



E-ISSN 3032-601X & P-ISSN 3032-7105

Vol. 3, No. 1, 2026

MISTER

**Journal of Multidisciplinary Inquiry in Science,
Technology and Educational Research**

**Jurnal Penelitian Multidisiplin dalam Ilmu
Pengetahuan, Teknologi dan Pendidikan**

**UNIVERSITAS SERAMBI MEKKAH
KOTA BANDA ACEH**

mister@serambimekkah.ac.id

Journal of Multidisciplinary Inquiry in Science Technology
and Educational Research

Journal of MISTER

Vol. 3, No. 1, 2026

Pages: 750–760

Klasifikasi Tumor Otak dengan Menggunakan Algoritma *Decision Tree*

Rama Satria Wicaksono, Hasbi Firmansyah, Wahyu Asriyani

Universitas Pancasakti Tegal

Article in Journal of MISTER

Available at : <https://jurnal.serambimekkah.ac.id/index.php/mister/index>

DOI : <https://doi.org/10.32672/mister.v3i1.3996>

How to Cite this Article

APA : Satria Wicaksono, R., Firmansyah, H. ., & Wahyu Asriyani. (2025). Klasifikasi Tumor Otak dengan Menggunakan Algoritma Decision Tree. Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research, 3(1), 750 – 760. <https://doi.org/10.32672/mister.v3i1.3996>

Others Visit : <https://jurnal.serambimekkah.ac.id/index.php/mister/index>

MISTER: *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research* is a scholarly journal dedicated to the exploration and dissemination of innovative ideas, trends and research on the various topics include, but not limited to functional areas of Science, Technology, Education, Humanities, Economy, Art, Health and Medicine, Environment and Sustainability or Law and Ethics.

MISTER: *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research* is an open-access journal, and users are permitted to read, download, copy, search, or link to the full text of articles or use them for other lawful purposes. Articles on Journal of MISTER have been previewed and authenticated by the Authors before sending for publication. The Journal, Chief Editor, and the editorial board are not entitled or liable to either justify or responsible for inaccurate and misleading data if any. It is the sole responsibility of the Author concerned.



ISSN 3032-7105

ISSN 3032-601X



Klasifikasi Tumor Otak dengan Menggunakan Algoritma *Decision Tree*

Rama Satria Wicaksono¹, Hasbi Firmansyah², Wahyu Asriyani³

Program Studi Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Pancasakti Tegal,
Kota Tegal, Indonesia^{1,2}

Program Studi Pendidikan Bahasa dan Sastra Indonesia, Fakultas Keguruan dan Ilmu Pendidikan,
Universitas Pancasakti Tegal, Kota Tegal, Indonesia³

*Email: satriawicaksonorama@mail.com, hasbifirmansyah@upstegal.ac.id, asriyani1409@gmail.com

Diterima: 06-12-2025

| Disetujui: 16-12-2025

| Diterbitkan: 18-12-2025

ABSTRACT

This study aims to perform brain tumor classification using the Decision Tree algorithm based on numerical features extracted from MRI images. The dataset consists of first-order statistical features and second-order texture features obtained through the Gray Level Co-occurrence Matrix (GLCM) method. The research process includes dataset collection, preprocessing, data splitting, model construction, and performance evaluation, all conducted using RapidMiner Studio. The data were divided into 90% for training and 10% for testing to optimize pattern learning while ensuring a representative evaluation. The Decision Tree model was built using default parameters with pruning applied to prevent overfitting. The evaluation results show that the model achieved an accuracy of 97.46%, with precision values of 97.45% for class 0 and 97.48% for class 1, as well as recall values of 97.97% for class 0 and 96.83% for class 1. The confusion matrix indicates that the model successfully classified most of the data correctly, demonstrating strong predictive performance. The decision tree structure identifies Entropy, Homogeneity, Energy, Skewness, and Mean as the most influential attributes in distinguishing tumor and non-tumor images. Overall, the study demonstrates that the Decision Tree algorithm is an effective and interpretable approach that can be used as a supporting tool for early identification of brain tumors.

Keywords: Brain Tumor; Classification; Decision Tree; Machine Learning; RapidMiner.

ABSTRAK

Penelitian ini bertujuan untuk melakukan klasifikasi tumor otak menggunakan algoritma Decision Tree berdasarkan fitur numerik hasil ekstraksi citra MRI. Dataset yang digunakan terdiri atas fitur statistik orde pertama dan fitur tekstur orde kedua yang diperoleh melalui metode Gray Level Co-occurrence Matrix (GLCM). Proses penelitian meliputi pengumpulan dataset, preprocessing, pembagian data, pembangunan model, dan evaluasi performa yang seluruhnya dilakukan menggunakan RapidMiner Studio. Data dibagi menjadi 90% sebagai data pelatihan dan 10% sebagai data pengujian untuk mengoptimalkan pembelajaran pola dan menjaga representativitas evaluasi. Model Decision Tree dibangun menggunakan parameter standar dengan penerapan pruning untuk mencegah overfitting. Hasil evaluasi menunjukkan bahwa model menghasilkan akurasi sebesar 97,46%, dengan nilai precision kelas 0 sebesar 97.45% dan kelas 1 sebesar 97.48% dan recall kelas 0 sebesar 97.97% dan kelas 1 sebesar 96.83%. Confusion matrix menunjukkan bahwa model mampu mengklasifikasikan sebagian besar data secara benar, sehingga memiliki performa prediksi yang baik. Struktur pohon keputusan mengidentifikasi Entropy, Homogeneity, Energy, Skewness, dan Mean sebagai atribut paling berpengaruh dalam membedakan citra tumor dan non-tumor. Secara keseluruhan, penelitian ini membuktikan

bahwa algoritma Decision Tree merupakan pendekatan yang efektif, mudah diinterpretasikan, dan dapat digunakan sebagai alat bantu dalam identifikasi awal tumor otak.

Katakunci: Decision Tree; Klasifikasi; Machine Learning; RapidMiner; Tumor Otak.

PENDAHULUAN

Tumor otak merupakan salah satu penyakit yang berbahaya karena pertumbuhan sel abnormal di dalam jaringan otak dapat mengganggu fungsi motorik, sensorik, kognitif, bahkan kesadaran seseorang. Deteksi dini tumor otak menjadi sangat penting karena semakin cepat tumor diidentifikasi, semakin besar peluang pasien memperoleh penanganan yang tepat (Dheepak et al., 2024). Teknologi pencitraan medis seperti MRI telah banyak digunakan untuk membantu proses diagnosis, namun interpretasi citra secara manual masih memiliki keterbatasan sehingga diperlukan sistem komputasi yang dapat membantu proses identifikasi secara lebih akurat (Fikriah et al., 2024).

Dataset Brain Tumor yang digunakan dalam penelitian ini merupakan dataset yang berisi fitur hasil ekstraksi dari citra MRI. Dataset ini mencakup dua jenis fitur, yaitu fitur statistik orde pertama (Mean, Variance, Standard Deviation, Skewness, dan Kurtosis) dan fitur tekstur orde kedua (Contrast, Energy, Angular Second Moment/ASM, Entropy, Homogeneity, Dissimilarity, Correlation, dan Coarseness). Fitur-fitur tersebut menggambarkan karakteristik intensitas dan pola tekstur citra yang dapat menjadi indikator perbedaan antara citra tumor dan non-tumor. Selain itu, dataset menyediakan label Class yang menunjukkan apakah citra mengandung tumor (1) atau tidak (0), sehingga dapat digunakan untuk proses klasifikasi otomatis menggunakan algoritma machine learning (Putri et al., 2024).

Data mining merupakan teknik yang digunakan untuk menggali informasi dan pola tersembunyi dari kumpulan data dalam jumlah besar. Dalam konteks pengolahan citra medis, data mining berperan penting untuk mengubah data numerik hasil ekstraksi fitur menjadi keputusan yang dapat digunakan untuk diagnosis. RapidMiner merupakan salah satu aplikasi yang banyak digunakan dalam penelitian data mining karena menyediakan antarmuka visual yang mempermudah proses preprocessing, pembagian data, pelatihan model, dan evaluasi tanpa harus menulis kode program secara manual. Beberapa penelitian menunjukkan bahwa RapidMiner efektif digunakan untuk membangun model klasifikasi pada berbagai kasus, termasuk data kesehatan (Prasetyo, 2023).

Algoritma Decision Tree merupakan metode klasifikasi yang populer karena mudah dipahami dan mampu menghasilkan aturan keputusan yang jelas. Struktur pohon yang membagi data berdasarkan nilai atribut memungkinkan interpretasi yang transparan, sehingga metode ini banyak digunakan dalam penelitian medis dan pendidikan. Decision Tree bekerja dengan memilih fitur terbaik sebagai pemisah (split) pada setiap node untuk membedakan kelas target secara optimal (Husnah, 2021).

Penelitian sebelumnya telah dilakukan terkait klasifikasi tumor otak menggunakan fitur tekstur dan algoritma machine learning. (Fikriah et al., 2024) menunjukkan bahwa fitur GLCM mampu meningkatkan akurasi identifikasi tumor otak. (Winnarto et al., 2024) menemukan bahwa pemilihan fitur yang tepat berpengaruh signifikan terhadap performa model klasifikasi tumor. Selain itu, penelitian oleh Ayudhitama & Pujiyanto (2020) membuktikan bahwa RapidMiner sangat cocok digunakan untuk eksperimen klasifikasi karena kemampuannya dalam memproses data secara visual dan cepat. Penelitian-penelitian ini membuktikan bahwa pendekatan machine learning dengan fitur statistik dan tekstur masih relevan digunakan hingga saat ini (Ayudhitama et al., n.d.).


Perbedaan penelitian ini dengan penelitian sebelumnya terletak pada penggunaan dataset Brain Tumor berbasis fitur statistik dan tekstur yang telah diekstraksi, serta implementasi algoritma Decision Tree secara penuh menggunakan RapidMiner. Banyak penelitian modern berfokus pada deep learning dengan citra mentah, namun penelitian ini memilih metode yang lebih ringan secara komputasi dan lebih mudah diinterpretasikan. Pendekatan ini memberikan pemahaman jelas mengenai fitur mana yang paling

berkontribusi dalam klasifikasi tumor otak dan bagaimana struktur keputusan dibentuk oleh algoritma Decision Tree (Hidayaturrahman, 2024).

Rumusan masalah dalam penelitian ini adalah bagaimana algoritma Decision Tree yang diimplementasikan menggunakan RapidMiner dapat mengklasifikasikan citra tumor otak dengan memanfaatkan fitur statistik dan tekstur pada dataset Brain Tumor, serta fitur mana yang memiliki pengaruh terbesar dalam proses klasifikasi. Tujuan dari penelitian ini yaitu membangun model klasifikasi tumor otak menggunakan Decision Tree, mengevaluasi performa model tersebut, dan menganalisis kontribusi fitur-fitur yang digunakan.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk menganalisis kemampuan algoritma Decision Tree dalam melakukan klasifikasi tumor otak. Proses penelitian dilakukan melalui beberapa tahapan, mulai dari pengumpulan dataset, preprocessing, pembagian data, pembangunan model, hingga evaluasi performa (Amaliyah & Fatah, 2024). Seluruh proses pengolahan data dilakukan menggunakan perangkat lunak RapidMiner Studio karena aplikasi ini memiliki antarmuka yang memudahkan penyusunan alur analisis tanpa memerlukan pemrograman langsung (Setyawan et al., 2025).



Gambar 1.Tahap Penelitian

Penelitian ini dilakukan melalui beberapa tahapan, yang diilustrasikan pada diagram alur berikut:

1. Pengumpulan Dataset

Dataset ini berisi kumpulan data numerik yang merupakan hasil ekstraksi fitur dari citra MRI otak. Fitur-fitur tersebut terdiri atas lima fitur statistik orde pertama, yaitu Mean, Variance, Standard Deviation, Skewness, dan Kurtosis, serta delapan fitur tekstur orde kedua yang diperoleh menggunakan metode Gray Level Co-occurrence Matrix (GLCM), yaitu Contrast, Energy, Entropy, ASM, Homogeneity, Dissimilarity, Correlation, dan Coarseness. Setiap baris data merepresentasikan satu citra MRI yang telah dikonversi menjadi nilai-nilai fitur, sehingga dataset bersifat terstruktur dan mudah diproses dalam sistem klasifikasi.

2. Preprocessing

Dataset Brain Tumor yang diperoleh diperiksa terlebih dahulu untuk mendeteksi adanya ketidakkonsistenan data, nilai kosong (*missing values*), duplikasi, ataupun anomali yang berpotensi memengaruhi kinerja algoritma klasifikasi. Pemeriksaan awal dilakukan menggunakan RapidMiner, yang memungkinkan peneliti mengevaluasi distribusi nilai dan tipe data setiap atribut. Setelah dilakukan pemeriksaan, tahap preprocessing dilanjutkan dengan memastikan bahwa seluruh fitur pada dataset berformat numerik, sedangkan kolom Class ditetapkan sebagai label menggunakan operator Set Role (Agus et al., 2023).

3. Pembagian Data

Dataset dibagi menjadi dua bagian, yaitu data pelatihan dan data pengujian. Proses pembagian data dilakukan menggunakan operator *split data* dengan proporsi 90% data untuk pelatihan dan 10% untuk pengujian. Pembagian ini dipilih agar model memperoleh data pelatihan yang cukup tanpa mengurangi representasi data pada tahap evaluasi. Selain *split data*, penelitian ini juga menerapkan *accuracy* dan *classification error* untuk memastikan hasil evaluasi lebih stabil dan tidak bias terhadap satu pembagian data tertentu (Carolina et al., 2020).

4. Pembangunan Model

Pada tahap pembangunan model, algoritma yang digunakan adalah Decision Tree. Algoritma ini membentuk struktur pohon berdasarkan pemilihan atribut terbaik dengan menggunakan ukuran pemisahan tertentu, seperti *gain ratio* atau *information gain*, untuk menghasilkan pohon keputusan yang mampu membedakan kelas tumor dan non-tumor. Penerapan algoritma dilakukan melalui operator “Decision Tree” pada RapidMiner (Suryawanshi & Patil, 2023). Parameter yang digunakan dalam pembuatan model disesuaikan dengan konfigurasi standar aplikasi, antara lain pengaturan kedalaman maksimum pohon, ukuran minimum node, serta aturan pemangkasan (*pruning*) untuk mengurangi kemungkinan overfitting. Model yang dihasilkan kemudian divisualisasikan dalam bentuk struktur pohon untuk dianalisis lebih lanjut (Supriyatin & Rianto, 2024).

5. Evaluasi Performa

kinerja model klasifikasi diukur menggunakan beberapa metrik evaluasi yang umum digunakan dalam penelitian machine learning, khususnya untuk permasalahan klasifikasi biner. Evaluasi dilakukan melalui operator *Performance (Classification)* pada RapidMiner Studio. Metrik utama yang digunakan adalah akurasi, yaitu persentase prediksi model yang sesuai dengan kelas sebenarnya (Fata, 2024).

HASIL DAN PEMBAHASAN

Pengumpulan Dataset

Dataset ini berisi hasil ekstraksi fitur dari citra MRI otak yang telah diproses sebelumnya menjadi bentuk numerik. Data dikumpulkan dalam format CSV dan terdiri atas 13 atribut fitur serta 1 atribut kelas. Seluruh data yang diunduh kemudian dimasukkan ke dalam RapidMiner Studio menggunakan operator *Retrieve* sehingga dapat diproses lebih lanjut dalam tahapan analisis.

Tabel 1. Dataset Tumor Otak

No.	Class	Mean	Variance	Standart Deviation	Entropy	Skewness	...	Coarseness
1.	0	65353393	61958784	24891521	0.10905	4276477	...	7,45834073
2.	0	87499694	80595763	28389392	0.26653	3718115	...	7,45834073
3.	1	73410949	11438082	33820233	0.00146	5061750	...	7,45834073
4.	1	59581451	95971198	30979218	0.00147	5677977	...	7,45834073
5.	0	73152313	72954057	27010008	0.14676	4283220	...	7,45834073
6.	0	12304412	60739525	24645390	0.21408	3729886	...	7,45834073
7.	0	15929473	92274613	30376736	0.12883	2930094	...	7,45834073
8.	0	19921615	10699502	32710093	0.10765	2484002	...	7,45834073
...	...	...	...	...	...	...	...	...
3763.	0	611013793	48088402	21929068	0.11817	4110669	...	7,45834073

Preprocessing


	Class	Mean	Variance	Standard D...	Entropy	Skewness
	nominal	real	real	real	real	real
1	0	65353393	61958784	24891521	0.109	4.276
2	0	87499694	80595763	28389392	0.267	3.718
3	1	73410949	11438082	33820233	0.001	5.062
4	1	59581451	95971198	30979218	0.001	5.678
5	0	73152313	72954057	27010008	0.147	4.283
6	0	12304412	60739525	24645390	0.214	3.730
7	0	15929473	92274613	30376736	0.129	2.930
8	0	19921615	10699502	32710093	0.108	2.484
9	0	19921615	10699502	32710093	0.108	2.484
10	1	59581451	95971198	30979218	0.001	5.678
11	1	73410949	11438082	33820233	0.002	3.873

Gambar 2. Preprocessing Dataset

Setelah dataset berhasil dikumpulkan, tahap berikutnya adalah melakukan preprocessing untuk memastikan bahwa data berada dalam kondisi optimal sebelum digunakan dalam proses pemodelan. Pada tahap ini, seluruh atribut numerik diperiksa secara menyeluruh menggunakan RapidMiner untuk memastikan tidak terdapat nilai hilang (*missing values*), duplikasi data, ataupun ketidakkonsistenan format yang dapat mengganggu proses analisis. Pemeriksaan ini dilakukan untuk mengidentifikasi potensi anomali yang dapat memengaruhi kinerja algoritma pada tahap pelatihan. Hasil pengecekan menunjukkan bahwa

dataset Brain Tumor yang digunakan tidak mengandung nilai kosong sehingga tidak diperlukan proses imputasi atau pengisian nilai. Selain itu, atribut yang tersedia berada dalam format numerik yang seragam sehingga cocok digunakan sebagai input algoritma klasifikasi tanpa memerlukan proses konversi tipe data. Tahap preprocessing ini menjadi krusial karena memastikan bahwa dataset telah memenuhi standar kualitas data sebelum melangkah ke tahap normalisasi, pembagian dataset, dan pembangunan model klasifikasi yang lebih kompleks.


Pembagian Data



Gambar 3. Pembagian Data

Proses pembagian dataset menjadi data pelatihan dan data pengujian merupakan tahap yang sangat krusial dalam penelitian ini, karena menentukan sejauh mana model mampu mempelajari pola yang terdapat pada data sekaligus mengukur kemampuan generalisasinya terhadap data baru. Pembagian dilakukan menggunakan operator Split Data pada RapidMiner dengan rasio 90% data pelatihan dan 10% data pengujian. Proporsi ini dipilih karena dataset memiliki jumlah instance yang cukup besar, sehingga alokasi mayoritas data pada tahap pelatihan memungkinkan algoritma Decision Tree mempelajari karakteristik distribusi fitur secara lebih mendalam. Dengan porsi pelatihan yang besar, model dapat memahami variasi penting pada fitur statistik orde pertama dan fitur tekstur orde kedua, yang secara langsung meningkatkan kemampuan model dalam membedakan pola citra tumor dan non-tumor. Sementara itu, proporsi 10% data pengujian tetap dipandang memadai untuk memberikan gambaran performa model secara objektif, karena masih mampu merepresentasikan karakteristik kelas pada dataset secara proporsional.


Pembangunan Model



Gambar 4. Pembangunan Model

Workflow pembangunan model yang terdiri dari beberapa operator inti seperti Retrieve, Select Attributes, Split data, Set Role, Decision Tree, Apply Model, dan Performance. Workflow ini menggambarkan rangkaian proses otomatis yang saling terhubung mulai dari memanggil dataset hingga

menghasilkan nilai akurasi dan confusion matrix. Struktur workflow yang jelas memudahkan replikasi penelitian, memastikan bahwa setiap langkah pemrosesan dapat ditelusuri dan divalidasi oleh peneliti lain.



Gambar 5. Parameter

Konfigurasi parameter pada algoritma Decision Tree. Parameter seperti *criterion* (Information Gain), *maximal depth*, *confidence*, dan *pruning* diatur berdasarkan default RapidMiner dengan aktivasi pruning untuk mengurangi risiko overfitting. Visualisasi parameter ini menjelaskan bagaimana model melakukan pemilihan atribut pemisah terbaik dan bagaimana mekanisme pemangkasan (pruning) bekerja untuk menghasilkan pohon keputusan yang optimal. Pengaturan parameter yang tepat merupakan faktor penting dalam meningkatkan performa dan interpretabilitas model.

Evaluasi Model

Evaluasi performa model dilakukan menggunakan operator *Performance (Classification)*. Metrik evaluasi yang digunakan mencakup akurasi, precision, recall, F1-score. Seluruh metrik ini digunakan untuk memberikan gambaran menyeluruh terhadap kemampuan model dalam mengklasifikasikan kedua kelas.

Tabel 2. Hasil Akurasi

Accuracy: 97.46%			
	True 0	True 1	Class Precision
Pred.0	1833	48	97.45%
Pred.1	38	1467	97.48%
Class Recall	97.97%	96.83%	

Hasil evaluasi menunjukkan bahwa model memperoleh akurasi sebesar 97.46%. Berdasarkan *accuracy* yang dihasilkan, model berhasil mengklasifikasikan:

- 1833 data non-tumor secara benar dan salah mengklasifikasikan 48 data
- 1467 data tumor secara benar dan salah mengklasifikasikan 38 data.

Nilai precision dan recall untuk kedua kelas juga tinggi, menunjukkan bahwa model memiliki sensitivitas dan presisi prediksi yang baik terhadap data tumor maupun non-tumor.


PerformanceVector

```

PerformanceVector:
accuracy: 97.46%
ConfusionMatrix:
True: 0 1
0: 1833 48
1: 38 1467
classification_error: 2.54%
ConfusionMatrix:
True: 0 1
0: 1833 48
1: 38 1467
weighted_mean_recall: 97.40%, weights: 1, 1
ConfusionMatrix:
True: 0 1
0: 1833 48
1: 38 1467
weighted_mean_precision: 97.46%, weights: 1, 1
ConfusionMatrix:
True: 0 1
0: 1833 48
1: 38 1467
    
```

Gambar 6. Hasil *Performance Vector*

Hasil evaluasi performa model yang ditampilkan melalui Performance Vector menunjukkan bahwa algoritma Decision Tree mampu menghasilkan kinerja klasifikasi yang sangat baik dalam membedakan citra tumor dan non-tumor berdasarkan fitur statistik dan tekstur pada dataset Brain Tumor. Model mencapai akurasi sebesar 97,46%, yang mengindikasikan bahwa sebagian besar prediksi sesuai dengan label sebenarnya pada data uji, dengan classification error hanya 2,54% sebagai indikator rendahnya tingkat kesalahan prediksi. Confusion matrix mencatat bahwa pada kelas non-tumor (kelas 0), model berhasil mengklasifikasikan 1833 instance secara tepat dengan hanya 48 instance salah diklasifikasikan sebagai tumor, sedangkan pada kelas tumor (kelas 1), sebanyak 1467 instance berhasil diprediksi dengan benar dan hanya 38 instance yang salah diprediksi sebagai non-tumor. Kecilnya kesalahan pada kedua kelas menunjukkan sensitivitas dan spesifisitas yang baik. Nilai weighted mean recall sebesar 97,40% menunjukkan bahwa model mampu mendeteksi hampir seluruh instance pada tiap kelas, yang sangat penting dalam aplikasi medis karena kesalahan deteksi tumor dapat berdampak signifikan. Sementara itu, weighted mean precision sebesar 97,46% menegaskan bahwa sebagian besar prediksi positif model adalah benar, sehingga risiko false positive cukup rendah. Konsistensi precision dan recall yang tinggi pada kedua kelas menggambarkan performa model yang stabil dan tidak bias. Secara keseluruhan, Performance Vector membuktikan bahwa Decision Tree dengan konfigurasi yang digunakan mampu menghasilkan model klasifikasi yang akurat, seimbang, dan dapat diandalkan, sehingga layak diterapkan sebagai pendekatan awal dalam identifikasi tumor otak berbasis fitur numerik.



Gambar 7. Hasil *Decision Tree*

Hasil visualisasi struktur pohon keputusan menunjukkan bagaimana algoritma Decision Tree memilih atribut-atribut secara bertingkat untuk membedakan kelas tumor (1) dan non-tumor (0). Atribut Entropy muncul sebagai *root node*, menandakan bahwa tingkat ketidakteraturan tekstur citra MRI merupakan faktor paling dominan dalam proses klasifikasi. Nilai Entropy yang rendah ($\leq 0,054$) langsung mengarah pada kelas tumor, sementara nilai yang lebih tinggi memicu analisis lanjutan pada atribut Homogeneity. Ketika nilai Homogeneity $> 0,510$, citra diklasifikasikan sebagai non-tumor, sedangkan nilai yang lebih rendah memerlukan pemeriksaan terhadap atribut Energy, di mana nilai Energy $> 0,237$ menunjukkan non-tumor. Jika tidak, model melanjutkan pemisahan menggunakan Skewness, dengan nilai $> 2,413$ mengarah pada kelas tumor. Pada kasus yang lebih ambigu, atribut Mean menjadi penentu akhir, di mana nilai Mean $> 10,303$ diklasifikasikan sebagai tumor. Struktur pohon ini menunjukkan bahwa kombinasi fitur tekstur dan statistik bekerja secara efektif dan saling melengkapi, serta menghasilkan model yang tetap mudah diinterpretasikan karena jalur keputusan yang jelas dan logis.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa algoritma Decision Tree mampu melakukan klasifikasi tumor otak secara efektif menggunakan fitur statistik orde pertama dan fitur tekstur orde kedua hasil ekstraksi citra MRI. Seluruh tahapan penelitian, mulai dari pengumpulan dataset, preprocessing, pembagian data, pembangunan model hingga evaluasi performa menunjukkan bahwa kualitas data dan pemilihan fitur berperan penting dalam keberhasilan model. Model memperoleh akurasi sebesar 97.46%, dengan nilai precision dan recall yang tinggi pada kedua kelas, sehingga membuktikan konsistensi performanya dalam membedakan citra tumor dan non-tumor. Struktur pohon keputusan yang dihasilkan juga menunjukkan interpretabilitas yang baik, di mana atribut Entropy, Homogeneity, Energy, Skewness, dan Mean menjadi faktor penentu dalam proses klasifikasi. Dengan demikian, penelitian ini menunjukkan bahwa metode Decision Tree berbasis RapidMiner merupakan pendekatan yang efektif, mudah diimplementasikan, serta dapat digunakan sebagai alat bantu dalam proses identifikasi awal tumor otak.

DAFTAR PUSTAKA

- Agus, I. M., Gunawan, O., Ayu, I. D., Saraswati, I., Gede, I. D., Agung, R., & Eka, I. P. (2023). *Klasifikasi Penyakit Jantung Menggunakan Algoritma Decision Tree Series C4 . 5 Dengan Rapidminer*. 5(2), 73–83.
- Amaliyah, A., & Fatah, Z. (2024). *Implementasi Prediksi Penyakit Ginjal Kronis dengan Menggunakan Metode Decision Tree*. 3(2), 180–186.
- Ayudhitama, A. P., Pujiyanto, U., Elektro, T., Teknik, F., Malang, U. N., Tree, D., & Network, N. (n.d.). *ANALISA 4 ALGORITMA DALAM KLASIFIKASI PENYAKIT LIVER*. 1–9.
- Carolina, A., Ade, K., & Kunci, K. (2020). *Penerapan Data Mining dengan Menggunakan Provinsi di Indonesia Pendahuluan*. 19, 27–38.
- Dheepak, G., J, A. C., & Vaishali, D. (2024). *Brain tumor classification : a novel approach integrating GLCM , LBP and composite features*. January, 1–12. <https://doi.org/10.3389/fonc.2023.1248452>
- Fata, A. N. P. H. W. S. D. A. (2024). *Penerapan Data Mining untuk Klasifikasi Penyakit Diabetes Menggunakan Metode Decision Tree*. 7(6), 1484–1495.
- Fikriah, F. K., Devi, A., Ariyanto, P., & Setyawan, A. F. (2024). *Klasifikasi hasil mri tumor otak dengan*

- ekstraksi fitur gray level co-occurrence matrix (glcm) 1). 9(2), 343–350.
- Hidayaturrahman. (2024). *KLASIFIKASI TUMOR OTAK PADA CITRA MAGNETIC RESONANCE IMAGING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK BERBASIS WEB*.
- Husnah, N. A. (2021). *IMPLEMENTASI ALGORITMA DECISION TREE UNTUK*. 7(2), 45–51.
- Prasetyo, S. Y. N. G. Z. (2023). *Model, Perbandingan Learning, Machine Klasifikasi, Pada Otak, Tumor Fitur, Menggunakan Cosine, Discrete*. 9(1), 29–34.
- Putri, A. D., Sholekhah, F., & Dadynata, E. (2024). *The Application of C4 . 5 Decision Tree Algorithm for Predicting the Survival Rate of Thyroid Cancer Patients Penerapan Algoritma Decesion Tree C4 . 5 untuk Memprediksi Tingkat Kelangsungan Hidup Pasien Kanker Tiroid*. 4(October), 1485–1495.
- Setyawan, A., Fitriani, A., Rilvani, E., Bangsa, U. P., & Bekasi, K. (2025). *KLASIFIKASI KEMISKINAN DI INDONESIA DENGAN*. 3(7).
- Supriyatin, W., & Rianto, Y. (2024). *Comparative Analysis Accuracy ID3 Algorithm and C4 . 5 Algorithm in S election of Candidates Basic Physics Laboratory Assistant*. 21(1), 1–14.
- Suryawanshi, S., & Patil, S. B. (2023). *Multiclass Classification of Brain MRI through DWT and GLCM Feature Extraction with Various Machine Learning Algorithms*. May.
- Winnarto, M. N., Mailasari, M., & Purnamawati, A. (2024). *Ekstraksi Fitur Dan Implementasi Machine Learning Untuk Klasifikasi Jenis Tumor Otak*. 6(1).