

Perbandingan Kinerja CNN dalam Klasifikasi Tumor Otak dengan Pendekatan Explainable AI

Comparison of CNN Performance in Brain Tumor Classification using an Explainable AI Approach

¹Amin Darussalam*, ²Shofwatul 'Uyun

^{1,2}Magister Informatika, Fakultas Sains dan Teknologi, UIN Sunan Kalijaga Yogyakarta Sleman, DIY Indonesia

*e-mail: 23206051017@student.uin-suka.ac.id

(received: 2 September 2026, revised: 7 September 2026, accepted: 8 September 2026)

Abstrak

Tumor otak merupakan penyakit serius yang dapat menyebabkan gangguan neurologis dan berpotensi mengancam jiwa apabila tidak terdeteksi secara dini. Diagnosis umumnya dilakukan melalui analisis citra Magnetic Resonance Imaging (MRI) oleh tenaga medis, yang memerlukan ketelitian tinggi dan waktu yang relatif lama. Meskipun metode berbasis Convolutional Neural Network (CNN) telah menunjukkan kinerja yang baik dalam klasifikasi citra medis, sifatnya yang cenderung black-box masih menjadi kendala dalam hal interpretabilitas. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi tumor otak berbasis CNN yang tidak hanya akurat tetapi juga interpretabel melalui integrasi pendekatan Explainable Artificial Intelligence (XAI). Metode yang diusulkan menggunakan transfer learning dengan dua arsitektur, yaitu ResNet50 dan MobileNetV2, serta memanfaatkan Gradient-weighted Class Activation Mapping (Grad-CAM) untuk memvisualisasikan area citra yang berkontribusi terhadap keputusan model dalam bentuk heatmap. Hasil eksperimen menunjukkan bahwa ResNet50 memperoleh Accuracy sebesar 93,7%, sedikit lebih tinggi dibandingkan MobileNetV2 yang mencapai 92.93%. Selain itu, visualisasi Grad-CAM menunjukkan bahwa model mampu mengidentifikasi dan memfokuskan perhatian pada area tumor yang relevan pada citra MRI. Temuan ini menunjukkan bahwa integrasi CNN dan XAI tidak hanya meningkatkan kinerja klasifikasi, tetapi juga memberikan interpretasi visual yang mendukung transparansi model, sehingga berpotensi meningkatkan kepercayaan dan efektivitas dalam proses diagnosis medis.

Kata kunci: CNN, Explainable AI, Grad-CAM, transfer learning, brain tumor.

Abstract

Brain tumors are life-threatening conditions that require accurate and timely diagnosis. In clinical practice, diagnosis is commonly performed through Magnetic Resonance Imaging (MRI) analysis by medical experts, which is time-consuming and subject to variability. Recent advances in Convolutional Neural Networks (CNN) have shown promising performance in medical image classification; however, their black-box nature limits clinical trust and interpretability. This study proposes a comparative analysis of CNN-based models integrated with Explainable Artificial Intelligence (XAI) to improve both classification performance and model transparency. A transfer learning approach is employed using two architectures, ResNet50 and MobileNetV2, on a multi-class brain tumor MRI dataset. To enhance interpretability, Gradient-weighted Class Activation Mapping (Grad-CAM) is utilized to visualize discriminative regions influencing model predictions. Experimental results demonstrate that ResNet50 achieves an Accuracy of 93.7%, outperforming MobileNetV2 with 92.93%. Furthermore, Grad-CAM visualizations consistently highlight tumor-relevant regions, indicating that the models learn meaningful spatial features for classification. These findings confirm that integrating CNN with XAI not only provides high classification Accuracy but also improves model interpretability, thereby increasing its potential applicability in supporting reliable and transparent medical diagnosis.

Keywords: CNN, Explainable AI, Grad-CAM, transfer learning, brain tumor.

1. Pendahuluan

Otak merupakan organ vital yang berperan dalam mengendalikan fungsi tubuh, di mana pertumbuhan sel yang tidak terkendali dapat menyebabkan tumor otak [1]. Tumor otak diklasifikasikan menjadi tumor primer dan sekunder, dengan jenis yang umum meliputi glioma, meningioma, dan pituitary. Deteksi dini sangat penting karena berpengaruh terhadap keberhasilan terapi dan tingkat kesembuhan pasien [2] [3] [4][20].

Dalam praktik klinis, pencitraan medis seperti *Magnetic Resonance Imaging* (MRI) dan *Computed Tomography* (CT scan) digunakan untuk mendeteksi tumor otak [5]. Namun, proses analisis citra masih kompleks, membutuhkan keahlian radiolog, serta memerlukan waktu yang relatif lama [6]. Keterbatasan tersebut mendorong pengembangan sistem diagnosis berbasis kecerdasan buatan untuk meningkatkan efisiensi dan Accuracy, khususnya melalui pendekatan *deep learning* dalam analisis citra medis.

Salah satu pendekatan yang menunjukkan performa signifikan dalam analisis citra medis adalah Deep Learning, khususnya melalui arsitektur Convolutional Neural Network (CNN). CNN dirancang untuk mengekstraksi fitur secara otomatis melalui operasi konvolusi, sehingga efektif dalam mengenali pola visual kompleks pada citra medis [7]. Penerapan CNN telah mendorong transformasi dari metode diagnosis konvensional menuju sistem diagnosis otomatis dengan tingkat Accuracy yang tinggi [8].


Namun demikian, salah satu tantangan utama dalam implementasi CNN di bidang medis adalah sifatnya yang cenderung *black box*, sehingga proses pengambilan keputusan model sulit dipahami oleh tenaga medis. Untuk mengatasi hal ini, berbagai penelitian telah mengintegrasikan pendekatan *Explainable Artificial Intelligence* (XAI), seperti *Gradient-weighted Class Activation Mapping* (Grad-CAM), guna meningkatkan interpretabilitas model melalui visualisasi area penting pada citra [9]. Meskipun demikian, sebagian besar penelitian sebelumnya masih berfokus pada peningkatan Accuracy model atau penerapan XAI secara terpisah, tanpa melakukan analisis komparatif yang mendalam terhadap interpretabilitas dan kinerja antar arsitektur CNN.

Dalam penelitian ini, arsitektur ResNet50 dan MobileNetV2 dipilih karena karakteristiknya yang saling melengkapi. ResNet50 memiliki kemampuan mengekstraksi fitur kompleks melalui mekanisme residual learning yang efektif dalam mengatasi permasalahan vanishing gradient pada jaringan yang dalam [10]. Sementara itu, MobileNetV2 menawarkan efisiensi komputasi melalui penggunaan depthwise separable convolution dan inverted residual, sehingga sesuai untuk implementasi pada sistem dengan keterbatasan sumber daya [11][20].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk melakukan analisis perbandingan interpretabilitas model CNN dalam klasifikasi tumor otak dengan membandingkan arsitektur ResNet50 dan MobileNetV2 yang dikombinasikan dengan metode Grad-CAM. Pendekatan ini difokuskan untuk mengevaluasi sejauh mana masing-masing model mampu memberikan visualisasi area penting yang menjadi dasar pengambilan keputusan, sehingga diharapkan menghasilkan sistem klasifikasi yang tidak hanya akurat dan efisien, tetapi juga memiliki tingkat interpretabilitas yang tinggi guna mendukung proses diagnosis medis yang lebih transparan dan terpercaya. Penelitian ini memberikan kontribusi berupa analisis komparatif performa dan interpretabilitas model CNN menggunakan pendekatan XAI pada klasifikasi tumor otak.

2. Metode Penelitian

Penelitian ini menggunakan desain eksperimental untuk mengevaluasi kinerja model klasifikasi dalam konteks deteksi tumor otak pada citra medis. Studi ini melibatkan pelatihan dua arsitektur *Convolutional Neural Network* (CNN), yaitu ResNet50 dan MobileNetV2, dengan beberapa konfigurasi parameter guna menentukan kombinasi optimal dalam proses klasifikasi. Selain itu, interpretasi hasil prediksi dilakukan menggunakan pendekatan Explainable AI (XAI) untuk meningkatkan transparansi serta pemahaman terhadap dasar pengambilan keputusan model. Tahapan penelitian ini meliputi beberapa langkah utama, yaitu dataset, praproses data, model deep learning, split data, training model, evaluasi kinerja, serta interpretasi hasil menggunakan metode Explainable AI (XAI). Secara keseluruhan, alur tahapan penelitian ini dapat dilihat pada Gambar 1.



Gambar 1 Tahapan penelitian

2.1. Dataset

Penelitian ini menggunakan dataset publik yang diperoleh dari platform Kaggle yaitu yolov 11 brain tumor detection, yang terdiri atas citra medis RGB berukuran $224 \times 224 \times 3$ piksel. Dataset yang digunakan berjumlah 3.000 citra yang telah dipilih dan dikurasi untuk memastikan keseimbangan antar kelas serta menghindari duplikasi data. Dataset tersebut terbagi ke dalam tiga kategori tumor otak, yaitu glioma, meningioma, dan pituitary, masing-masing sebanyak 1.000 citra. Dataset ini mengacu pada sumber *Brain Tumor Detection* yang tersedia pada tautan berikut: <https://www.kaggle.com/code/myriamgam62/yolov11-brain-tumor-detection>. Rincian distribusi dataset dapat dilihat pada Tabel 1.

Tabel 1 Rincian jumlah dataset

No	Kelas	Jumlah
1	<i>Glioma</i>	1000
2	<i>Meningioma</i>	1000
3	<i>Pituitary</i>	1000
Total		3000

2.2. Praproses Data

Tahap praproses data dilakukan untuk menyiapkan citra sebelum memasuki proses pelatihan model. Seluruh citra di-*resize* menjadi 224×224 piksel agar sesuai dengan kebutuhan arsitektur CNN yang digunakan. Selain itu, dilakukan normalisasi nilai piksel untuk menyamakan rentang data sehingga lebih stabil dan efisien saat diproses oleh model. Tahap ini bertujuan menjaga konsistensi ukuran serta kualitas citra agar proses pembelajaran model dapat berlangsung secara optimal.

2.3. Model Deep Learning

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *Deep Learning* yang banyak digunakan untuk tugas klasifikasi pada data berdimensi dua, seperti gambar dan video. CNN bekerja dengan mengekstraksi fitur secara otomatis melalui operasi konvolusi sehingga mampu mengenali pola dan mendeteksi objek pada citra secara efektif. [7]. Adapun arsitektur CNN yang digunakan pada penelitian ini sebagai berikut.

A. ResNet50

Pada tahun 2015, Microsoft Research Asia memperkenalkan ResNet (Residual Network) untuk mengatasi masalah *vanishing gradient* pada jaringan saraf yang sangat dalam. Arsitektur ini memenangkan ILSVRC 2015 melalui varian ResNet50 yang terdiri dari 50 lapisan. Keunggulan ResNet terletak pada konsep *residual learning* dengan *skip connection*, yang memungkinkan pelatihan model menjadi lebih stabil dan efektif [12].

B. MobileNetV2

MobileNetV2 merupakan arsitektur CNN yang dirancang untuk efisiensi komputasi dan penggunaan sumber daya yang rendah, sehingga cocok untuk perangkat dengan keterbatasan hardware. Dirilis pada April 2017, MobileNetV2 menghadirkan dua komponen utama, yaitu Linear Bottleneck dan Shortcut Connection antar bottleneck, yang meningkatkan efisiensi sekaligus mempertahankan Accuracy model [13].

2.5. Training

Pada tahap training, dilakukan pengaturan hyperparameter untuk memastikan proses pembelajaran model berjalan optimal. Model menggunakan optimizer Adam dengan learning rate 0.001 serta loss function *sparse_categorical_crossentropy* untuk klasifikasi multi-kelas. Proses pelatihan dilakukan dengan batch size 32 dan 20 epoch. Selain itu, digunakan pretrained model berbasis ImageNet yang kemudian dilakukan fine-tuning pada layer akhir untuk menyesuaikan dengan dataset tumor otak. Implementasi dilakukan menggunakan framework TensorFlow dengan dukungan GPU guna mempercepat komputasi, sehingga menghasilkan model yang stabil dan memiliki kemampuan generalisasi yang baik.

2.6. Evaluasi Model

Pada tahap ini, pengujian sistem dievaluasi menggunakan *Confusion Matrix* untuk menghitung nilai Accuracy, Presisi, Recall, dan *F-1 score* [14]. Adapun persamaan untuk menghitung nilai Accuracy, Precision, Recall, dan *F-1 score* dapat dilihat pada persamaan (1), (2), (3), (4), dan (5).

$$N \text{ (Total Data)} = TP + TN + FP + FN \quad (1)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F - 1 \text{ score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

True Positive (TP): Jumlah data positif yang diidentifikasi dengan benar oleh sistem. True Negative (TN): Jumlah data negatif yang diidentifikasi dengan benar oleh sistem. False Positive (FP): Jumlah data yang seharusnya negatif tetapi diklasifikasikan sebagai positif oleh sistem. False Negative (FN): Jumlah data yang seharusnya positif tetapi diklasifikasikan sebagai negatif oleh sistem.

2.7. Interpretasi Model XAI dengan Grad-CAM

Seiring meningkatnya kompleksitas model Kecerdasan Buatan (AI), proses pengambilan keputusan menjadi sulit dipahami karena sifatnya yang *black box*, sehingga mekanisme hubungan antara input dan output tidak dapat dijelaskan secara eksplisit, bahkan oleh pengembangnya sendiri [15]. Untuk mengatasi keterbatasan tersebut, *Explainable Artificial Intelligence* (XAI) dikembangkan sebagai pendekatan yang bertujuan meningkatkan transparansi dan interpretabilitas model, khususnya pada *Convolutional Neural Network* (CNN). XAI memungkinkan analisis terhadap kontribusi fitur dan representasi internal yang memengaruhi prediksi, sehingga keputusan model dapat dijelaskan secara sistematis, serta meningkatkan kepercayaan dan akuntabilitas dalam penggunaannya [16]. Salah satu metode XAI yang banyak digunakan adalah Gradient-weighted Class Activation Mapping (Grad-CAM), yang memvisualisasikan area penting pada citra melalui heatmap spesifik kelas. Visualisasi ini menunjukkan wilayah yang menjadi fokus perhatian model CNN selama proses prediksi. Dalam konteks pencitraan medis, penerapan Grad-CAM dapat meningkatkan transparansi model sekaligus membantu tenaga medis memahami dasar pengambilan keputusan sistem berbasis kecerdasan buatan [17][20]. Selain itu, dilakukan analisis kualitatif (*qualitative analysis*) dengan mengevaluasi kesesuaian antara hasil visualisasi heatmap dan area tumor pada citra, yang menunjukkan bahwa model mampu memfokuskan perhatian pada wilayah yang relevan secara diagnostik.


3. Hasil dan Pembahasan

3.1. Hasil Penelitian

Berdasarkan hasil cross-validation lima lipatan, ResNet50 menunjukkan performa yang lebih stabil dengan Accuracy berkisar antara 0.9117 hingga 0.9417, sedangkan MobileNetV2 berada pada rentang 0.9150 hingga 0.9350, dengan nilai standard deviation yang rendah (± 0.01) pada kedua model, menandakan konsistensi yang baik. Secara umum, ResNet50 cenderung menghasilkan Accuracy yang lebih tinggi, yang dapat dijelaskan melalui konsep residual learning yang memanfaatkan skip connection untuk mengatasi vanishing gradient dan memungkinkan pembelajaran fitur yang lebih mendalam. Dalam konteks feature extraction pada citra MRI tumor otak, hal ini berdampak pada kemampuan model dalam menangkap pola tekstur dan karakteristik intensitas yang lebih kompleks, sehingga menghasilkan fitur yang lebih diskriminatif dan meningkatkan kinerja klasifikasi dibandingkan MobileNetV2.

3.2. Evaluasi ROC Curve Multi-Kelas ResNet50


Gambar 2 menunjukkan kurva ROC (Receiver Operating Characteristic) multi-kelas untuk evaluasi kinerja model dalam klasifikasi tumor otak. Berdasarkan hasil yang diperoleh, nilai AUC untuk kelas glioma dan pituitary masing-masing sebesar 0.96, sedangkan kelas meningioma sebesar 0.93. Selain itu, nilai macro-average AUC sebesar 0.95 menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik secara keseluruhan. Kurva ROC yang mendekati sudut kiri atas mengindikasikan bahwa model mampu membedakan antar kelas dengan tingkat sensitivitas dan spesifisitas yang tinggi. Hasil ini menegaskan bahwa model memiliki performa yang optimal dalam mengklasifikasikan tiga jenis tumor otak.



Gambar 2 ROC curve multi-kelas ResNet50

3.3. Evaluasi ROC Curve Multi-Kelas MobileNetV2


Gambar 3 menampilkan kurva ROC (Receiver Operating Characteristic) multi-kelas untuk mengevaluasi performa model dalam klasifikasi tumor otak. Nilai AUC yang diperoleh adalah 0.96 untuk kelas glioma, 0.92 untuk meningioma, dan 0.96 untuk pituitary, dengan macro-average AUC sebesar 0.95. Kurva yang mendekati sudut kiri atas menunjukkan bahwa model memiliki kemampuan diskriminasi yang sangat baik dalam membedakan antar kelas. Meskipun performa pada kelas meningioma sedikit lebih rendah dibandingkan kelas lainnya, secara keseluruhan model menunjukkan kinerja yang optimal dalam klasifikasi multi-kelas.



Gambar 3. ROC Curve multi-kelas MobileNetV2

3.4. Evaluasi Confusion Matrix ResNet50


Confusion matrix pada Gambar 4 menunjukkan bahwa model memiliki kinerja klasifikasi yang sangat baik pada tiga kelas tumor otak (glioma, meningioma, dan pituitary), dengan prediksi benar yang dominan pada diagonal utama, yaitu 942, 901, dan 968. Kesalahan klasifikasi relatif kecil dan terutama terjadi antara kelas meningioma dan pituitary, yang diduga memiliki kemiripan karakteristik citra MRI. Secara keseluruhan, hasil ini mengindikasikan kemampuan diskriminatif dan generalisasi model yang tinggi dalam mengklasifikasikan tumor otak.



Gambar 4. Confusion matrix ResNet50

3.5. Evaluasi Confusion Matrix MobileNetV2

Confusion matrix pada Gambar 5 menunjukkan performa model yang sangat baik dengan prediksi benar pada diagonal utama sebesar 933 (glioma), 878 (meningioma), dan 977 (pituitary). Kesalahan klasifikasi relatif kecil dan paling sering terjadi antara meningioma dan pituitary. Secara keseluruhan, hasil ini mengindikasikan kemampuan klasifikasi dan generalisasi model yang tinggi dalam membedakan ketiga jenis tumor otak.



Gambar 5 Confusion matrix MobileNetV2

3.6. Hasil Accuracy Validasi Tiap Fold

Berdasarkan hasil cross-validation lima lipatan, ResNet50 menunjukkan performa yang relatif stabil dengan nilai Accuracy berkisar antara 0.9117 hingga 0.9417, dengan nilai tertinggi pada Fold 3 (0.9417). Sementara itu, MobileNetV2 mencatat Accuracy antara 0.9150 hingga 0.9350, dengan performa terbaik pada Fold 2 (0.9350). Selain itu, nilai standard deviation dari K-Fold untuk ResNet50 dan MobileNetV2 masing-masing berada pada kisaran yang rendah (± 0.01), yang menunjukkan bahwa kedua model memiliki konsistensi dan stabilitas performa yang baik terhadap variasi data. Secara umum, ResNet50 cenderung menghasilkan Accuracy yang sedikit lebih tinggi pada sebagian besar fold, meskipun kedua model sama-sama memiliki kemampuan generalisasi yang baik, sebagaimana ditunjukkan pada Tabel 2.

Tabel 2 Hasil accuracy validasi tiap fold

Model	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
ResNet50	0.9233	0.9250	0.9417	0.9333	0.9117
MobileNetV2	0.9150	0.9350	0.9183	0.9200	0.9150

3.7. Hasil Penelitian pada Model

Berdasarkan hasil evaluasi kinerja model, ResNet50 menunjukkan performa yang sedikit lebih unggul dibandingkan MobileNetV2 dengan nilai Accuracy, Precision, Recall, dan F1-Score masing-masing sebesar 93,7%, sedangkan MobileNetV2 memperoleh 92.93% pada seluruh metrik evaluasi. Konsistensi nilai pada setiap metrik menunjukkan bahwa kedua model memiliki kemampuan klasifikasi yang seimbang antara ketepatan prediksi dan sensitivitas terhadap setiap kelas. Meskipun selisih performanya relatif kecil, ResNet50 terbukti lebih optimal dalam mengekstraksi fitur secara mendalam, sementara MobileNetV2 tetap menawarkan kinerja yang kompetitif dengan kompleksitas model yang lebih ringan, yang dapat dilihat pada Tabel 3.

Tabel 3 Hasil penelitian pada model


Model	Accuracy	Precision	Recall	F1-Score
ResNet50	93.7%	93.8%	93.7%	93.7%
MobileNetV2	92.93%	93.0%	92.9%	92.9%

3.8. Interpretasi Model Menggunakan XAI

Pada Gambar 6 menampilkan hasil visualisasi Grad-CAM yang dikombinasikan dengan bounding box pada citra MRI otak untuk menunjukkan area yang paling berkontribusi terhadap keputusan model klasifikasi. Warna merah dan kuning pada heatmap merepresentasikan tingkat aktivasi tertinggi, yang berarti wilayah tersebut memiliki pengaruh paling besar dalam proses prediksi model, sedangkan warna biru menunjukkan kontribusi yang rendah. Bounding box berwarna hijau digunakan untuk

menegaskan lokasi utama yang menjadi fokus perhatian model berdasarkan distribusi aktivasi Grad-CAM.

Pada ketiga contoh citra, terlihat bahwa area dengan intensitas warna merah terkonsentrasi di bagian tertentu dari struktur otak, yang mengindikasikan dugaan lokasi tumor atau kelainan jaringan. Konsistensi antara heatmap dan bounding box menunjukkan bahwa model mampu mengidentifikasi region of interest (ROI) secara relevan terhadap area abnormal pada citra MRI. Visualisasi ini memperkuat aspek interpretabilitas model karena tidak hanya menghasilkan prediksi kelas, tetapi juga memberikan bukti visual mengenai dasar pengambilan keputusan, sehingga meningkatkan transparansi dan potensi kepercayaan dalam aplikasi klinis.



Gambar 6 Interpretasi Grad-CAM pada ResNet50

3.9. Analisis Interpretasi XAI

Untuk meningkatkan transparansi dan interpretabilitas model klasifikasi tumor otak berbasis Convolutional Neural Network (CNN), penelitian ini menerapkan pendekatan Explainable Artificial Intelligence (XAI) menggunakan metode Gradient-weighted Class Activation Mapping (Grad-CAM). Metode ini memvisualisasikan area penting pada citra MRI yang berkontribusi terhadap keputusan model melalui representasi heatmap spesifik kelas. Hasil visualisasi menunjukkan bahwa model secara konsisten memfokuskan perhatian pada area tumor yang relevan secara diagnostik. Dengan demikian, penerapan Grad-CAM tidak hanya meningkatkan pemahaman terhadap mekanisme pengambilan keputusan model, tetapi juga memperkuat transparansi dan kepercayaan pengguna terhadap sistem klasifikasi berbasis deep learning dalam konteks pencitraan medis. Untuk mendukung evaluasi interpretabilitas secara lebih komprehensif, pendekatan kuantitatif seperti Intersection over Union (IoU) dapat digunakan untuk mengukur tingkat kesesuaian antara area yang diidentifikasi model dengan anotasi ground truth. Selain itu, analisis kualitatif (qualitative interpretability analysis) juga dilakukan dengan menilai secara visual kesesuaian heatmap terhadap lokasi tumor oleh ahli atau berdasarkan kriteria tertentu, sehingga memberikan pemahaman yang lebih terstruktur terhadap kemampuan model dalam menangkap pola yang relevan secara klinis.

3.10. Perbandingan dengan Penelitian Sebelumnya

Berdasarkan perbandingan penelitian yang telah dilakukan sebelumnya, model Support Vector Machine (SVM) pada dataset Kaggle mampu mencapai tingkat Accuracy sebesar 91% [18], sedangkan pendekatan Convolutional Neural Network (CNN) pada penelitian lain memperoleh Accuracy 92,97% [19]. Namun, kedua penelitian tersebut belum mengintegrasikan metode Explainable Artificial Intelligence (XAI) untuk menjelaskan proses pengambilan keputusan model.

Dalam penelitian ini, pendekatan yang diusulkan menggunakan arsitektur ResNet50 dan MobileNetV2 pada dataset yang sama, serta mengintegrasikan metode Grad-CAM sebagai teknik XAI untuk meningkatkan interpretabilitas model. Hasil eksperimen menunjukkan bahwa ResNet50

memperoleh Accuracy sebesar 93,7%, sedangkan MobileNetV2 mencapai Accuracy sebesar 92,93%. Integrasi Grad-CAM tidak hanya membantu memvisualisasikan area penting pada citra yang memengaruhi prediksi model, tetapi juga meningkatkan transparansi sistem, sehingga hasil klasifikasi dapat lebih mudah dipahami dan dipercaya dalam konteks aplikasi medis, yang terlihat pada Tabel 4.

Tabel 4 Perbandingan dengan penelitian sebelumnya

Peneliti	Model	Dataset	Accuracy	XAI
[18]	SVM	Kaggle	91%	-
[19]	CNN	Kaggle	92,97%	-
Usulan Kami	ResNet50	Kaggle	93,7%	Grad-CAM
Usulan Kami	MobileNetV2	Kaggle	92,93%	Grad-CAM

4. Kesimpulan

Penelitian ini bertujuan meningkatkan transparansi model klasifikasi tumor otak berbasis CNN melalui integrasi metode XAI, yaitu Grad-CAM. Hasil visualisasi heatmap menunjukkan area citra MRI yang paling berkontribusi terhadap prediksi model, sehingga meningkatkan interpretabilitas dan kepercayaan dalam konteks klinis. Berdasarkan eksperimen, ResNet50 memperoleh performa terbaik dengan Accuracy 93,7%, sedangkan MobileNetV2 mencapai 92,93%. ResNet50 unggul dalam ekstraksi fitur yang lebih mendalam, sementara MobileNetV2 menawarkan efisiensi komputasi dengan performa yang tetap kompetitif. Penerapan cross-validation juga terbukti meningkatkan generalisasi model dan mengurangi risiko overfitting. Penelitian ini masih terbatas pada dataset publik dan belum diuji pada data klinis nyata. ResNet50 direkomendasikan untuk sistem klasifikasi dengan fokus pada Accuracy tinggi, sedangkan MobileNetV2 sesuai untuk implementasi pada perangkat dengan keterbatasan sumber daya. Penelitian selanjutnya disarankan memperluas dataset serta mengeksplorasi arsitektur CNN lain guna meningkatkan robustnes dan Accuracy model dalam kondisi klinis nyata.

Referensi

- [1] A. Amila, E. Sembiring, A. S. Marbun, P. A. Samosir, A. Hia, and W. E. M. Purba, "Edukasi Deteksi Dini dan Pencegahan Tumor Otak pada Anak dan Remaja," *Jurnal Abdimas Mutiara*, Vol. 6, No. 1, pp. 169–175, 2025.
- [2] U. Sandhya, "Brain Tumor Detection and Classification with DGMM – RBCNN Technique," *International Journal of Health Sciences*, Vol. 6, No. April, pp. 7345–7361, 2022, DOI: 10.53730/ijhs.v6nS1.6911.
- [3] M. S. Mithun and S. J. Jawhar, "Journal of Radiation Research and Applied Sciences Detection and Classification on MRI Images of Brain Tumor using YOLO NAS Deep Learning Model," *J. Radiat. Res. Appl. SCI.*, Vol. 17, No. 4, p. 101113, 2024, DOI: 10.1016/j.jrras.2024.101113.
- [4] V. Le, T. Pham, and C. Author, "Ovarian Tumors Detection and Classification on Ultrasound Images using One-Stage Convolutional Neural Networks," *J. Rob. Control*, Vol. 5, No. 2, pp. 561–581, 2024, DOI: 10.18196/jrc.v5i2.20589.
- [5] M. Aamir et al., "Brain Tumor Detection and Classification using an Optimized Convolutional Neural Network," 2024.
- [6] B. S. Shukur and M. M. Mijwil, "Involving Machine Learning Techniques in Heart Disease Diagnosis : A Performance Analysis," *Int. J. Electr. Comput. Eng.*, Vol. 13, No. 2, pp. 2177–2185, 2023, DOI: 10.11591/ijece.v13i2.pp2177-2185.
- [7] D. P. Mawardi, M. Novita, N. D. Saputro, "Deteksi Awal Klasifikasi Jenis Penyakit Kanker Kulit dengan Algoritma Convolutional Neural Network (CNN) berbasis Mobile Apps," *Adopsi Teknol. dan Sist. Inf.*, Vol. 3, No. 2, pp. 1–6, 2024, DOI: 10.30872/atasi.v3i2.2305.
- [8] I. G. L. Yudha, N. A. Sanjaya ER, A. A. I. N. E. Karyawati, I. B. G. Dwidasmara, I. G. N. A. C. Putra, and I. B. M. Mahendra, "Article Classification using Convolutional Neural Network (CNN) and Chi-Square Feature Selection," *JELIKU (Jurnal Elektron. Ilmu Komput.*

<http://sistemasi.ftik.unisi.ac.id>

- Udayana), Vol. 11, No. 3, p. 529, 2022, DOI: 10.24843/jlk.2023.v11.i03.p08.
- [9] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, Vol. 2016-Decem, pp. 770–778, 2016, DOI: 10.1109/CVPR.2016.90.
- [10] M. Sandler, G. Inc, and L.-C. C. , Andrew Howard, Menglong Zhu, Andrey Zhmoginov, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," IEEE Access. Accessed: Feb. 12, 2025. [Online]. Available: <https://ieeexplore.ieee.org/document/8578572/metrics#metrics>
- [11] Q. A. Fitroh and S. Uyun, "Pembelajaran Transfer mendalam untuk meningkatkan Klasifikasi Akurasi Gambar Dermoskopi Kanker Kulit," *J. Nas. Tek. Elektro dan Teknol. Inf.*, Vol. 12, pp. 78–84, 2023, DOI: 10.22146/jnteti.v12i2.6502.
- [12] I. Mudzakir and T. Arifin, "Klasifikasi Penggunaan Masker dengan Convolutional Neural Network menggunakan Arsitektur MobileNetv2," *Expert J. Manaj. Sist. Inf. dan Teknol.*, Vol. 12, No. 1, p. 76, 2022, DOI: 10.36448/expert.v12i1.2466.
- [13] U. Multi, D. Palembang, J. Rajawali, and N. Palembang, "Klasifikasi Kanker Kulit pada Citra Dermatoskopi menggunakan CNN 1,2," Vol. 5, No. 1, 2024, DOI: 10.35957/algorithmexxxx.
- [14] I. Xai, A. L. Review, D. Nasien, M. H. Adiya, and D. Willeam, "Journal of Applied Business and Technology Increasing Trust in AI with Explainable Artificial," Vol. 5, No. 3, pp. 230–237, 2024.
- [15] L. Gilpin, L. H., Bau, D., Yuan, B. Z., Bajwa, A., Specter, M., & Kagal, "Explaining Explanations: An Overview of Interpretability of Machine Learning," *Proc. - 2018 IEEE 5th Int. Conf. Data SCI. Adv. Anal. DSAA 2018*, pp. 80–89, 2018, [Online]. Available: <https://doi.org/10.1109/DSAA.2018.00018>
- [16] I. R. Putra, Zulrahmadi, A. Swandi, Yulia, and T.D. Putri, "Enhanced Classification of Brain MRI Images for Tumor Detection using Transfer Learning and Grad-CAM-based Explainable Convolutional Neural Network (CNN)," *J. ICT Apl. Syst.*, Vol. 4, No. 2, pp. 76–88, 2025, DOI: 10.56313/jictas.v4i2.454.
- [17] T. A. M and Q. N. Azizah, "Klasifikasi Tumor Otak menggunakan Ekstraksi Fitur HOG dan Support Vector Machine," *J. Khatulistiwa Inform.*, Vol. 4, No. 1, pp. 45–50, 2022, [Online]. Available: <https://www.neliti.com/publications/491268/>
- [18] M. Farhan, A. F. Fuady, D. O. Amsyah, and D. A. Aptanta, "Implementasi CNN Resnet50 untuk Klasifikasi dan Prediksi Tumor Otak pada Citra MRI menggunakan MATLAB," *J. Ilmu Komput. dan Tek. Inform. I*, Vol. 2, No. 1, pp. 98–107, 2026, DOI: 10.64803/juikti.v2i1.113.
- [19] M. M. Mohamed, T. R. Mahesh, V. V. Kumar, and G. Suresh, "Enhancing Brain Tumor Detection in MRI Images through Explainable AI using Grad-CAM with Resnet 50," *BMC Med. Imaging*, Vol. 24, No. 1, p. 201, 2024, DOI: 10.1186/s12880-024-01292-7.
- [20] Md Imran Nazir, Afsana Akter, Md Anwar Hussen Wadud. Md Ashraf Uddin, "Utilizing Customized CNN for Brain Tumor Prediction with Explainable AI", *Heliyon*, Vol. 10, No. 20, Art. no. e38997, 2024, DOI: 10.1016/j.heliyon.2024.e38997.
- [21] Francesco Mercaldo, Luca Brunese, Fabio Martinelli, "Explainable Convolutional Neural Networks for Brain Cancer Detection and Localisation," *Sensors*, Vol. 23, No. 17, Art. No. 7614, DOI: 10.3390/s23177614.