

Pengaruh Orientasi Citra MRI pada Klasifikasi Tumor Otak Berbasis GLCM dan SVM

Yoza Setya Febriyanti ^{(1)*}, Okta Qomaruddin Aziz ⁽²⁾, Suhartono ⁽³⁾

Departemen Teknik Informatika, UIN Maulana Malik Ibrahim Malang, Malang, Indonesia
e-mail : yozasetya@gmail.com, okta.qomaruddin@uin-malang.ac.id, suhartono@ti.uin-malang.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 29 Desember 2025, direvisi 23 April 2026, diterima 23 April 2026, dan dipublikasikan 25 Mei 2026.

Abstract

Brain tumors are a global health problem, ranking 12th as a cause of death. MRI is used in the diagnosis of brain tumors because of its ability to display soft tissue structures in detail, but manual interpretation of MRI images by radiologists is still subjective. Therefore, a more objective computer-based classification approach is needed. One factor that could potentially affect classification performance is the difference in MRI image orientation, namely axial, sagittal, and coronal. This study aims to analyze the effect of MRI image orientation on GLCM and SVM-based brain tumor classification. The preprocessing stage includes cropping, noise reduction, and resizing. Feature extraction was performed using GLCM with distance $d = 1$ at angles of 0° , 45° , 90° , and 135° with contrast, correlation, energy, and homogeneity features. Classification was performed using SVM with Linear, Polynomial, RBF, and Sigmoid kernels. The test results show that the axial orientation produces the highest accuracy of 78% with the Linear kernel, the sagittal orientation achieves an accuracy of 83% with the Polynomial kernel, and the coronal orientation provides the highest accuracy of 86% with the RBF kernel. These findings indicate that the orientation of MRI images affects the performance of texture-based brain tumor classification.

Keywords: Brain Tumor, MRI Image, GLCM, SVM, Image Processing

Abstrak

Tumor otak merupakan masalah kesehatan global yang menempati peringkat ke-12 sebagai penyebab kematian. MRI digunakan dalam diagnosis tumor otak karena kemampuannya menampilkan struktur jaringan lunak secara detail, namun interpretasi citra MRI secara manual oleh radiolog masih bersifat subjektif. Oleh karena itu, diperlukan pendekatan klasifikasi berbasis komputer yang lebih objektif. Salah satu faktor yang berpotensi memengaruhi kinerja klasifikasi adalah perbedaan orientasi citra MRI, yaitu *axial*, *sagittal*, dan *coronal*. Penelitian ini bertujuan menganalisis pengaruh orientasi citra MRI terhadap klasifikasi tumor otak berbasis GLCM dan SVM. Tahap preprocessing meliputi *cropping*, *noise reduction*, dan *resize*. Ekstraksi fitur dilakukan menggunakan GLCM dengan jarak $d = 1$ pada sudut 0° , 45° , 90° , dan 135° dengan fitur *contrast*, *correlation*, *energy*, dan *homogeneity*. Klasifikasi dilakukan menggunakan SVM dengan kernel *Linear*, *Polynomial*, RBF, dan *Sigmoid*. Hasil pengujian menunjukkan bahwa orientasi *axial* menghasilkan akurasi tertinggi 78% dengan kernel *Linear*, orientasi *sagittal* mencapai akurasi 83% dengan kernel *Polynomial*, dan orientasi *coronal* memberikan akurasi tertinggi 86% dengan kernel RBF. Temuan ini menunjukkan bahwa orientasi citra MRI berpengaruh terhadap performa klasifikasi tumor otak berbasis tekstur.

Kata Kunci: Tumor Otak, Citra MRI, GLCM, SVM, Pengolahan Citra

1. PENDAHULUAN

Tumor otak merupakan gangguan pada sistem saraf pusat yang dapat memengaruhi berbagai fungsi vital manusia, seperti fungsi motorik, sensorik, dan kognitif. Kondisi ini ditandai oleh pertumbuhan sel abnormal pada jaringan otak atau area sekitarnya, yang dapat bersifat jinak maupun ganas, dengan karakteristik serta tingkat keparahan yang berbeda pada setiap jenisnya (Pichavel et al., 2022). *World Health Organization* (WHO) mengelompokkan tumor otak ke dalam



beberapa jenis utama, yaitu *glioma*, *meningioma*, dan tumor kelenjar hipofisis (*pituitary*), yang masing-masing memiliki karakteristik klinis dan radiologis yang berbeda (Louis et al., 2021).

Berdasarkan data *Global Cancer Observatory* (GLOBOCAN) tahun 2022, tumor otak dan sistem saraf pusat menempati peringkat ke-19 sebagai jenis kanker dengan jumlah kasus baru terbanyak di dunia dan peringkat ke-12 sebagai penyebab kematian akibat kanker. Jumlah kasus baru yang tercatat mencapai 321.731 kasus, dengan total kematian sebanyak 248.500 jiwa (Ferlay et al., 2024). Data tersebut menunjukkan bahwa tumor otak masih menjadi permasalahan kesehatan yang signifikan, sehingga diperlukan pendekatan diagnosis yang akurat dan andal untuk mendukung deteksi dini serta perencanaan terapi yang tepat.

Dalam praktik klinis, *Magnetic Resonance Imaging* (MRI) merupakan modalitas pencitraan utama yang digunakan dalam diagnosis dan evaluasi tumor otak. MRI memiliki keunggulan dalam menampilkan kontras jaringan lunak secara detail tanpa paparan radiasi pengion, sehingga lebih sensitif dalam mengidentifikasi perubahan jaringan akibat pertumbuhan tumor, edema, maupun perdarahan mikro dibandingkan *CT scan* (Singh, 2021). Meskipun demikian, interpretasi citra MRI masih sangat bergantung pada pengalaman radiolog, yang berpotensi menimbulkan subjektivitas dan ketidakkonsistenan dalam proses klasifikasi, terutama pada citra dengan kompleksitas tinggi (Albalawi et al., 2024). Kondisi ini mendorong pengembangan sistem klasifikasi berbasis komputer untuk meningkatkan akurasi dan konsistensi diagnosis.

Pendekatan *machine learning* telah banyak diterapkan dalam analisis citra medis, termasuk pada klasifikasi tumor otak berbasis citra MRI. Salah satu tahapan penting dalam pendekatan ini adalah ekstraksi fitur, yang bertujuan merepresentasikan informasi citra ke dalam bentuk fitur numerik yang lebih ringkas dan informatif (Tamada, 2020). *Gray Level Co-Occurrence Matrix* (GLCM) merupakan metode ekstraksi fitur tekstur yang banyak digunakan pada citra MRI karena mampu merepresentasikan hubungan statistik antar tingkat keabuan piksel pada jarak dan arah tertentu. Karakteristik tersebut memungkinkan GLCM untuk menggambarkan heterogenitas jaringan otak secara lebih jelas (Hussain et al., 2022). Sejumlah penelitian menunjukkan bahwa fitur-fitur GLCM, seperti *contrast*, *correlation*, *energy*, dan *homogeneity*, bersifat informatif dalam membedakan karakteristik jaringan tumor otak (Vijithananda et al., 2022).

Setelah proses ekstraksi fitur, tahap klasifikasi berperan dalam menentukan label jenis tumor berdasarkan fitur yang diperoleh. *Support Vector Machine* (SVM) merupakan salah satu algoritma klasifikasi yang banyak digunakan dalam citra medis karena kemampuannya menangani data berdimensi tinggi, ukuran sampel terbatas, serta distribusi kelas yang tidak seimbang melalui pembentukan batas keputusan yang optimal (Srivastava et al., 2022). Beberapa penelitian telah menggabungkan ekstraksi fitur dengan SVM untuk klasifikasi tumor otak. Febrianti et al. (2020) menggunakan fitur GLCM dengan tujuh parameter tekstur dan memperoleh akurasi sebesar 76% untuk klasifikasi dua kelas. Mutiara dan Azizah (2022) memanfaatkan fitur *Histogram of Oriented Gradients* (HOG) dengan SVM untuk klasifikasi empat kelas tumor otak dan memperoleh akurasi sebesar 91%. Sementara itu, Ardiantito et al. (2023) menggunakan fitur *Local Binary Patterns* (LBP) dengan SVM dan memperoleh akurasi sebesar 88% pada empat kelas.

Meskipun berbagai pendekatan tersebut menunjukkan performa yang cukup baik, masih terdapat beberapa keterbatasan yang belum banyak dikaji secara mendalam. Pada metode ekstraksi fitur, GLCM memiliki ketergantungan yang tinggi terhadap parameter arah dan jarak dalam merepresentasikan hubungan spasial antar piksel. Sebagian besar penelitian sebelumnya hanya menggunakan satu arah tertentu atau tidak mempertimbangkan variasi orientasi citra secara eksplisit, sehingga informasi tekstur yang dihasilkan menjadi tidak sepenuhnya representatif terhadap variasi pola spasial pada citra MRI dengan sudut pandang yang berbeda. Kondisi ini berpotensi menurunkan kemampuan fitur dalam membedakan kelas tumor ketika citra memiliki orientasi yang beragam.

Di sisi lain, pada tahap klasifikasi, penggunaan SVM dalam penelitian sebelumnya umumnya terbatas pada pemilihan kernel tertentu tanpa dilakukan analisis komprehensif terhadap



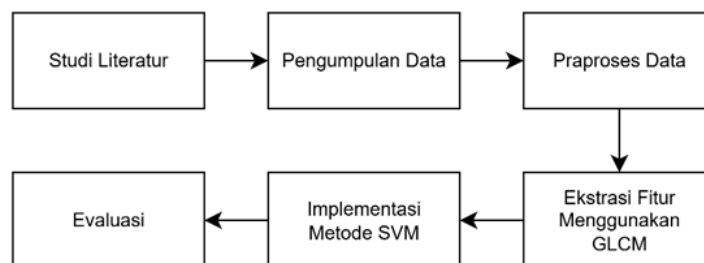
pengaruh variasi kernel dan konfigurasi *hyperparameter* terhadap performa model. Padahal, perbedaan distribusi fitur tekstur yang dihasilkan dari citra MRI dapat memerlukan fungsi kernel yang berbeda agar pemisahan kelas pada ruang fitur dapat dilakukan secara optimal. Keterbatasan ini menunjukkan bahwa hubungan antara karakteristik fitur dan konfigurasi model belum sepenuhnya dieksplorasi.

Selain itu, sebagian besar penelitian terdahulu lebih berfokus pada peningkatan akurasi melalui kombinasi metode ekstraksi fitur dan algoritma klasifikasi, tanpa mempertimbangkan faktor teknis lain yang berpotensi memengaruhi hasil klasifikasi, seperti orientasi citra MRI. Dalam praktiknya, citra MRI dapat diperoleh dalam berbagai orientasi, seperti *axial*, *sagittal*, dan *coronal*, yang masing-masing memberikan tampilan struktur anatomi yang berbeda. Perbedaan orientasi ini berpotensi menghasilkan variasi representasi tekstur yang signifikan, namun aspek tersebut masih jarang dianalisis secara khusus dalam konteks klasifikasi tumor otak berbasis citra.

Berdasarkan keterbatasan tersebut, penelitian ini bertujuan untuk menganalisis pengaruh orientasi citra MRI terhadap performa klasifikasi tumor otak berbasis fitur tekstur GLCM dan algoritma SVM. Berbeda dengan penelitian sebelumnya yang berfokus pada peningkatan akurasi melalui kombinasi metode, penelitian ini secara khusus menitikberatkan pada analisis pengaruh orientasi citra terhadap performa klasifikasi. Dengan demikian, kontribusi utama penelitian ini terletak pada aspek analisis orientasi citra MRI (*axial*, *sagittal*, dan *coronal*), serta bagaimana orientasi tersebut memengaruhi hasil ekstraksi fitur dan kinerja model klasifikasi.

2. METODE PENELITIAN

Penelitian ini bertujuan menganalisis pengaruh orientasi citra MRI (*axial*, *sagittal*, dan *coronal*) terhadap performa klasifikasi tumor otak berbasis fitur tekstur GLCM dan algoritma SVM. Seluruh tahapan pengolahan citra dan pemodelan dilakukan menggunakan bahasa pemrograman *Python* pada platform *Google Colab*. Rangkaian tahapan penelitian disajikan pada Gambar 1.



Gambar 1 Desain Tahapan Penelitian

Berdasarkan Gambar 1, penelitian diawali dengan studi literatur dan pengumpulan data citra MRI. Tahap praproses meliputi *cropping* untuk memfokuskan area otak, *noise reduction* untuk mengurangi gangguan pada citra, serta *resize* untuk menyeragamkan ukuran citra sebelum ekstraksi fitur dilakukan. Fitur tekstur GLCM kemudian digunakan sebagai masukan dalam pelatihan dan pengujian model SVM sehingga diperoleh prediksi kelas tumor, yang selanjutnya dinilai kinerjanya menggunakan *confusion matrix* dan metrik evaluasi.

2.1 Pengumpulan Data

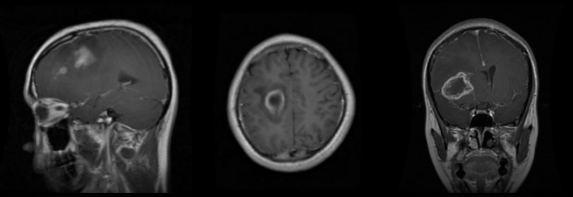
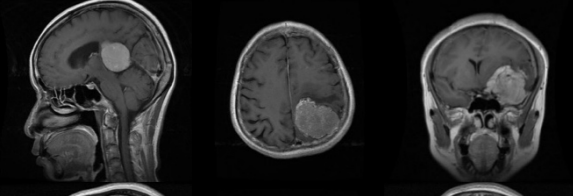
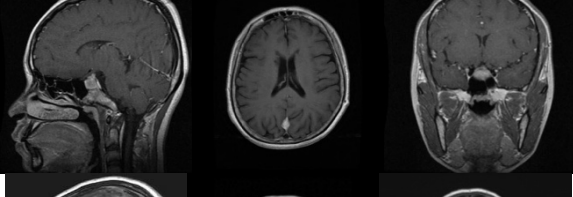
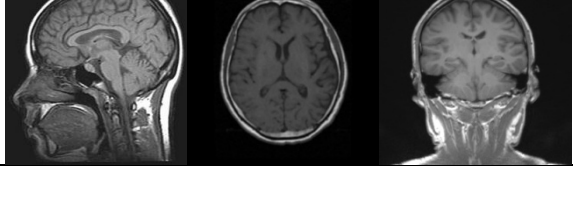
Data yang digunakan pada penelitian ini merupakan data sekunder berupa citra MRI otak dari dataset publik *Brain Tumor Classification* (MRI) yang tersedia pada platform *Kaggle*: (<https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>). Dataset ini dikembangkan oleh Bhuvaji et al. (2021) yang juga digunakan dalam penelitian mereka terkait klasifikasi tumor otak berbasis metode *deep learning*. Dataset terdiri dari empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*. Seluruh citra kemudian dikelompokkan ulang



berdasarkan orientasi pengambilan citra, yaitu *axial*, *sagittal*, dan *coronal*, untuk memungkinkan analisis pengaruh orientasi terhadap performa klasifikasi dilakukan secara terpisah pada setiap kelompok orientasi.

Pada kondisi awal, jumlah citra pada masing-masing orientasi tidak seimbang. Orientasi *axial* berjumlah 1.256 citra (333 *glioma*, 361 *meningioma*, 289 *pituitary*, 273 *no tumor*), orientasi *sagittal* berjumlah 986 citra (295 *glioma*, 291 *meningioma*, 306 *pituitary*, 94 *no tumor*), dan orientasi *coronal* berjumlah 946 citra (298 *glioma*, 285 *meningioma*, 318 *pituitary*, 45 *no tumor*). Ketidakseimbangan distribusi kelas ini berpotensi menyebabkan model cenderung bias terhadap kelas mayoritas. Untuk mengatasi hal tersebut, dilakukan teknik penyeimbangan data menggunakan metode *undersampling*, yaitu dengan menyamakan jumlah citra pada setiap kelas berdasarkan jumlah kelas terkecil, yaitu 45 citra per kelas (mengacu pada kelas *no tumor* pada orientasi *coronal*). Dengan demikian, pada setiap orientasi digunakan total 180 citra (4 kelas × 45 citra).

Tabel 1 Contoh Citra MRI Jenis Tumor Otak Setiap Orientasi

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

Penggunaan *undersampling* bertujuan untuk menghasilkan distribusi data yang seimbang sehingga evaluasi performa model menjadi lebih objektif dan tidak bias terhadap kelas tertentu (Zhou et al., 2024). Namun demikian, pendekatan ini memiliki keterbatasan, yaitu berkurangnya jumlah data latih yang dapat memengaruhi kemampuan generalisasi model. Dalam konteks penelitian ini, *undersampling* dipilih dengan mempertimbangkan tujuan utama penelitian, yaitu membandingkan performa klasifikasi antar orientasi citra secara adil dan terkontrol, sehingga keseimbangan distribusi data menjadi prioritas dibandingkan jumlah data yang lebih besar. Contoh citra MRI dari masing-masing orientasi dapat dilihat pada Tabel 1.

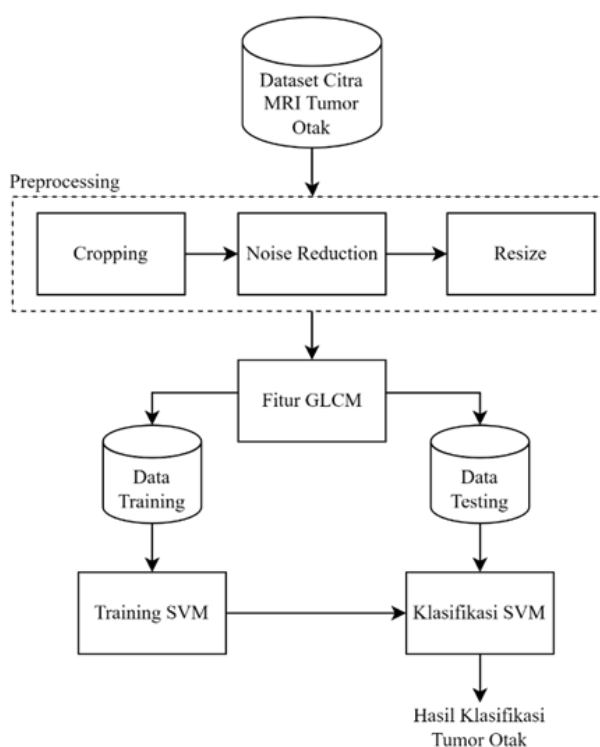
2.2 Desain Sistem

Desain sistem menggambarkan alur kerja klasifikasi tumor otak berbasis citra MRI menggunakan GLCM dan SVM, mulai dari masukan citra hingga keluaran berupa prediksi kelas. Pada tahap



awal, dataset diseimbangkan menggunakan metode *undersampling* dengan menyamakan jumlah data pada setiap kelas berdasarkan kelas terkecil. Selanjutnya, citra melalui tahap praproses yang terdiri atas *cropping*, *noise reduction*, dan *resize* untuk memperoleh citra yang lebih fokus, bersih, dan seragam.

Citra hasil praproses kemudian diekstraksi menggunakan GLCM sehingga diperoleh fitur tekstur sebagai representasi numerik. Dataset fitur selanjutnya dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan metode *stratified random sampling* untuk menjaga proporsi setiap kelas tetap seimbang pada kedua subset. Proses pembagian data dilakukan sebelum tahap pelatihan model, sehingga data latih dan data uji tidak saling memengaruhi. Data latih digunakan untuk melatih model SVM, sedangkan data uji digunakan untuk menghasilkan prediksi. Pembagian data dilakukan sebelum proses pelatihan untuk mencegah *data leakage* antara data latih dan data uji, sehingga evaluasi model lebih mencerminkan kemampuan generalisasi. Hasil prediksi tersebut kemudian dievaluasi menggunakan *confusion matrix*. Desain sistem klasifikasi yang digunakan pada penelitian ini disajikan pada Gambar 2.



Gambar 2 Desain Sistem


2.3 Preprocessing Citra

Preprocessing citra dilakukan untuk menyiapkan citra MRI agar memiliki kualitas dan format yang lebih seragam sebelum masuk ke tahap ekstraksi fitur tekstur. Tahap ini penting karena citra MRI mentah umumnya masih memuat area latar belakang yang tidak relevan, noise halus, serta variasi ukuran citra (Shree et al., 2025). Pada penelitian ini, *preprocessing* terdiri atas tiga langkah berurutan, yaitu *cropping*, *noise reduction*, dan *resize*, sehingga area otak lebih terfokus, gangguan citra berkurang, dan dimensi citra konsisten.

Langkah pertama adalah *cropping*, yaitu memfokuskan area otak dan menghilangkan bagian latar belakang yang tidak diperlukan (Tarigan et al., 2025). Proses *cropping* dilakukan dengan memisahkan objek otak dari background hitam menggunakan *thresholding*, kemudian menentukan *bounding box* yang melingkupi area otak, lalu memotong citra mengikuti batas




tersebut. Tahap ini membantu memastikan fitur tekstur yang diekstraksi benar-benar merepresentasikan jaringan otak, bukan area kosong atau noise di luar objek. Contoh citra sebelum dan sesudah *cropping* ditunjukkan pada Gambar 3.




Gambar 3 Hasil Cropping

Langkah kedua adalah *noise reduction* untuk mengurangi gangguan berupa bintik acak atau fluktuasi intensitas yang dapat memengaruhi kestabilan perhitungan fitur tekstur (Vadmal et al., 2020). Pada penelitian ini digunakan *Gaussian filter* berukuran kernel 3×3, karena ukuran kernel yang kecil terbukti efektif dalam mereduksi *noise* tanpa menyebabkan blur berlebihan pada citra. Penggunaan kernel yang lebih besar cenderung menghilangkan detail penting pada struktur jaringan, sehingga kurang sesuai untuk citra medis yang membutuhkan preservasi informasi diagnostik (Ramadan, 2019). Contoh citra sebelum dan sesudah *noise reduction* ditunjukkan pada Gambar 4.



Gambar 4 Hasil Noise Reduction

Langkah ketiga adalah *resize* untuk menyeragamkan ukuran citra sebelum ekstraksi fitur, sehingga semua citra memiliki dimensi yang sama dan dapat dibandingkan secara konsisten (Ottoni & Kasperczuk, 2025). Ukuran citra pada penelitian ini ditetapkan menjadi 256×256 piksel. Untuk mencegah distorsi bentuk akibat perbedaan rasio panjang lebar setelah *cropping*, proses *resize* dilakukan dengan pendekatan *aspect ratio preserving*, kemudian ditambahkan padding hitam apabila ukuran belum mencapai 256×256 (karena latar belakang MRI umumnya hitam). Contoh hasil *resize* ditunjukkan pada Gambar 5.



Gambar 5 Hasil Resize



2.4 Ekstraksi Fitur GLCM

Ekstraksi fitur tekstur pada penelitian ini dilakukan menggunakan metode GLCM untuk merepresentasikan karakteristik tekstur citra MRI tumor otak dalam bentuk fitur numerik. GLCM digunakan karena mampu menggambarkan hubungan statistik antar tingkat keabuan piksel pada jarak dan orientasi tertentu, sehingga sesuai untuk menganalisis heterogenitas jaringan otak pada citra MRI (Alibabaei et al., 2023).

Pada tahap ini, citra hasil praproses terlebih dahulu dikuantisasi ke dalam 16 level keabuan untuk meningkatkan efisiensi komputasi serta menjaga kestabilan distribusi probabilitas pada matriks GLCM (Barburiceanu et al., 2021). Selanjutnya, matriks GLCM dihitung menggunakan jarak piksel $d=1$ pada empat orientasi sudut, yaitu 0° , 45° , 90° , dan 135° . Pemilihan jarak $d=1$ didasarkan pada kemampuannya dalam menangkap hubungan spasial lokal antar piksel yang merepresentasikan detail tekstur halus pada citra MRI, yang penting dalam membedakan pola jaringan normal dan abnormal (Aggarwal, 2022). Sementara itu, penggunaan empat orientasi sudut bertujuan untuk memperoleh representasi tekstur yang lebih komprehensif dan tidak bergantung pada satu arah tertentu, mengingat pola jaringan tumor bersifat tidak beraturan dan dapat muncul dalam berbagai arah (Varghese et al., 2023).

Fitur tekstur yang diekstraksi dari matriks GLCM meliputi *contrast*, *correlation*, *energy*, dan *homogeneity*. Pemilihan keempat fitur ini didasarkan pada konsep fitur tekstur yang diperkenalkan oleh Haralick et al. (1973), di mana fitur-fitur tersebut mampu merepresentasikan karakteristik utama tekstur citra, yaitu variasi intensitas (*contrast*), hubungan linear antar piksel (*correlation*), tingkat keseragaman (*energy*), serta kedekatan distribusi nilai keabuan terhadap diagonal matriks (*homogeneity*). Selain itu, keempat fitur ini dipilih karena paling umum digunakan dalam berbagai penelitian klasifikasi citra medis dan telah terbukti efektif dalam membedakan karakteristik jaringan tumor otak, sehingga dianggap cukup representatif tanpa harus menggunakan seluruh fitur GLCM yang tersedia (Dixon et al., 2024). Setiap fitur dihitung pada keempat orientasi sudut yang telah ditentukan, sehingga setiap citra direpresentasikan oleh 16 fitur tekstur (4 fitur \times 4 sudut) yang kemudian digunakan sebagai masukan dalam proses klasifikasi menggunakan algoritma SVM.

Sebagai ilustrasi, Tabel 2 menyajikan contoh hasil ekstraksi fitur GLCM pada salah satu orientasi sudut, yaitu 0° , pada citra MRI dengan orientasi *axial*. Meskipun tabel hanya menampilkan satu orientasi sudut, pada proses klasifikasi digunakan seluruh kombinasi fitur dari keempat sudut yang telah ditentukan.

Tabel 2 Contoh Hasil Ekstraksi Fitur GLCM

Kelas	Fitur GLCM			
	<i>Contrast</i>	<i>Correlation</i>	<i>Energy</i>	<i>Homogeneity</i>
<i>Glioma</i>	0.42	0.97	0.14	0.87
<i>Meningioma</i>	0.37	0.97	0.14	0.88
<i>Pituitary</i>	0.52	0.96	0.15	0.86
<i>No tumor</i>	0.51	0.95	0.21	0.89

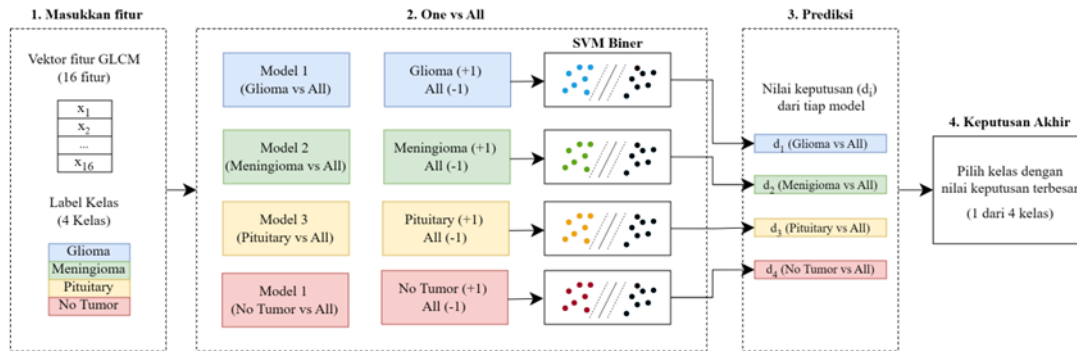
2.5 Klasifikasi SVM

Klasifikasi jenis tumor otak pada penelitian ini dilakukan menggunakan SVM dengan masukan berupa fitur tekstur hasil ekstraksi GLCM. SVM dipilih karena kemampuannya dalam membentuk *hyperplane* optimal yang memaksimalkan margin antar kelas, sehingga efektif dalam menangani data berdimensi tinggi dengan jumlah sampel terbatas, seperti pada klasifikasi citra medis berbasis fitur tekstur (Montesinos López et al., 2022).

Penelitian ini melakukan klasifikasi terhadap empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*, sehingga diperlukan strategi klasifikasi multi-kelas. Pendekatan yang digunakan adalah *One vs All (OvA)*, yaitu membangun beberapa model SVM biner secara terpisah. Setiap



model mengklasifikasikan satu kelas sebagai kelas positif (+1) dan kelas lainnya sebagai negatif (-1), sehingga dihasilkan empat *classifier*, yaitu *glioma vs all*, *meningioma vs all*, *pituitary vs all*, dan *no tumor vs all*. Pada tahap prediksi, masing-masing *classifier* menghasilkan nilai keputusan, kemudian kelas akhir ditentukan berdasarkan nilai keputusan tertinggi. Ilustrasi alur klasifikasi SVM dengan pendekatan *One vs All* ditunjukkan pada Gambar 6.



Gambar 6 Alur Klasifikasi SVM Dengan Pendekatan One vs All

Pengaruh fungsi kernel terhadap performa klasifikasi dianalisis melalui empat jenis kernel, yaitu *Linear*, *Polynomial*, *Radial Basis Function (RBF)*, dan *Sigmoid*. Perbedaan karakteristik masing-masing kernel memungkinkan model menangkap pola distribusi fitur yang beragam pada citra MRI, sehingga pemilihan kernel menjadi faktor penting dalam menentukan batas pemisah antar kelas pada ruang fitur. Optimasi *hyperparameter* dilakukan menggunakan metode *Grid Search* dengan rentang nilai parameter seperti yang ditunjukkan pada Tabel 3. Parameter yang dioptimasi meliputi *C*, *gamma*, *degree*, dan *coef0*. Parameter *C* mengontrol keseimbangan antara margin dan kesalahan klasifikasi, *gamma* menentukan jangkauan pengaruh suatu sampel, *degree* digunakan pada kernel *polynomial*, sedangkan *coef0* berfungsi sebagai konstanta tambahan pada kernel *polynomial* dan *sigmoid*. Rentang nilai parameter mengacu pada penelitian Faradisya dan Pakereng (2025).

Tabel 3 Rentang Hyperparameter Grid Search pada SVM

Hyperparameter	Nilai
<i>C</i>	0.1, 1, 10
<i>Gamma</i>	0.01, 0.1, 1
<i>Degree</i>	2, 3, 4
<i>Coef0</i>	0, 0.1, 1

Keandalan model ditingkatkan melalui penerapan *k-fold cross validation* ($k=5$) pada data latih dalam proses *Grid Search*. Pendekatan ini memungkinkan model dilatih dan divalidasi secara berulang pada subset data yang berbeda, sehingga menghasilkan estimasi performa yang lebih stabil serta mengurangi risiko *overfitting* terhadap pembagian data tertentu. Selain itu, dataset dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan *stratified* sampling guna menjaga proporsi setiap kelas. Data latih digunakan dalam proses pelatihan dan validasi, sedangkan data uji dimanfaatkan sebagai evaluasi akhir terhadap model. Kombinasi antara metode *hold-out* dan *cross validation* ini dipilih untuk memperoleh keseimbangan antara efisiensi komputasi dan kemampuan generalisasi model, terutama pada dataset dengan ukuran terbatas setelah proses *balancing*.

Meskipun berbagai metode *machine learning* telah digunakan dalam klasifikasi citra medis, penelitian ini berfokus pada analisis pengaruh orientasi citra terhadap performa klasifikasi berbasis fitur tekstur. Oleh karena itu, SVM digunakan sebagai model utama agar hasil yang diperoleh lebih merefleksikan pengaruh orientasi citra dibandingkan kompleksitas model. Model



terbaik yang diperoleh dari proses optimasi kemudian dievaluasi menggunakan *confusion matrix* serta metrik performa berupa akurasi, presisi, recall, dan F1-score.

3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan menyajikan hasil pengujian dan analisis performa klasifikasi tumor otak berbasis fitur tekstur GLCM dan algoritma SVM. Pengujian dilakukan pada dataset seimbang untuk masing-masing orientasi citra MRI, yaitu *axial*, *sagittal*, dan *coronal*, dengan menerapkan empat kernel SVM (*Linear*, *Polynomial*, RBF, dan *Sigmoid*) yang telah dioptimasi menggunakan Grid Search. Semua pengujian menggunakan data latih sebesar 80% dan data uji 20%. Evaluasi kinerja model dilakukan menggunakan *confusion matrix* serta metrik akurasi, presisi, *recall*, dan *F1-score*.

Hasil pengujian performa klasifikasi tumor otak pada orientasi citra MRI *axial* disajikan pada Tabel 4. Pada orientasi ini, kernel *Linear* menghasilkan nilai akurasi tertinggi sebesar 78%, dibandingkan dengan kernel lainnya. Kernel RBF menghasilkan nilai akurasi sebesar 75%, sedangkan kernel *Polynomial* menunjukkan akurasi yang lebih rendah sebesar 69%. Kernel *Sigmoid* menghasilkan performa terendah pada orientasi *axial* dengan nilai akurasi sebesar 58%.

Tabel 4 Hasil Evaluasi pada Orientasi Axial

Sudut Pandang	Kernel	Evaluasi			
		Accuracy	Precision	Recall	F1-score
Axial	Linear	78%	79%	78%	77%
Axial	Polynomial	69%	73%	69%	69%
Axial	RBF	75%	77%	75%	75%
Axial	Sigmoid	58%	59%	58%	58%

Hasil pengujian performa klasifikasi pada orientasi citra MRI *sagittal* ditunjukkan pada Tabel 5. Pada orientasi ini, kernel *Polynomial* menghasilkan performa terbaik dengan nilai akurasi sebesar 83%. Kernel *Linear* dan RBF masing-masing menghasilkan nilai akurasi sebesar 75%, sedangkan kernel *Sigmoid* menunjukkan performa yang lebih rendah dengan nilai akurasi sebesar 69%.

Tabel 5 Hasil Evaluasi pada Orientasi Sagittal

Sudut Pandang	Kernel	Evaluasi			
		Accuracy	Precision	Recall	F1-score
Sagittal	Linear	75%	77%	75%	74%
Sagittal	Polynomial	83%	83%	83%	83%
Sagittal	RBF	75%	76%	75%	75%
Sagittal	Linear	75%	77%	75%	74%

Hasil pengujian performa klasifikasi pada orientasi citra MRI *coronal* disajikan pada Tabel 6. Pada orientasi ini, kernel RBF menghasilkan performa tertinggi dengan nilai akurasi sebesar 86%, yang merupakan nilai akurasi tertinggi di antara seluruh skenario pengujian. Kernel *Polynomial* menghasilkan nilai akurasi sebesar 83%, sedangkan kernel *Linear* dan *Sigmoid* masing-masing memperoleh nilai akurasi sebesar 78% dan 69%.

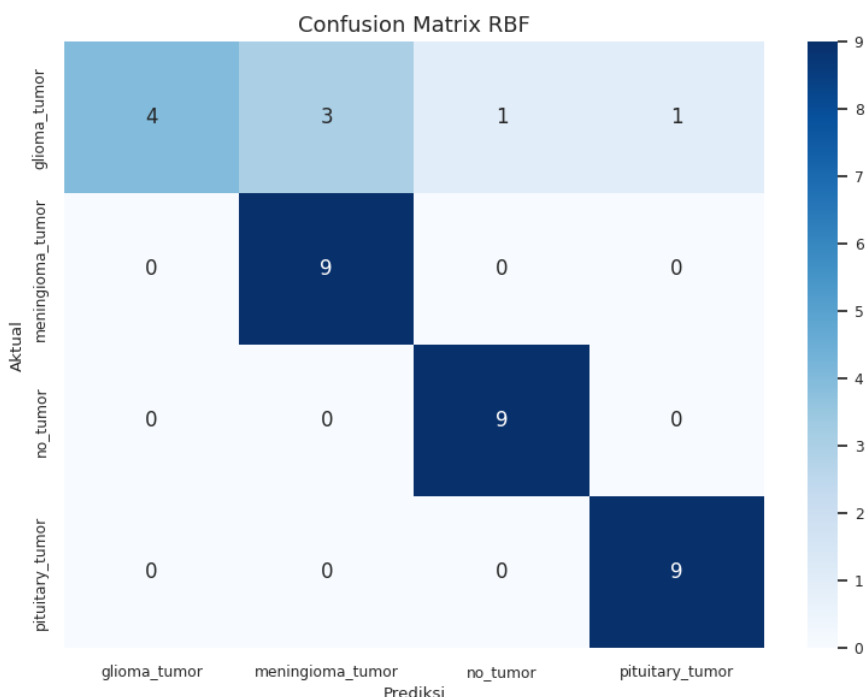
Tabel 6 Hasil Evaluasi pada Orientasi Coronal

Sudut Pandang	Kernel	Evaluasi			
		Accuracy	Precision	Recall	F1-score
Coronal	Linear	78%	78%	78%	78%
Coronal	Polynomial	83%	83%	83%	83%
Coronal	RBF	86%	89%	86%	84%
Coronal	Sigmoid	69%	69%	69%	66%



Berdasarkan hasil pengujian pada ketiga orientasi citra MRI, kombinasi kernel terbaik pada masing-masing orientasi berbeda. Pada orientasi *axial*, performa terbaik diperoleh oleh kernel *Linear* dengan nilai akurasi sebesar 78%. Pada orientasi *sagittal*, kernel *Polynomial* menghasilkan akurasi tertinggi sebesar 83%. Sementara itu, pada orientasi *coronal*, kernel RBF memberikan performa terbaik dengan nilai akurasi sebesar 86%, yang merupakan nilai akurasi tertinggi di antara seluruh skenario pengujian.

Untuk memberikan gambaran lebih rinci mengenai hasil klasifikasi pada skenario terbaik, ditampilkan *confusion matrix* dari model dengan performa tertinggi pada penelitian ini, yaitu SVM kernel RBF pada orientasi citra MRI *coronal*, sebagaimana ditunjukkan pada Gambar 7. *Confusion matrix* tersebut memperlihatkan distribusi prediksi kelas yang dihasilkan oleh model terhadap kelas aktual pada data uji.



Gambar 7 Confusion Matriks Skenario Terbaik

Berdasarkan *confusion matrix* tersebut, dilakukan perhitungan metrik evaluasi pada masing-masing kelas tumor. Hasil evaluasi *precision*, *recall*, dan *F1-score* untuk setiap kelas pada model terbaik disajikan pada Tabel 7. Kelas *meningioma* tumor memperoleh nilai *precision* sebesar 75%, *recall* 100%, dan *F1-score* 86%. Kelas *no tumor* dan *pituitary* tumor masing-masing menunjukkan nilai *recall* sebesar 100% dengan *F1-score* sebesar 95%. Sementara itu, kelas *glioma* tumor memiliki nilai *recall* yang lebih rendah, yaitu 44%, dengan *F1-score* sebesar 62%.

Tabel 7 Nilai Evaluasi pada Skenario Terbaik

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

Hasil pengujian menunjukkan bahwa orientasi citra MRI memengaruhi performa klasifikasi tumor otak berbasis fitur tekstur GLCM dan algoritma SVM. Meskipun seluruh eksperimen dilakukan pada dataset seimbang dengan skema pelatihan dan evaluasi yang sama, nilai akurasi yang



dihasilkan pada setiap orientasi citra menunjukkan perbedaan yang konsisten. Performa klasifikasi pada orientasi *axial* menghasilkan nilai akurasi yang lebih rendah dibandingkan dua orientasi lainnya. Pada orientasi ini, struktur otak ditampilkan dari arah atas ke bawah, sehingga beberapa bagian jaringan tumor dan jaringan sehat cenderung memiliki pola tekstur yang saling tumpang tindih pada bidang irisan tertentu. Tumpang tindih tersebut berpotensi menyebabkan fitur tekstur yang diekstraksi oleh GLCM memiliki tingkat kemiripan yang lebih tinggi antar kelas. Akibatnya, pemisahan kelas pada ruang fitur menjadi kurang tegas dan berdampak pada penurunan akurasi klasifikasi.

Orientasi *sagittal* menunjukkan peningkatan performa dibandingkan orientasi *axial*. Tampilan citra dari sisi samping memungkinkan representasi jaringan otak dan lokasi tumor terlihat lebih tersegmentasi secara spasial, terutama pada area peralihan antara jaringan normal dan jaringan abnormal. Pada orientasi ini, perbedaan tekstur antar kelas cenderung lebih terjaga sehingga fitur GLCM mampu menangkap variasi pola dengan lebih konsisten. Kondisi tersebut tercermin pada peningkatan nilai akurasi yang diperoleh pada orientasi *sagittal* dibandingkan orientasi *axial*.

Orientasi *coronal* memberikan performa tertinggi dibandingkan orientasi lainnya. Pada orientasi ini, struktur otak ditampilkan dari arah depan ke belakang sehingga distribusi jaringan dan batas tumor dapat terlihat lebih jelas dan relatif simetris pada banyak citra. Representasi tekstur yang dihasilkan pada orientasi *coronal* cenderung lebih stabil karena variasi pola antar kelas dapat ditangkap secara lebih menyeluruh pada bidang irisan ini. Stabilitas tersebut mendukung proses ekstraksi fitur GLCM dan membantu model klasifikasi dalam membedakan kelas tumor dengan tingkat akurasi yang lebih tinggi.

Perbedaan performa antar orientasi juga tercermin pada kombinasi kernel yang menghasilkan akurasi terbaik pada masing-masing orientasi. Variasi ini menunjukkan bahwa distribusi fitur tekstur GLCM yang dihasilkan dari setiap orientasi memiliki karakteristik yang tidak sepenuhnya sama. Perbedaan karakteristik tersebut memengaruhi bagaimana fungsi pemisah pada algoritma SVM bekerja dalam memisahkan kelas pada ruang fitur. Meskipun kernel terbaik berbeda pada tiap orientasi, pola hasil yang muncul tetap menunjukkan bahwa orientasi citra berperan dalam menentukan kualitas representasi fitur yang digunakan pada proses klasifikasi.

Analisis pada skenario terbaik, yaitu orientasi *coronal* dengan kernel RBF, memberikan gambaran yang lebih rinci mengenai kemampuan model dalam mengenali masing-masing kelas tumor. Berdasarkan *confusion matrix* pada gambar 6, sebagian besar citra pada kelas *meningioma*, *no tumor*, dan *pituitary* tumor dapat diklasifikasikan dengan tingkat ketepatan yang tinggi. Sebaliknya, kelas *glioma* masih menunjukkan tingkat kesalahan klasifikasi yang lebih besar dibandingkan kelas lainnya. Pola ini mengindikasikan bahwa pada sebagian citra, karakteristik tekstur *glioma* memiliki kemiripan dengan kelas lain sehingga memicu kesalahan prediksi pada data uji.

Hasil pembahasan ini menegaskan bahwa orientasi citra MRI tidak hanya berpengaruh terhadap nilai akurasi yang diperoleh, tetapi juga terhadap kestabilan fitur tekstur yang diekstraksi serta pola kesalahan klasifikasi antar kelas. Variasi orientasi menghasilkan representasi tekstur yang berbeda, yang pada akhirnya memengaruhi kinerja model dalam membedakan jenis tumor. Dalam konteks pengembangan sistem klasifikasi tumor otak berbasis fitur tekstur, orientasi citra MRI menjadi aspek teknis yang layak dipertimbangkan sejak tahap perancangan sistem.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa orientasi citra MRI berpengaruh terhadap performa klasifikasi tumor otak berbasis fitur tekstur GLCM dan SVM. Perbedaan orientasi menghasilkan perbedaan kualitas representasi tekstur yang berdampak pada nilai akurasi, di mana orientasi *coronal* memberikan performa terbaik dengan akurasi tertinggi 86% pada kernel RBF, diikuti orientasi *sagittal* menghasilkan akurasi tertinggi 83% pada kernel *polynomial*, sedangkan orientasi *axial* menghasilkan akurasi tertinggi 78% pada kernel *linear*. Temuan ini menegaskan bahwa



pemilihan orientasi citra merupakan aspek penting dalam perancangan sistem klasifikasi tumor otak berbasis tekstur karena dapat meningkatkan ketepatan pemisahan kelas pada ruang fitur.

DAFTAR PUSTAKA

- Aggarwal, A. K. (2022). Learning Texture Features from GLCM for Classification of Brain Tumor MRI Images using Random Forest Classifier. *WSEAS Transactions on Signal Processing*, 18, 60–63. <https://doi.org/10.37394/232014.2022.18.8>
- 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
- 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>
- 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>
- 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>
- 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>
- Kadam, A., Bhuvaji, S., & Deshpande, S. (2021). *Brain Tumor Classification using Deep Learning Algorithms*. 9(Xii), 417–426.
- 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>
- 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*.
- 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/>
- Otoni, M., & Kasperczuk, A. (2025). *Machine Learning in MRI Brain Imaging: A Review of Methods, Challenges, and Future Directions*.
- Pichaivel, M., Anbumani, G., Theivendren, P., & Gopal, M. (2022). An Overview of Brain Tumor. *Brain Tumors*. <https://doi.org/10.5772/intechopen.100806>
- Ramadan, Z. M. (2019). *Effect of kernel size on Wiener and Gaussian image filtering*. 17(3), 1455–1460. <https://doi.org/10.12928/TELKOMNIKA.v17i3.11192>



- Shree, A., Desai, K., Savle, R., Savaliya, J., & Upadhyay, J. B. (2025). *Image Processing in MRI : A Methodology Review*. 365–372.
- 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>
- 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>
- Tarigan, H. B. R., Mulyantoro, D. K., & Rochmayanti, D. (2025). *DETEKSI TUMOR OTAK PADA CITRA MAGNETIC RESONANCE IMAGING (MRI) BRAIN DENGAN METODE SUPPORT VECTOR MACHINE (SVM)*. 9, 4118–4135.
- Vadmal, V., Junno, G., Badve, C., Huang, W., Waite, K. A., & Barnholtz-sloan, J. S. (2020). *Neuro-Oncology Advances MRI image analysis methods and applications: an algorithmic perspective using brain tumors as an exemplar*. 2(April), 1–13. <https://doi.org/10.1093/noajnl/vdaa049>
- Varghese, B. A., Fields, B. K. K., Hwang, D. H., Duddalwar, V. A., Jr, G. R. M., Cen, S. Y., & Chan, K. (2023). *Spatial assessments in texture analysis: what the radiologist needs to know*. August, 1–7. <https://doi.org/10.3389/fradi.2023.1240544>
- 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>
- Zhou, W., Liu, C., Yuan, P., & Jiang, L. (2024). *applied sciences An Undersampling Method Approaching the Ideal Classification Boundary for Imbalance Problems*.

