Switzerland)*, 11(5), 1–26. <https://doi.org/10.3390/app11052332>
- Byun, Y. H., & Park, C.-K. (2022). Classification and Diagnosis of Adult Glioma: A Scoping Review. *Brain & Neurorehabilitation*, 15(3). <https://doi.org/10.12786/bn.2022.15.e23>
- Casar Borota, O. (2024). The 2022 WHO classification of tumors of the pituitary gland An update on.pdf.
- Christaki, M., Vasilakos, C., Papadopoulou, E. E., Tataris, G., Siarkos, I., & Soulakellis, N. (2022). Building Change Detection Based on a Gray-Level

Co-Occurrence Matrix and Artificial Neural Networks. *Drones*, 6(12).
<https://doi.org/10.3390/drones6120414>

Christen, P., Hand, D. J., & Kirielle, N. (2023). A Review of the F-Measure : Its History , Properties , Criticism ,. 56(3). <https://doi.org/10.1145/3606367>

Cusworth, S., Gkoutos, G. V., & Acharjee, A. (2024). A novel generative adversarial networks modelling for the class imbalance problem in high dimensional omics data. *BMC Medical Informatics and Decision Making*, 24(1), 1–17. <https://doi.org/10.1186/s12911-024-02487-2>

Dixon, J., Akinniyi, O., Abdelhamid, A., Saleh, G. A., Rahman, M. M., & Khalifa, F. (2024). A Hybrid Learning-Architecture for Improved Brain Tumor Recognition. *Algorithms*, 17(6), 1–17. <https://doi.org/10.3390/a17060221>

Eisenbarth, D., & Wang, Y. A. (2023). Glioblastoma heterogeneity at single cell resolution. *Oncogene*, 42(27), 2155–2165. <https://doi.org/10.1038/s41388-023-02738-y>

Faradisia, A., & Pakereng, M. A. I. (2025). Comparative Analysis of Linear , Polynomial , RBF , and Sigmoid Kernels in Support Vector Machine for Heart Disease Classification Analisis Komparatif Kernel Linear , Polynomial , RBF , dan Sigmoid pada Support Vector Machine untuk Klasifikasi Penyakit Jantung. 5(October), 1531–1537.

Febrianti, A. S., Sardjono, T. A., & Babgei, A. F. (2020). Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine. *Jurnal Teknik ITS*, 9(1). <https://doi.org/10.12962/j23373539.v9i1.51587>

Ferlay, J., Colombet, M., Soerjomataram, I., Parkin, D. M., Piñeros, M., Znaor, A., & Bray, F. (2024). Cancer statistics for the year 2022: An overview. *International Journal of Cancer*, 149(4), 778–789. <https://doi.org/10.1002/ijc.33588>

Guido, R., Ferrisi, S., Lofaro, D., & Conforti, D. (2024). An Overview on the Advancements of Support Vector Machine Models in Healthcare Applications: A Review. *Information (Switzerland)*, 15(4). <https://doi.org/10.3390/info15040235>

Haralick, M. R., Shanmugam, K. I., & Dinstein. (1973). Textural Features for Image Classification. *SEG Technical Program Expanded Abstracts*, 34, 1811–1815. <https://doi.org/10.1190/segam2015-5927230.1>

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>

Hussain, L., Malibari, A. A., Alzahrani, J. S., Alamgeer, M., Obayya, M., Al-Wesabi, F. N., Mohsen, H., & Hamza, M. A. (2022). Bayesian dynamic profiling and optimization of important ranked energy from gray level co-occurrence (GLCM) features for empirical analysis of brain MRI. *Scientific Reports*, 12(1), 1–19. <https://doi.org/10.1038/s41598-022-19563-0>

Iqbal, N., Mumtaz, R., Shafi, U., & Zaidi, S. M. H. (2021). Gray level co-occurrence matrix (GLCM) texture based crop classification using low altitude remote sensing platforms. *PeerJ Computer Science*, 7, 1–26. <https://doi.org/10.7717/PEERJ-CS.536>

Kadam, A., Bhuvaji, S., & Deshpande, S. (2021). Brain Tumor Classification using Deep Learning Algorithms. 9(Xii), 417–426.

Kocak, B., Klontzas, M. E., Stanzione, A., Meddeb, A., Demircioğlu, A., Bluethgen, C., Bressem, K. K., Ugga, L., Mercaldo, N., Díaz, O., & Cuocolo, R. (2025). Evaluation metrics in medical imaging AI: fundamentals, pitfalls, misapplications, and recommendations. *European Journal of Radiology Artificial Intelligence*, 3(June), 100030. <https://doi.org/10.1016/j.ejrai.2025.100030>

Louis, D. N., Perry, A., Wesseling, P., Brat, D. J., Cree, I. A., Figarella-Branger, D., Hawkins, C., Ng, H. K., Pfister, S. M., Reifenberger, G., Soffietti, R., von Deimling, A., & 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/10.1093/neuonc/noab106>

Martucci, M., Russo, R., Schimperna, F., D’Apolito, G., Panfilì, 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>

Mitchell, D. K., Kwon, H. J., Kubica, P. A., Huff, W. X., O’Regan, R., & Dey, M. (2022). Brain metastases: An update on the multi-disciplinary approach of clinical management. *Neurochirurgie*, 68(1), 69–85. <https://doi.org/10.1016/j.neuchi.2021.04.001>

Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Fundamentals of Artificial Neural Networks and Deep Learning. In: *Multivariate Statistical Machine Learning Methods for Genomic Prediction*. In *Multivariate Statistical Machine Learning Methods for Genomic Prediction*.

- Mutiara, T. A. (Tika), & Azizah, Q. N. (Qudsiah). (2022). Klasifikasi Tumor Otak Menggunakan Ekstraksi Fitur HOG dan Support Vector Machine. *Jurnal Khatulistiwa Informatika*, 4(1), 45–50. <https://www.neliti.com/publications/491268/>
- Naz, F., & Siddique, Y. H. (2020). Human Brain Disorders: A Review. *The Open Biology Journal*, 8(1), 6–21. <https://doi.org/10.2174/1874196702008010006>
- Ogasawara, C., Philbrick, B. D., & Adamson, D. C. (2021). Meningioma: A review of epidemiology, pathology, diagnosis, treatment, and future directions. *Biomedicines*, 9(3). <https://doi.org/10.3390/biomedicines9030319>
- Piccialli, V., & Sciandrone, M. (2022). Nonlinear optimization and support vector machines. *Annals of Operations Research*, 314(1), 15–47. <https://doi.org/10.1007/s10479-022-04655-x>
- Pichaivel, M., Anbumani, G., Theivendren, P., & Gopal, M. (2022). An Overview of Brain Tumor. *Brain Tumors*. <https://doi.org/10.5772/intechopen.100806>
- Sadad, A., Utami, E., & Hartanto, A. D. (2023). A systematic literature review of gray level co-occurrence matrix on plants. *Journal of Intelligent Decision Support System (IDSS)*, 6(3), 121–128.
- Sajjadi, S. F., Salehi, N., & Sadeghi, M. (2024). Comprehensive integrated single-cell RNA sequencing analysis of brain metastasis and glioma microenvironment: Contrasting heterogeneity landscapes. *PLoS ONE*, 19(7 July), 1–20. <https://doi.org/10.1371/journal.pone.0306220>
- Singh, A. K. (2021). Role of Advanced Magnetic Resonance Imaging Techniques in the Evaluation of Intracranial Masses and Mass like Lesions. *Journal of Medical Science And Clinical Research*, 09(04), 143–162. <https://doi.org/10.18535/jmscr/v9i4.23>
- Smith, C. J., Perfetti, T. A., Chokshi, C., Venugopal, C., Ashford, J. W., & Singh, S. K. (2024). Risk factors for glioblastoma are shared by other brain tumor types. *Human and Experimental Toxicology*, 43, 1–6. <https://doi.org/10.1177/09603271241241796>
- Srivastava, S., Kumar, L., Jeyanthi, R., Deepa, K., & Aggrawal, V. (2022). Framework for Ship Trajectory Forecasting Based on Linear Stationary Models Using Automatic Identification System. *Procedia Computer Science*, 218(2022), 1463–1474. <https://doi.org/10.1016/j.procs.2023.01.125>
- Tamada, D. (2020). Review: Noise and artifact reduction for MRI using deep learning. 1–9. <http://arxiv.org/abs/2002.12889>

- Vijithananda, S. M., Jayatilake, M. L., Hewavithana, B., Gonçalves, T., Rato, L. M., Weerakoon, B. S., Kalupahana, T. D., Silva, A. D., & Dissanayake, K. D. (2022). Feature extraction from MRI ADC images for brain tumor classification using machine learning techniques. *BioMedical Engineering Online*, 21(1), 1–21. <https://doi.org/10.1186/s12938-022-01022-6>
- Wahyu Ardiantito S, Stacyana Jesika Surianto, Suci Ramadhani, & Willy Pramudia Ananta. (2023). Klasifikasi Tumor Otak Menggunakan Local Binary Pattern dan SVM Classifier. *Student Research Journal*, 1(6), 182–190. <https://doi.org/10.55606/srjyappi.v1i6.823>
- Zahid, M., Rziza, M., & Alaoui, R. (2025). Skin Lesion Classification Using Hybrid Feature Extraction Based on Classical and Deep Learning Methods. *BioMedInformatics*, 5(3), 41. <https://doi.org/10.3390/biomedinformatics5030041>
- Zhao, X., He, M., Yang, R., Geng, N., Zhu, X., & Tang, N. (2025). The global, regional, and national brain and central nervous system cancer burden and trends from 1990 to 2021: an analysis based on the Global Burden of Disease Study 2021. *Frontiers in Neurology*, 16(June), 1–20. <https://doi.org/10.3389/fneur.2025.1574614>
- Zulkarnain, Z., Mutia, R., Ariani, J. A., Barik, Z. A., & Azmi, H. (2024). Performance Comparison K-Nearest Neighbor, Naive Bayes, and Decision Tree Algorithms for Netflix Rating Classification. *IJATIS: Indonesian Journal of Applied Technology and Innovation Science*, 1(1), 16–22. <https://doi.org/10.57152/ijatis.v1i1.1104>

LAMPIRAN

Lampiran 1 *Graphical User Interface*

Klasifikasi Jenis Tumor Otak – GLCM + SVM

Upload citra MRI otak dan pilih sudut pandang. Sistem akan mengekstraksi fitur GLCM dan mengklasifikasikan tumor menggunakan SVM.

Upload Citra MRI

Letakkan Gambar di Sini
- atau -
Klik untuk Mengunggah

Pilih Sudut Pandang

ATAS (Axial)

Klasifikasikan


Reset

Hasil Klasifikasi

Klasifikasi Jenis Tumor Otak – GLCM + SVM

Upload citra MRI otak dan pilih sudut pandang. Sistem akan mengekstraksi fitur GLCM dan mengklasifikasikan tumor menggunakan SVM.

Upload Citra MRI



Pilih Sudut Pandang

BELAKANG (Coronal)

Klasifikasikan

Reset

Hasil Klasifikasi

meningioma_tumor

meningioma_tumor	68%
glioma_tumor	16%
no_tumor	11%
pituitary_tumor	5%