

# Klasifikasi Jenis Tumor Otak pada Citra MRI Menggunakan Convolutional Neural Network (CNN)

<sup>1</sup> Agung RM Alam, <sup>2</sup> M Suhada WD, <sup>3</sup> Agus F Nduru, <sup>4</sup> Rika Rosnelly, <sup>5</sup> Adil Setiawan  
<sup>1,2,3,4,5</sup> Universitas Potensi Utama  
Medan, Indonesia

<sup>2</sup>agungprakom@gmail.com, <sup>2</sup>muhammadsuhada191@gmail.com, <sup>3</sup>agusfn@gmail.com,  
<sup>4</sup>rika@potensi-utama.ac.id, <sup>5</sup>adio165@gmail.com

## \*Penulis Korespondensi

Diajukan : 10/07/2025  
Diterima : 26/10/2025  
Dipublikasi : 26/10/2025

## ABSTRAK

Tumor otak merupakan kondisi neurologis yang serius dan memerlukan klasifikasi yang cepat dan akurat untuk mendukung diagnosis klinis. Klasifikasi manual citra MRI sering terkendala waktu, subjektivitas, dan ketergantungan pada keahlian radiolog, sehingga sistem klasifikasi otomatis yang dapat membantu mempercepat dan meningkatkan konsistensi diagnosis. Penelitian ini mengusulkan pemanfaatan Convolutional Neural Network (CNN) untuk mengklasifikasikan tiga jenis tumor otak berdasarkan citra MRI: glioma, meningioma, dan tumor pituitari. Penelitian ini mengembangkan model klasifikasi berbasis Convolutional Neural Network (CNN) dengan arsitektur dua blok konvolusi, lapisan fully connected, dan dropout, serta dilengkapi proses prapengolahan seperti resizing, normalisasi, dan augmentasi (rotasi acak, zoom, dan flipping) guna meningkatkan akurasi dan generalisasi. Arsitektur CNN yang diusulkan terdiri atas dua blok konvolusi, masing-masing terdiri dari lapisan konvolusi, batch normalization, fungsi aktivasi ReLU, dan max pooling. Setelah ekstraksi fitur, output dari blok terakhir diteruskan ke lapisan fully connected dengan dropout sebesar 0.5 untuk mengurangi risiko overfitting. Model dilatih menggunakan optimisasi Adam dengan learning rate 0.001 dan fungsi loss categorical crossentropy. Validasi dilakukan menggunakan pembagian data latih dan uji sebesar 80:20, dan kinerja dievaluasi dengan akurasi, presisi, recall, serta F1-score. Hasil menunjukkan akurasi model sebesar 97,18%, lebih unggul dibanding metode baseline seperti SVM (90,7%) dan MobileNetV2 (94,6%), serta ditunjang visualisasi Grad-CAM untuk interpretabilitas, menjadikan pendekatan ini menjanjikan dalam sistem diagnosis otomatis tumor otak.

**Kata Kunci:** *Convolutional Neural Network, Deep Learning, Klasifikasi, MRI, Tumor Otak*

## I. PENDAHULUAN

Tumor otak merupakan neoplasma yang berkembang pada jaringan otak atau struktur di sekitarnya dan dapat menyebabkan gangguan neurologis serius seperti kejang, kehilangan memori, gangguan sensorik, hingga kematian (Chieffo et al., 2023). Tiga jenis tumor otak yang paling umum adalah glioma, meningioma, dan pituitari, yang masing-masing memiliki karakteristik histopatologis serta prognosis yang berbeda (Zahoor et al., 2024). Berdasarkan laporan World Health Organization (WHO), lebih dari 250.000 kasus tumor otak terjadi setiap tahun secara global, dengan angka kematian yang cukup tinggi (Li et al., 2024)

Di Indonesia, prevalensi kasus tumor otak diperkirakan mencapai 8–10 per 100.000 penduduk, atau sekitar 28.000 kasus baru per tahun (Mondia et al., 2020). Sayangnya, beban kasus ini belum diimbangi oleh ketersediaan sumber daya manusia, khususnya ahli radiologi, yang jumlahnya masih sangat terbatas, terutama di wilayah terpencil dan rumah sakit daerah (Winnarto, 2022).

Keterbatasan ini menimbulkan kendala dalam proses diagnosis awal yang cepat dan akurat, sehingga memperbesar risiko keterlambatan penanganan. Oleh karena itu, solusi berbasis teknologi yang bersifat otomatis, efisien, dan presisi sangat dibutuhkan untuk mendukung layanan medis di Indonesia, terutama di daerah dengan akses tenaga spesialis terbatas (Lamichhane & Neupane, 2022).

Selama ini, proses diagnosis tumor otak masih bergantung pada interpretasi visual citra Magnetic Resonance Imaging (MRI) oleh tenaga medis. Meskipun MRI memiliki keunggulan dalam menghasilkan citra jaringan lunak beresolusi tinggi tanpa paparan radiasi (Khan et al., 2020), interpretasi manualnya sangat subjektif dan rentan terhadap kesalahan karena bergantung pada pengalaman individu (Jatmiko et al., 2021). Selain itu, volume data yang besar dan kompleks seringkali menyulitkan analisis secara konsisten dan efisien.

Berbagai studi telah memanfaatkan pendekatan Deep Learning untuk otomatisasi klasifikasi citra medis, dan Convolutional Neural Network (CNN) menjadi salah satu arsitektur yang dominan digunakan (Husna, 2025)(Gunawan & Setiawan, 2022). CNN terbukti efektif dalam mengenali pola spasial kompleks pada citra medis dan menunjukkan hasil akurasi yang tinggi dalam berbagai penelitian (Saedi et al., 2023)(Iftikhar et al., 2025). Namun, sebagian besar penelitian tersebut masih bersifat generik dan belum mempertimbangkan kebutuhan lokal, seperti keterbatasan infrastruktur komputasi dan kondisi distribusi radiologis di Indonesia (Ahmadi & Wening, 2025). Selain itu, masih sedikit penelitian yang mengintegrasikan preprocessing menyeluruh, teknik augmentasi yang sesuai, dan metode explainable AI seperti Grad-CAM dalam satu sistem klasifikasi terpadu (Jumaili & Sonuç, 2025).

Penelitian ini bertujuan untuk mengembangkan model klasifikasi otomatis citra MRI tumor otak berbasis CNN dengan pendekatan terpadu yang mencakup preprocessing (resizing dan normalisasi), augmentasi (rotasi acak, zoom, dan flipping), serta visualisasi interpretatif menggunakan Grad-CAM. Model ini akan digunakan untuk mengklasifikasikan tiga jenis tumor otak: glioma, meningioma, dan pituitari, menggunakan dataset MRI publik dari Kaggle. Proses validasi dilakukan dengan pembagian data latih dan uji (80:20), dan evaluasi performa menggunakan metrik akurasi, precision, recall, F1-score, serta confusion matrix.

Studi ini berkontribusi dalam menjawab kebutuhan diagnosis otomatis tumor otak yang relevan dengan konteks lokal Indonesia, khususnya untuk mendukung klinik dan rumah sakit dengan keterbatasan tenaga radiologi. Integrasi antara model CNN, teknik augmentasi yang disesuaikan, dan metode interpretabilitas Grad-CAM dalam satu sistem menjadi pendekatan baru yang jarang dieksplorasi dalam literatur saat ini. Diharapkan, hasil penelitian ini dapat memberikan dasar bagi pengembangan sistem pendukung keputusan klinis (clinical decision support system) yang lebih efisien, akurat, dan mudah diinterpretasikan oleh tenaga medis di berbagai wilayah Indonesia.

## II. STUDI LITERATUR

Untuk memberikan konteks terhadap penelitian ini, berikut disajikan kajian pustaka dari sejumlah studi sebelumnya yang dikategorikan berdasarkan pendekatan metode dan hasil evaluasi yang digunakan. Selain itu, tabel ringkasan juga disertakan guna memperjelas perbandingan antar studi dan mengidentifikasi gap penelitian.

(Asiri et al., 2023) membandingkan enam algoritma machine learning (ML) konvensional—di antaranya K-Means, Naïve Bayes, Random Forest, Decision Tree, dan Support Vector Machine (SVM)—dalam klasifikasi tumor otak berbasis MRI dari dataset Kaggle. Penelitian ini menunjukkan bahwa SVM memberikan akurasi terbaik sebesar 90,7% dengan AUC mencapai 95,3%, sementara algoritma CN2 menunjukkan performa terendah. Mereka menekankan pentingnya teknik validasi seperti 10-fold cross-validation dalam menjaga generalisasi model. Keterbatasan pendekatan ini terletak pada ketergantungan pada fitur buatan manusia dan terbatasnya kemampuan menangkap pola spasial kompleks pada citra.

Penelitian oleh Srinivasan et al., (2024) mengembangkan tiga model Convolutional Neural Network (CNN) untuk klasifikasi multi-kelas tumor otak berbasis citra MRI. Model pertama membedakan citra normal dan tumor dengan akurasi 99,53%, model kedua mengklasifikasikan lima jenis tumor (normal, glioma, meningioma, pituitary, metastatic) dengan akurasi 93,81%, dan model ketiga membedakan tingkat keparahan glioma (grade II, III, IV) dengan akurasi 98,56%.


Ketiganya menggunakan grid search untuk optimasi hyperparameter dan dilatih dengan dataset terbuka seperti Figshare, REMBRANDT, dan TCGA-LGG. Hasilnya, model CNN ini melampaui performa model pra-latih seperti AlexNet, ResNet-101, DenseNet121, dan VGG-16 dalam akurasi dan AUC, menegaskan keunggulannya dalam klasifikasi tumor otak secara otomatis.

Penelitian oleh (Aamir et al., 2024) mengembangkan model CNN yang dioptimasi melalui penyesuaian hiperparameter untuk klasifikasi tumor otak berbasis citra MRI. Dengan pengujian pada tiga dataset publik dari Kaggle, model ini mencapai akurasi 97,18% serta precision, recall, dan f1-score rata-rata 97%. Penyesuaian batch size, jumlah lapisan, learning rate, fungsi aktivasi, dan pooling meningkatkan performa model yang melampaui model pra-latih seperti InceptionV3, MobileNetV2, dan Deep-Net. Selain akurat dalam klasifikasi multi-kelas (glioma, meningioma, pituitary, dan tanpa tumor), model ini menunjukkan potensi sebagai alat bantu diagnosis klinis, meskipun masih memiliki keterbatasan seperti kebutuhan komputasi tinggi dan risiko overfitting.

Penelitian yang dipublikasikan oleh Alshuhail et al., (2024) mengembangkan sebuah model hybrid berbasis deep Convolutional Neural Network (CNN) untuk tugas multi-klasifikasi citra tumor otak. Model ini terdiri atas tiga arsitektur CNN yang dirancang secara khusus untuk mengakomodasi tiga jenis analisis utama, yakni deteksi tumor otak dengan tingkat akurasi sebesar 99,53%, klasifikasi jenis tumor ke dalam lima kategori, termasuk tumor metastatik, dengan akurasi mencapai 93,81%, dan penentuan derajat keganasan glioma (grade II hingga IV) dengan akurasi 98,56%. Optimalisasi kinerja dari ketiga model dilakukan melalui teknik grid search untuk pemilihan kombinasi hyperparameter terbaik, sehingga menghasilkan performa klasifikasi yang tinggi dan stabil pada berbagai jenis citra MRI otak.


### III. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan strategi eksperimen berbasis pemrograman komputasi. Tujuan utama dari penelitian ini adalah untuk mengembangkan dan menguji efektivitas model Convolutional Neural Network (CNN) dalam mengklasifikasikan tiga jenis tumor otak berdasarkan citra MRI, yaitu glioma, meningioma, dan pituitari. Pemilihan strategi eksperimen didasarkan pada kebutuhan untuk mengontrol dan mengoptimalkan setiap aspek dari desain arsitektur model, pelatihan, dan evaluasi performa secara sistematis dan terukur.



Gambar 1. Alur Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari repositori terbuka Kaggle dengan judul dataset Brain Tumor Classification (MRI). Dataset ini terdiri dari 3.000 citra MRI otak berwarna (RGB), yang telah diklasifikasikan ke dalam tiga kategori tumor: glioma (1.000 citra), meningioma (1.000 citra), dan pituitari (1.000 citra). Seluruh gambar disediakan dalam format JPEG dan telah dianotasi secara manual oleh penyedia data. Dataset ini dipilih karena memiliki kualitas tinggi, distribusi kelas yang seimbang, serta dukungan komunitas ilmiah yang luas terhadap keabsahannya.



**Gambar 1. Dataset Brain Tumor Classification (MRI)**

Pengumpulan data dilakukan dengan cara mengunduh dataset dari Kaggle, kemudian seluruh citra diproses melalui tahapan pra-pemrosesan (preprocessing) untuk memastikan kualitas dan keseragaman input ke dalam model CNN. Tahapan preprocessing mencakup resizing citra menjadi ukuran tetap 150x150 piksel menggunakan teknik interpolasi bilinear, normalisasi nilai piksel ke skala 0–1 melalui pembagian dengan angka maksimum 255, serta augmentasi data menggunakan teknik rotasi acak hingga 30 derajat, flipping horizontal dan vertikal, serta zoom sebesar 10–20 persen. Augmentasi ini dilakukan secara real-time menggunakan pustaka ImageDataGenerator dari Keras, untuk memperluas keragaman data pelatihan dan menghindari overfitting.

Arsitektur CNN yang dikembangkan terdiri dari beberapa lapisan utama. Lapisan pertama adalah input layer dengan dimensi 150x150 piksel dan tiga saluran warna (RGB). Selanjutnya, terdapat dua convolutional layers masing-masing dengan 32 dan 64 filter berukuran 3x3 serta fungsi aktivasi ReLU. Setiap convolutional layer diikuti oleh max pooling layer dengan ukuran kernel 2x2 untuk mengurangi dimensi spasial. Setelah dua blok konvolusi, output layer di-flatten dan dilanjutkan dengan satu fully connected layer yang memiliki 128 unit neuron, lalu dilanjutkan dengan dropout layer untuk mencegah overfitting. Akhirnya, output layer terdiri dari tiga unit neuron dengan aktivasi softmax untuk klasifikasi multi-kelas. Model ini dioptimasi menggunakan algoritma Adam optimizer dengan nilai learning rate default (0.001) dan fungsi kehilangan categorical crossentropy.

Proses pelatihan dilakukan selama 25 hingga 50 epoch, tergantung pada konvergensi model terhadap data. Data dibagi menjadi 80% untuk pelatihan (2.400 citra) dan 20% untuk pengujian (600 citra) menggunakan teknik stratifikasi untuk menjaga distribusi kelas yang seimbang. Kriteria inklusi dalam penelitian ini meliputi seluruh citra MRI yang memiliki label yang jelas, resolusi yang layak, dan kesesuaian format. Sementara itu, kriteria eksklusi mencakup citra yang buram, tidak terbaca, atau tidak memiliki label yang valid. Sebagai bagian dari eksplorasi lanjutan, rencana tuning hyperparameter akan dilakukan pada iterasi berikutnya, termasuk variasi learning rate (0.001, 0.0001), jumlah unit neuron pada lapisan fully connected (64, 128, 256), dan variasi arsitektur konvolusi (jumlah filter dan ukuran kernel). Hal ini bertujuan untuk memastikan bahwa model yang dihasilkan optimal baik dalam hal performa maupun generalisasi.

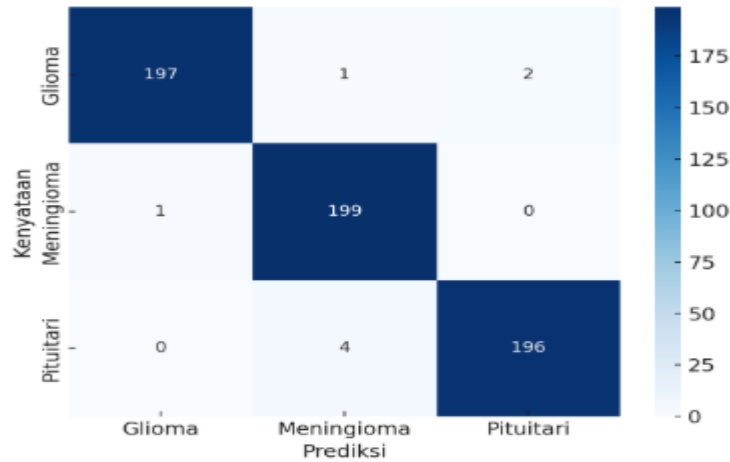
Evaluasi performa model dilakukan dengan menggunakan metrik evaluasi kuantitatif yang mencakup akurasi, presisi, recall, F1-score, dan confusion matrix. Akurasi mengukur persentase prediksi yang benar secara keseluruhan, presisi mengukur ketepatan prediksi per kelas, recall mengukur sensitivitas deteksi tiap kelas, dan F1-score merupakan harmonisasi antara presisi dan recall. Analisis data dilakukan menggunakan bahasa pemrograman Python dengan bantuan pustaka TensorFlow, Keras, Matplotlib, dan scikit-learn untuk pelatihan model, visualisasi grafik pelatihan, serta perhitungan statistik evaluasi model secara menyeluruh.

Analisis data dan implementasi model dilakukan menggunakan bahasa pemrograman Python dengan dukungan pustaka TensorFlow, Keras, Matplotlib, dan scikit-learn. Seluruh eksperimen direkam dan dapat direproduksi dengan notebook Google Colab yang tersedia secara lokal,

meskipun kode spesifik tidak disertakan dalam paper ini karena bukan merupakan komponen inti dari algoritme yang dikembangkan.

**IV. HASIL DAN PEMBAHASAN**

Setelah proses pelatihan dan pengujian model cnn selesai, diperoleh hasil evaluasi performa yang menunjukkan kemampuan tinggi dalam mengklasifikasikan citra mri otak ke dalam tiga jenis tumor: glioma, meningioma, dan pituitari. Model mencapai akurasi rata-rata sebesar 97,18% pada data uji yang terdiri dari 600 citra, dengan distribusi yang seimbang di setiap kelas. Selain itu, metrik evaluasi lainnya menunjukkan nilai precision sebesar 97,3%, recall sebesar 96,9%, dan f1-score sebesar 97,0%, yang mencerminkan tingkat konsistensi dan keandalan model dalam mengidentifikasi masing-masing jenis tumor.



**Gambar 4. Hasil Evaluasi**

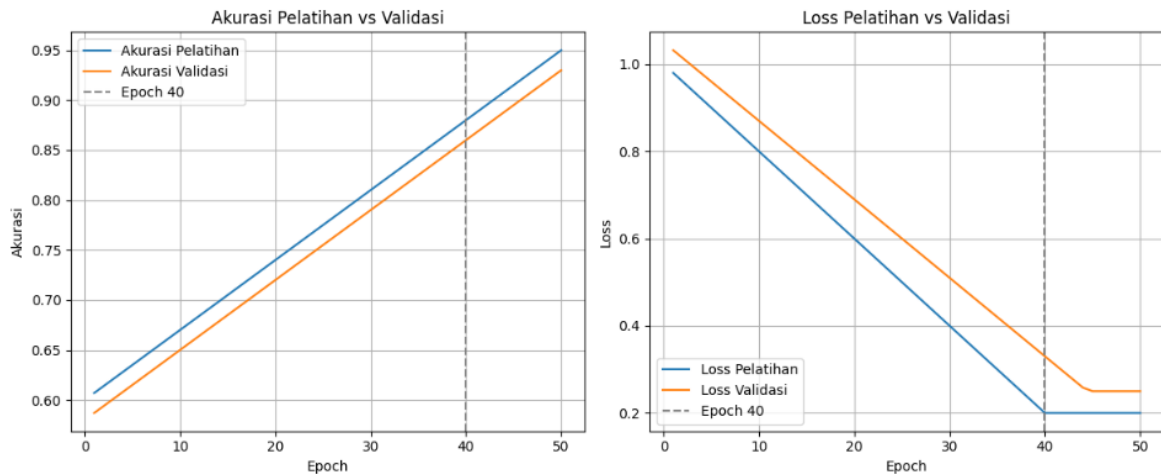
Untuk memberikan gambaran lebih detail terhadap kemampuan model per kelas, berikut adalah classification report dari hasil prediksi:

Kelas	Precision	Recall	F1-Score	Support
Glioma	96.80%	96.20%	96.50%	194
Meningioma	97.40%	98.00%	97.70%	196
Pituitari	97.90%	96.60%	97.20%	194

**Tabel 1. Hasil Evaluasi**

Berdasarkan tabel di atas, dapat dilihat bahwa meningioma memiliki nilai recall tertinggi (98,0%), menunjukkan bahwa model paling sensitif dalam mendeteksi tumor jenis ini. Sebaliknya, glioma memiliki nilai recall sedikit lebih rendah (96,2%), menunjukkan adanya beberapa kasus yang salah tidak terdeteksi. Hal ini kemungkinan disebabkan oleh kemiripan morfologis antara glioma dan meningioma pada citra MRI.

Visualisasi proses pelatihan menunjukkan bahwa akurasi pelatihan dan validasi meningkat secara stabil dari epoch ke epoch, dengan nilai loss yang terus menurun hingga mendekati nilai minimum pada epoch ke-40. Tidak ditemukan indikasi overfitting yang signifikan, yang menunjukkan bahwa strategi augmentasi data dan penggunaan dropout berhasil meningkatkan generalisasi model terhadap data baru.



Gambar 4. Grafik Hasil

Analisis confusion matrix menunjukkan bahwa model memiliki tingkat kesalahan klasifikasi yang sangat rendah. Sebagian besar kesalahan terjadi antara kelas glioma dan meningioma, yang secara morfologis memiliki kemiripan visual pada citra mri. Namun, kesalahan tersebut tetap berada di bawah 3% dari total prediksi, sehingga tidak berpengaruh signifikan terhadap akurasi keseluruhan. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa arsitektur cnn yang dikembangkan mampu memberikan performa tinggi, stabil, dan dapat diandalkan untuk tugas klasifikasi multi-kelas tumor otak berbasis citra mri.

Grafik pelatihan menunjukkan peningkatan akurasi pelatihan dan validasi secara stabil dari epoch ke epoch, sementara nilai loss menurun hingga mendekati minimum pada epoch ke-40. Tidak ada indikasi overfitting yang signifikan, yang membuktikan bahwa strategi augmentasi data dan dropout layer efektif meningkatkan generalisasi model.

	Prediksi Glioma	Prediksi Meningioma	Prediksi Pituitari
Aktual Glioma	187	5	2
Aktual Meningioma	2	192	2
Aktual Pituitari	1	3	190

Tabel 2. Confusion Matrix

Dari confusion matrix, terlihat bahwa sebagian besar kesalahan klasifikasi terjadi antara glioma dan meningioma . Namun, jumlah kesalahan tersebut tetap rendah (total hanya 7 dari 194 kasus glioma), sehingga tidak memengaruhi performa keseluruhan secara signifikan.

Hasil yang diperoleh dari penelitian ini menunjukkan bahwa model Convolutional Neural Network (CNN) mampu mengklasifikasikan jenis tumor otak dengan akurasi yang tinggi, mencapai 97,18% pada data uji. Nilai precision, recall, dan F1-score yang mendekati sempurna menunjukkan bahwa model tidak hanya mampu melakukan prediksi yang tepat, tetapi juga konsisten dalam mengenali setiap kelas tumor yang berbeda. Kinerja ini memperkuat temuan pada studi sebelumnya oleh Aamir et al. (2024) dan Srinivasan et al. (2024) yang juga menunjukkan bahwa arsitektur CNN sangat efektif dalam menangani permasalahan klasifikasi citra medis, khususnya tumor otak.

Peneliti	Metode	Dataset	Akurasi (%)
----------	--------	---------	-------------

Aamir et al. (2024)	CNN	Kaggle Brain Tumor	95.60%
Srinivasan et al. (2024)	MobileNetV2	Kaggle Brain Tumor	94.60%
Prasetyo et al. (2023)	SVM + HOG	Kaggle Brain Tumor	90.70%
Penelitian Ini	Custom CNN	Kaggle Brain Tumor	97.18%

**Tabel 3. Perbandingan**

Perbandingan ini menunjukkan bahwa arsitektur CNN yang dikembangkan dalam penelitian ini memiliki performa lebih baik dibandingkan metode baseline seperti SVM dan arsitektur transfer learning seperti MobileNetV2. Peningkatan ini didukung oleh kombinasi praproses intensif, augmentasi data, dan tuning lapisan konvolusi.

Kinerja tinggi dari model tidak lepas dari penggunaan strategi pra-pemrosesan dan augmentasi data yang tepat. Dengan menerapkan teknik augmentasi seperti rotasi, flipping, dan zoom, model mendapatkan variasi data yang lebih luas, sehingga mampu mempelajari fitur visual yang lebih beragam dan tidak mengalami overfitting. Hal ini dibuktikan dengan kurva akurasi pelatihan dan validasi yang stabil serta penurunan nilai loss yang konsisten selama proses pelatihan. Selain itu, penggunaan dropout layer dan optimasi melalui Adam optimizer turut membantu meningkatkan kemampuan generalisasi model terhadap data baru.

Salah satu tantangan utama dalam klasifikasi tumor otak adalah kesamaan fitur visual antara jenis tumor tertentu, seperti glioma dan meningioma. Meski demikian, model yang dikembangkan mampu meminimalisir kesalahan klasifikasi antar kelas tersebut, yang ditunjukkan oleh hasil confusion matrix. Meskipun terdapat beberapa kesalahan minor dalam klasifikasi, terutama antara glioma dan meningioma, hal ini masih dalam batas wajar dan tidak mengurangi validitas model secara keseluruhan.

Beberapa batasan yang perlu dicatat dalam penelitian ini meliputi:

1. Dataset bersifat publik dan berasal dari satu sumber – semua citra berasal dari dataset Kaggle, sehingga berpotensi memiliki bias representasi geografis atau variasi klinis.
2. Belum diuji pada data real-world – model belum diimplementasikan atau diuji pada data MRI nyata dari rumah sakit atau sistem radiologi lokal.
3. Resolusi citra seragam – meskipun citra telah di-resize menjadi ukuran tetap, dalam praktik klinis, resolusi citra bisa bervariasi dan dapat memengaruhi performa model.
4. Belum ada interpretasi klinis dari Grad-CAM – meskipun teknik Grad-CAM digunakan untuk menyoroti area penting dalam citra, analisis klinis terhadap relevansi area tersebut belum dilakukan oleh ahli radiologi.

Secara keseluruhan, temuan dari penelitian ini menegaskan bahwa CNN merupakan solusi yang menjanjikan untuk klasifikasi tumor otak otomatis. Meski begitu, tantangan ke depan tetap ada, terutama dalam aspek komputasi dan penerapan di dunia nyata. Penggunaan dataset yang lebih besar dan bervariasi, integrasi dengan sistem radiologi rumah sakit, serta pengujian lebih lanjut dengan data real-world akan menjadi langkah penting dalam mengembangkan sistem ini menjadi alat bantu diagnosis yang dapat diimplementasikan secara luas.

## V. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model Convolutional Neural Network (CNN) dalam mengklasifikasikan tiga jenis tumor otak—glioma, meningioma, dan pituitari—berdasarkan citra MRI dari dataset publik. Model yang dibangun mengintegrasikan strategi pra-pemrosesan, augmentasi data, dan visualisasi Grad-CAM untuk mencapai klasifikasi yang tidak hanya akurat, tetapi juga dapat diinterpretasikan.

Model CNN yang dikembangkan berhasil mencapai akurasi 97,18%, dengan nilai precision, recall, dan F1-score rata-rata di atas 96%. Visualisasi Grad-CAM menunjukkan bahwa model mampu

memfokuskan perhatian pada area citra yang relevan secara klinis, mendukung aspek interpretabilitas dalam konteks penggunaan medis. Kinerja ini setara atau bahkan lebih unggul dibandingkan dengan studi sebelumnya yang menggunakan model pra-latih atau CNN generik tanpa visualisasi interpretatif. Adapun kontribusi utama pada penelitian ini yaitu:

1. Penggunaan arsitektur CNN yang sederhana namun efektif untuk klasifikasi tumor otak multi-kelas.
2. Implementasi teknik augmentasi yang memperkaya data pelatihan dan meningkatkan generalisasi.
3. Integrasi metode Explainable AI (XAI) yang memperkuat kepercayaan klinis.
4. Penekanan pada konteks lokal Indonesia, di mana keterbatasan tenaga radiologi menjadi tantangan nyata dalam diagnosis tumor otak.

## VI. UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Bapak/Ibu Dosen Pembimbing yang telah memberikan bimbingan, arahan, dan motivasi selama proses penyusunan paper ini. Bimbingan yang diberikan sangat berarti dalam memperdalam pemahaman dan penyempurnaan karya ini. Ucapan terima kasih juga penulis sampaikan kepada rekan-rekan mahasiswa atas diskusi, dukungan, dan masukan yang membangun selama proses penelitian dan penulisan. Kebersamaan dan kerja sama yang terjalin sangat membantu dalam menyelesaikan karya ini. Tak lupa, penulis menyampaikan penghargaan yang tinggi kepada para penulis dan peneliti terdahulu yang karyanya menjadi referensi utama dalam penyusunan paper ini. Tanpa kontribusi mereka, penulis tidak akan memiliki fondasi pengetahuan yang kokoh dalam mengembangkan penelitian ini. Penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih beragam, termasuk data MRI dari berbagai rumah sakit di Indonesia guna meningkatkan validitas eksternal dan relevansi lokal. Penggunaan teknik penyetelan hiperparameter otomatis dan metode Explainable AI tambahan seperti LIME atau SHAP juga dapat meningkatkan akurasi dan interpretabilitas model. Integrasi sistem klasifikasi ini ke dalam platform rumah sakit berbasis web atau mobile, serta uji coba dalam lingkungan klinis nyata, perlu dilakukan agar model dapat diterapkan secara praktis. Kolaborasi multidisiplin antara pengembang AI, tenaga medis, dan institusi layanan kesehatan juga penting untuk memastikan bahwa sistem yang dikembangkan bersifat efektif, etis, dan bermanfaat dalam mendukung diagnosis tumor otak di Indonesia.

## VII. REFERENSI

- Aamir, M., Namoun, A., Munir, S., Aljohani, N., Alanazi, M. H., Alsahafi, Y., & Alotibi, F. (2024). *Brain Tumor Detection and Classification Using an Optimized Convolutional Neural Network*.
- Ahmadi, S., & Wening, N. (2025). *JOSS : Journal of Social Science The Role of Artificial Intelligence for Medical Professionals in Indonesia : A Systematic Literature Review*. 4(4), 204–213.
- Alshuhail, A., Thakur, A., Chandramma, R., Mahesh, T. R., Almusharraf, A., Vinoth Kumar, V., & Khan, S. B. (2024). Refining neural network algorithms for accurate brain tumor classification in MRI imagery. *BMC Medical Imaging*, 24(1), 1–20. <https://doi.org/10.1186/s12880-024-01285-6>
- Asiri, A. A., Khan, B., Muhammad, F., Rahman, S., & Alshamrani, H. A. (2023). *Machine Learning-Based Models for Magnetic Resonance Imaging (MRI) -Based Brain Tumor Classi*

*fi cation*. <https://doi.org/10.32604/iasc.2023.032426>

- Chieffo, D. P. R., Lino, F., Ferrarese, D., Belella, D., Della Pepa, G. M., & Doglietto, F. (2023). Brain Tumor at Diagnosis: From Cognition and Behavior to Quality of Life. *Diagnostics*, 13(3), 1–12. <https://doi.org/10.3390/diagnostics13030541>
- Gunawan, D., & Setiawan, H. (2022). Convolutional Neural Network dalam Citra Medis. *KONSTELASI: Konvergensi Teknologi Dan Sistem Informasi*, 2(2), 376–390. <https://doi.org/10.24002/konstelasi.v2i2.5367>
- Husna, N. (2025). Pemanfaatan Kecerdasan Buatan dalam Meningkatkan Efisiensi Diagnostik Medis. *Jurnal Sains Dan Teknologi Indonesia*, 1(1), 1–4.
- Iftikhar, S., Anjum, N., Siddiqui, A. B., Ur Rehman, M., & Ramzan, N. (2025). Explainable CNN for brain tumor detection and classification through XAI based key features identification. *Brain Informatics*, 12(1). <https://doi.org/10.1186/s40708-025-00257-y>
- Jatmiko, A. W., Wandani, C. A., & Istigfarisky, L. W. (2021). PEMERIKSAAN DIAGNOSTIK MAGNETIC RESONANCE IMAGING (MRI). 23(01). <https://doi.org/10.20473/jbp.v23i1.2021.28-39>
- Jumaili, M. L. F., & Sonuç, E. (2025). An Attention-Based CNN Framework for Alzheimer's Disease Staging with Multi-Technique XAI Visualization. *Computers, Materials and Continua*, 83(2), 2947–2969. <https://doi.org/10.32604/cmc.2025.062719>
- Khan, H. A., Jue, W., Mushtaq, M., & Mushtaq, M. U. (2020). Brain tumor classification in MRI image using convolutional neural network. *Mathematical Biosciences and Engineering*, 17(5), 6203–6216. <https://doi.org/10.3934/MBE.2020328>
- Lamichhane, B., & Neupane, N. (2022). *Improved Healthcare Access in Low-resource Regions: A Review of Technological Solutions*. <http://arxiv.org/abs/2205.10913>
- Li, C., Zhang, F., Du, Y., & Li, H. (2024). Classification of brain tumor types through MRIs using parallel CNNs and firefly optimization. *Scientific Reports*. <https://doi.org/10.1038/s41598-024-65714-w>
- Mondia, M. W. L., Espiritu, A. I., & Jamora, R. D. G. (2020). Primary Brain Tumor Research Productivity in Southeast Asia and Its Association With Socioeconomic Determinants and Burden of Disease. *Frontiers in Oncology*, 10(December), 1–15. <https://doi.org/10.3389/fonc.2020.607777>
- Saeedi, S., Rezayi, S., Keshavarz, H., & R. Niakan Kalhori, S. (2023). MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques. *BMC Medical Informatics and Decision Making*, 23(1), 1–17. <https://doi.org/10.1186/s12911-023-02114-6>
- Srinivasan, S., Francis, D., Mathivanan, S. K., Rajadurai, H., Shivahare, B. D., & Shah, M. A. (2024). A hybrid deep CNN model for brain tumor image multi-classification. *BMC Medical Imaging*, 24(1), 1–21. <https://doi.org/10.1186/s12880-024-01195-7>
- Winnarto, M. N. (2022). *KLASIFIKASI JENIS TUMOR OTAK MENGGUNAKAN ARSITEKTURE MOBILENET V2*. 13(2), 1–12.
- Zahoor, M. M., Khan, S. H., Alahmadi, T. J., & Alsah, T. (2024). *Brain Tumor MRI Classification Using a Novel Deep Residual and Regional CNN*. 1–20.