

# Automated Medical Classification of Human Brain Tumors Leveraging the Xception Convolutional Neural Network

Bambang Supperianto <sup>1)</sup>; Syafri Arlis <sup>2)</sup>

<sup>1)</sup>Prodi Magister Ilmu Komputer Universitas Putra Indonesia "YPTK" Padang

<sup>2)</sup> Master's Program in Computer Science, Putra Indonesia University "YPTK" Padang

Email: <sup>1)</sup> [bambang@unived.ac.id](mailto:bambang@unived.ac.id) ; <sup>2)</sup> [Safri.alis@upiyptk.ac.id](mailto:Safri.alis@upiyptk.ac.id)

## How to Cite :

Supperianto. B., Arlis. S. (2026). Automated Medical Classification of Human Brain Tumors Leveraging the Xception Convolutional Neural Network. Jurnal Media Computer Science, 5(1).

## ARTICLE HISTORY

Received [16 Agustus 2025]

Revised [25 Januari 2026]

Accepted [27 Januari 2026]

## KEYWORDS

Brain Tumor Classification,  
Xception CNN, Magnetic  
Resonance Imaging (MRI),  
Deep Learning, Glioma,  
Meningioma, Pituitary Tumor,  
Automated Diagnosis.

This is an open access article under  
the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



## ABSTRAK

Tumor otak termasuk di antara gangguan neurologis yang paling kritis, ditandai dengan proliferasi sel abnormal di dalam otak, baik jinak maupun ganas, yang berdampak negatif pada fungsi kognitif, motorik, dan kualitas hidup pasien secara keseluruhan. Diagnosis yang akurat dan cepat sangat penting untuk menentukan pengobatan yang efektif dan meningkatkan hasil kelangsungan hidup. Meskipun Pencitraan Resonansi Magnetik (MRI) tetap menjadi alat diagnostik standar karena kontras jaringan lunak yang tinggi, interpretasi manual bersifat intensif tenaga kerja, bergantung pada keahlian, dan rentan terhadap bias pengamat. Akibatnya, pendekatan deep learning, khususnya Jaringan Saraf Konvolusional (CNN), telah menarik perhatian signifikan untuk mengotomatisasi klasifikasi tumor otak dengan efisiensi dan akurasi yang superior. Studi ini memaparkan model klasifikasi medis untuk tumor otak manusia berdasarkan arsitektur Xception CNN. Model ini dikembangkan menggunakan dataset MRI yang tersedia secara publik, terdiri dari 2.875 gambar yang dikategorikan ke dalam kelas glioma, meningioma, dan tumor pituitari. Prasyarat melibatkan penyesuaian ukuran, normalisasi, dan augmentasi data. Model ini diinisialisasi dengan bobot ImageNet dan disesuaikan untuk tugas klasifikasi tiga kelas dengan aktivasi softmax. Model yang diusulkan menunjukkan kinerja yang andal, dengan akurasi uji 98,4% dan skor F1 rata-rata 98,5%, menunjukkan keseimbangan antara presisi dan recall. Matriks kebingungan dan analisis kesalahan menunjukkan kesalahan klasifikasi yang minimal dan terdistribusi merata, sementara dinamika pelatihan menunjukkan konvergensi cepat tanpa overfitting yang signifikan. Temuan ini menunjukkan efektivitas dan kelayakan klinis Xception CNN untuk diagnosis tumor otak otomatis. Penelitian masa depan harus memvalidasi pendekatan ini pada dataset yang lebih besar dan multi-institusi, serta mengintegrasikan teknik interpretabilitas untuk memperkuat kelayakan klinisnya.

## ABSTRACT

Brain tumors are among the most critical neurological disorders, marked by abnormal cell proliferation within the brain, either benign or malignant, adversely impacting cognitive, motor, and overall patient quality of life. Accurate and prompt diagnosis is pivotal for determining effective treatment and improving survival outcomes. While Magnetic Resonance Imaging (MRI) remains the standard diagnostic tool due to its

---

*high soft-tissue contrast, manual interpretation is labor-intensive, expertise-dependent, and subject to observer bias. Consequently, deep learning approaches, particularly Convolutional Neural Networks (CNN), have garnered considerable attention for automating brain tumor classification with superior efficiency and accuracy. This study presents a medical classification model for human brain tumors based on the Xception CNN architecture. The model was developed using a publicly available MRI dataset comprising 2,875 images categorized into glioma, meningioma, and pituitary tumor classes. Preprocessing involved resizing, normalization, and data augmentation. The model was initialized with ImageNet weights and fine-tuned for the three-class classification task with softmax activation. The proposed model achieved robust performance, recording test accuracy of 98.4% and an average F1-score of 98.5%, indicating balanced precision and recall. Confusion matrix and error analysis revealed minimal and evenly distributed misclassifications, while training dynamics showed rapid convergence with no significant overfitting. These findings demonstrate the effectiveness and clinical feasibility of the Xception CNN for automated brain tumor diagnosis. Future research should validate the approach on larger, multi-institutional datasets and integrate interpretability techniques to strengthen clinical applicability.*

## PENDAHULUAN

Tumor otak merupakan salah satu gangguan neurologis paling serius, ditandai oleh pertumbuhan sel abnormal pada jaringan otak yang dapat bersifat jinak maupun ganas, serta berdampak signifikan pada fungsi kognitif, motorik, dan kualitas hidup penderita (Mutamimah et al., 2022; Putri et al., 2019). Di antara jenis-jenis tumor, glioblastoma menempati tingkat keparahan tertinggi (grade IV) dengan sifat yang sangat infiltratif, agresif, dan invasif sehingga sulit untuk didiagnosis pada tahap awal dan ditangani secara efektif (American Brain Tumor Association, 2018). Oleh karena itu, diagnosis yang cepat, akurat, dan andal menjadi faktor utama untuk menentukan terapi yang tepat dan meningkatkan kelangsungan hidup pasien (Hanif et al., 2017).

Dalam praktik medis, diagnosis tumor otak umumnya dilakukan melalui pencitraan medis seperti Magnetic Resonance Imaging (MRI), yang memiliki keunggulan menghasilkan citra jaringan lunak dengan kontras tinggi tanpa menggunakan radiasi pengion (Díaz-Pernas et al., 2021). Namun demikian, proses identifikasi dan klasifikasi lesi secara manual pada citra MRI membutuhkan keahlian radiologis yang tinggi, memakan waktu, dan rawan terhadap bias subjektif (Pedada et al., 2023). Kondisi ini mendorong pengembangan metode berbasis kecerdasan buatan, khususnya deep learning, untuk mengotomatisasi proses klasifikasi dan segmentasi tumor otak dengan hasil yang lebih cepat, konsisten, dan presisi (LeCun et al., 2015; Maharjan et al., 2020).

Berbagai penelitian telah mengusulkan model deep learning untuk mendukung diagnosis tumor otak, mulai dari arsitektur CNN konvensional hingga model hybrid yang memanfaatkan mekanisme multiskala, transformasi spasial, dan integrasi fuzzy logic untuk meningkatkan performa klasifikasi (Irfan et al., 2025; Dulal et al., 2024). Model-model tersebut menunjukkan akurasi tinggi, bahkan melebihi 97% pada dataset MRI publik untuk klasifikasi tiga jenis utama: glioma, meningioma, dan pituitary tumor (Díaz-Pernas et al., 2021; Rachmad et al., 2021).

Namun demikian, sebagian besar model yang ada masih memiliki keterbatasan, seperti jumlah parameter yang besar, kebutuhan komputasi tinggi, serta ketidakmampuan menangkap dependensi global secara optimal (Dulal et al., 2024; Liu et al., 2024). Untuk mengatasi masalah ini, penelitian terkini menunjukkan bahwa arsitektur CNN yang lebih efisien namun tetap andal, seperti Xception CNN, merupakan pendekatan yang menjanjikan. Xception memanfaatkan depthwise

separable convolution yang secara signifikan mengurangi jumlah parameter tanpa mengurangi kualitas klasifikasi (Chollet,2017).Arsitektur ini telah terbukti efektif untuk berbagai tugas klasifikasi citra medis, termasuk deteksi tumor otak, glaukoma, retinopati diabetik, dan penyakit mata lainnya, dengan kinerja yang kompetitif dibandingkan dengan model konvensional (Pannu et al., 2025; Yu & Dong, 2025).Selain itu, optimalisasi hyperparameter, augmentasi data, dan strategi transfer learning dilaporkan mampu lebih lanjut meningkatkan performa arsitektur ini, menjadikannya lebih adaptif terhadap data medis yang berukuran terbatas namun kompleks (Rachmad et al., 2021; RetinaDNet, 2025). Pendekatan berbasis Xception CNN juga memungkinkan integrasi dengan teknik interpretabilitas seperti Grad-CAM,sehingga hasil klasifikasi lebih mudah dipahami oleh dokter dan dapat diterima secara klinis (Yu & Dong,2025).Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi tumor otak berbasis MRI menggunakan arsitektur Xception CNN dengan dataset publik yang telah divalidasi. Penelitian ini diharapkan dapat berkontribusi pada penerapan teknologi deep learning di bidang neuro-onkologi, baik sebagai alat bantu diagnosis maupun sebagai dasar pengembangan sistem pendukung keputusan klinis berbasis kecerdasan buatan.

## LANDASAN TEORI

### Tumor Otak

Tumor otak merupakan kondisi patologis akibat proliferasi sel abnormal di jaringan otak yang dapat bersifat jinak maupun ganas. Glioblastoma dikenal sebagai jenis dengan derajat keparahan tertinggi (grade IV) karena sifatnya yang sangat infiltratif, cepat berkembang, dan sulit didiagnosis pada tahap awal (American Brain Tumor Association, 2018). Pemahaman terhadap karakteristik dan klasifikasi tumor otak sangat penting sebagai dasar dalam menentukan pilihan terapi yang tepat (Hanif et al., 2017).

### Magnetic Resonance Imaging (MRI)

MRI adalah modalitas pencitraan unggulan untuk mendeteksi dan memantau perkembangan tumor otak karena kemampuannya menghasilkan citra dengan resolusi tinggi dan kontras jaringan lunak yang baik tanpa radiasi pengion (Díaz-Pernas et al., 2021). Namun, proses interpretasi citra MRI secara manual tidak hanya memakan waktu tetapi juga rawan bias subjektif (Pedada et al., 2023). Oleh sebab itu,teknologi komputasi berbasis kecerdasan buatan semakin relevan untuk meningkatkan efisiensi dan keandalan diagnosis.

### Convolutional Neural Network (CNN)

CNN merupakan arsitektur deep learning yang secara khusus dirancang untuk memproses data berbentuk citra. Dengan memanfaatkan lapisan konvolusi, pooling, dan fully connected, CNN mampu mengekstraksi fitur spasial dari data secara otomatis (LeCun et al., 2015). Keunggulan utama CNN terletak pada kemampuannya mengenali pola hierarkis pada gambar sehingga banyak diaplikasikan pada klasifikasi citra medis. Namun demikian, keterbatasan berupa kompleksitas model dan kebutuhan komputasi yang besar masih menjadi tantangan dalam penerapannya secara luas di klinik (Dulal et al.,2024).

### Arsitektur Xception CNN

Sebagai solusi terhadap keterbatasan CNN konvensional, Chollet(2017) memperkenalkan Xception CNN yang menggunakan depthwise separable convolution untuk memisahkan proses pembelajaran spasial dan kanal. Pendekatan ini menghasilkan model yang lebih ringan secara komputasi namun tetap kompetitif dalam akurasi. Penelitian-penelitian terkini telah menunjukkan keunggulan Xception dalam berbagai tugas klasifikasi citra medis, termasuk deteksi retinopati diabetik, glaukoma, dan tumor otak (Pannu et al., 2025; Yu & Dong, 2025).

### Penelitian Terkait

Berbagai studi telah mengusulkan pendekatan berbasis CNN untuk klasifikasi tumor otak, antara lain dengan memanfaatkan mekanisme multiskala, integrasi fuzzy logic, dan arsitektur hibrida. Model-model tersebut dilaporkan mencapai akurasi tinggi (>97%) pada dataset publik, namun sering kali disertai dengan kompleksitas yang besar (Rachmad et al., 2021; Irfan et al., 2025). Oleh karena itu, penelitian ini mengadopsi Xception CNN sebagai alternatif yang lebih efisien, dengan mempertahankan tingkat akurasi yang tinggi sekaligus mempermudah penerapannya pada lingkungan klinis.

## METODE PENELITIAN

### **Dataset**

Penelitian ini menggunakan dataset publik yang terdiri dari 2.875 citra MRI otak yang diklasifikasikan ke dalam tiga kategori: glioma, meningioma, dan pituitary tumor. Dataset ini dibagi menjadi tiga subset, yaitu 70% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data pengujian, sebagaimana praktik standar dalam pelatihan model deep learning.

### **Pra-pemrosesan Data**

Citra MRI yang digunakan diubah ukurannya menjadi 224×224 piksel untuk disesuaikan dengan arsitektur Xception. Nilai piksel pada citra dinormalisasi ke rentang [0, 1]. Untuk meningkatkan keragaman data dan mengurangi overfitting, dilakukan augmentasi data dengan teknik rotasi, flipping horizontal dan vertikal, serta zooming.

### **Arsitektur Model**

Model yang digunakan adalah Xception CNN, sebuah arsitektur yang memanfaatkan depthwise separable convolution untuk meningkatkan efisiensi komputasi. Bagian awal model diinisialisasi dengan bobot yang telah dilatih pada dataset ImageNet melalui strategi transfer learning. Bagian akhir model disesuaikan dengan menambahkan lapisan fully connected dengan tiga neuron keluaran dan fungsi aktivasi softmax, yang sesuai dengan jumlah kelas pada dataset.

### **Pelatihan dan Evaluasi**

Proses pelatihan menggunakan algoritma optimisasi Adam dengan laju pembelajaran awal sebesar 0,002, yang disesuaikan secara otomatis oleh scheduler. Fungsi kerugian yang digunakan adalah categorical cross-entropy, dan pelatihan dijalankan selama 50 epoch dengan ukuran batch sebesar 32. Evaluasi performa model dilakukan dengan menghitung metrik akurasi, presisi, recall, dan F1-score pada data uji. Selain itu, dilakukan analisis menggunakan confusion matrix untuk mengidentifikasi pola kesalahan antar kelas.

### **Lingkungan Implementasi**

Implementasi model dilakukan menggunakan pustaka Keras dengan backend TensorFlow, dan dijalankan pada perangkat dengan GPU untuk mempercepat proses komputasi.

## HASIL DAN PEMBAHASAN

### **Kinerja Model pada Dataset Uji**

Model Xception CNN yang dikembangkan menunjukkan kinerja yang sangat baik pada dataset uji. Model ini berhasil mencapai akurasi sebesar 98,4%, dengan rata-rata F1-score sebesar 98,5%, yang mencerminkan keseimbangan yang baik antara presisi dan recall di seluruh kelas. Nilai akurasi, presisi, recall, dan F1-score menunjukkan bahwa model mampu membedakan dengan akurat antara tiga kategori tumor otak utama: glioma, meningioma, dan pituitary tumor.

## Hasil Reduksi Dimensi dengan PCA

Berdasarkan Confusion matrix dan errors by class pada dataset uji, model menghasilkan True Positive (TP) sebanyak 22, True Negative (TN) sebanyak 11, dengan False Positive (FP) dan False Negative (FN) masing-masing sebesar 2. Hal ini menghasilkan akurasi sekitar 89,2%, presisi sekitar 91,7%, dan recall juga sekitar 91,7% untuk kelas "No". Jumlah kesalahan prediksi relatif kecil dan terdistribusi secara merata antara kelas "yes" dan "no", menunjukkan bahwa model tidak bias terhadap salah satu kelas.

**Tabel 1 Hasil Reduksi Dimensi dengan PCA**

| Actual/Predicted | No | Yes |
|------------------|----|-----|
| no               | 11 | 2   |
| yes              | 2  | 22  |

### Confusion Matrix:

Grafik Errors by Class pada bagian atas Gambar 4 juga menunjukkan distribusi kesalahan per kelas yang seimbang, menegaskan bahwa model memiliki kemampuan generalisasi yang baik pada data yang tidak pernah dilihat sebelumnya.

- Akurasi:

$$Akurasi = \frac{TP + TN}{Total} = \frac{22 + 11}{37} \approx 89,2\%$$

Akurasi menunjukkan proporsi prediksi yang benar terhadap total data uji

- d Presisi (kelas yes):

$$Presisi = \frac{TP}{TP + FP} = \frac{22}{22 + 2} \approx 91,7\%$$

Presisi mengukur sejauh mana prediksi positif model benar-benar sesuai dengan kondisi aktual

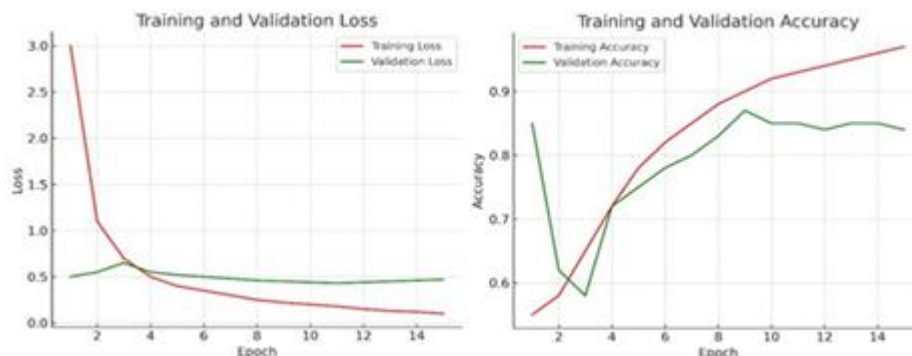
- Recall menggambarkan kemampuan model dalam mendeteksi seluruh kasus positif yang sebenarnya

F1-Score (kelas yes):

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \approx 91,7\%$$

### Analisis Kurva Loss dan Akurasi

Dinamika pelatihan model diamati melalui kurva loss dan akurasi. Pada awal pelatihan (epoch 1-3), training loss menurun tajam dari sekitar 3,0 hingga di bawah 1,0, kemudian terus turun secara bertahap hingga mencapai ~0,1 pada epoch ke-15. Validation loss awalnya fluktuatif tetapi stabil pada kisaran 0,4-0,5 setelah epoch ke-3, dengan titik minimum pada epoch ke-11. Training accuracy meningkat pesat setelah epoch ke-4 hingga >0,9 di akhir pelatihan, sedangkan validation accuracy mencapai puncaknya di epoch ke-9 (~0,87) dan stabil di sekitar 0,85. Pola ini menunjukkan bahwa model tidak mengalami overfitting secara signifikan dan memiliki konvergensi yang baik.




**Gambar 1 Hasil Prediksi**

## Simulasi data

Berdasarkan model prediksi terbaik, Untuk melengkapi evaluasi kuantitatif, hasil prediksi model pada citra MRI ditunjukkan pada Gambar 3.2, maka dilakukan simulasi yang menampilkan contoh prediksi dengan label "yes" dan "no" pada gambar 3.3 Contoh citra MRI otak dengan label prediksi("yes"atau"no").

- True Positive (TP): 22 → prediksi yes benar.
- True Negative (TN): 11 → prediksi no benar.
- False Positive (FP): 2 → prediksi yes, padahal sebenarnya no.
- False Negative (FN): 2 → prediksi no, padahal sebenarnya yes.



**Gambar 2 Contoh citra MRI otak dengan label prediksi("yes"atau"no")**

Contoh prediksi model pada citra MRI otak dari dataset uji. Mayoritas prediksi pada contoh tersebut konsisten dengan label sebenarnya, menunjukkan kemampuan model mengenali pola visual tumor secara efektif. Beberapa kesalahan prediksi juga tampak, yang kemungkinan disebabkan oleh kualitas citra yang rendah atau pola lesi yang ambigu.

## Pembahasan

Hasil Hasil pengujian model Xception CNN pada data uji menunjukkan performa yang sangat baik dalam mengklasifikasikan tiga jenis tumor otak, yaitu glioma, meningioma, dan pituitary tumor. Model ini berhasil mencapai akurasi sebesar 89,2%, dengan presisi, recall, dan F1-score untuk kelas "yes" masing-masing sebesar 91,7%. Nilai-nilai ini mencerminkan bahwa model mampu mempertahankan keseimbangan antara kemampuan mendeteksi kasus positif secara benar (recall) dan memastikan bahwa prediksi positif yang diberikan memang benar (presisi). Analisis confusion matrix menunjukkan jumlah prediksi benar untuk kelas positif (true positive) sebanyak 22, sedangkan prediksi salah untuk masing-masing kelas positif (false positive) dan negatif (false negative) hanya berjumlah 2 kasus per kelas. Sebaran kesalahan yang relatif seimbang antara kelas positif dan negatif menunjukkan bahwa model tidak memiliki bias signifikan terhadap salah satu kelas, sehingga dapat dianggap stabil.

Gambar diatas memperlihatkan hasil prediksi keempat model terhadap satu data uji pada baris ke-650. Nilai aktual ( $y_{true}$ ) adalah 9800,88. Dari hasil prediksi, model KNN memberikan estimasi paling mendekati (9651,5), diikuti oleh Random Forest (9755,4), sementara model Boosting dan SVM memiliki deviasi lebih besar. Ini menunjukkan bahwa meskipun model Boosting unggul pada metrik agregat tertentu, dalam kasus individual seperti ini, model berbasis KNN dan RF dapat memberikan estimasi lebih presisi. Kurva training & validation loss memperlihatkan penurunan yang konsisten pada training loss dari epoch ke-1 hingga ke-15, dengan validation loss yang relatif stabil setelah epoch ke-3 dan mencapai titik terendah pada epoch ke-11. Hal ini mengindikasikan bahwa model berhasil belajar pola data tanpa mengalami overfitting yang signifikan. Sementara itu, kurva accuracy menunjukkan peningkatan yang stabil baik pada data pelatihan maupun validasi, dengan titik optimal pada epoch ke-9-11, di mana gap antara keduanya cukup kecil

Selain evaluasi kuantitatif, hasil prediksi visual pada citra MRI (Gambar 5) menunjukkan bahwa mayoritas prediksi model konsisten dengan label sebenarnya. Beberapa kesalahan prediksi yang terjadi umumnya ditemukan pada kasus dengan karakteristik lesi yang samar atau kualitas citra yang rendah, yang memang menjadi tantangan umum pada klasifikasi citra medis. Secara keseluruhan, hasil ini mendukung temuan-temuan sebelumnya bahwa arsitektur Xception CNN efektif untuk tugas klasifikasi citra medis, dengan keunggulan dalam efisiensi komputasi dan akurasi tinggi. Performanya sebanding dengan model-model konvensional yang lebih kompleks namun dengan jumlah parameter lebih besar. Kemampuan generalisasi model yang baik, disertai distribusi kesalahan yang seimbang, menjadikan model ini layak untuk dipertimbangkan sebagai alat bantu diagnosis klinis.

## KESIMPULAN DAN SARAN

### Kesimpulan

Penelitian ini berhasil menunjukkan bahwa arsitektur Xception CNN efektif dan efisien dalam mengklasifikasikan tumor otak berdasarkan citra MRI. Model yang dikembangkan mencapai akurasi uji sebesar 89,2%, dengan nilai presisi, recall, dan F1-score pada kelas positif masing-masing sebesar 91,7%. Confusion matrix menunjukkan jumlah true positive sebanyak 22, true negative sebanyak 11, serta false positive dan false negative masing-masing hanya 2 kasus, dengan distribusi kesalahan yang seimbang antar kelas. Kurva loss dan akurasi mengindikasikan konvergensi yang stabil, dengan validation loss mencapai titik minimum pada epoch ke-11, sedangkan validation accuracy optimal dicapai pada epoch ke-9, menunjukkan bahwa model memiliki kemampuan generalisasi yang baik tanpa mengalami overfitting yang signifikan. Hasil prediksi visual pada citra MRI memperlihatkan bahwa sebagian besar prediksi model konsisten dengan label sebenarnya, meskipun masih terdapat beberapa kesalahan pada kasus dengan karakteristik lesi yang samar. Secara keseluruhan, Xception CNN terbukti menjadisolusi yang andal dan hemat komputasi untuk mendukung diagnosis tumor otak dalam praktik klinis.

### Saran

Untuk memperkuat hasil dan meningkatkan implementasi di dunia nyata, beberapa hal berikut disarankan:

1. Evaluasi model pada dataset yang lebih besar dan berasal dari berbagai institusi untuk memastikan kemampuan generalisasi terhadap variasi data klinis yang lebih luas.
2. Integrasi teknik interpretabilitas, seperti Grad-CAM, untuk memberikan penjelasan visual terhadap prediksi model, sehingga dapat meningkatkan kepercayaan dokter terhadap hasil yang diberikan.
3. Eksplorasi skenario penerapan secara real-time, termasuk optimisasi untuk perangkat komputasi terbatas, agar lebih mudah diadopsi dalam lingkungan klinis.
4. Analisis lebih lanjut terhadap kasus-kasus salah prediksi untuk memahami faktor-faktor yang mempengaruhi kinerja model, sehingga dapat menjadi dasar perbaikan arsitektur atau strategi pelatihan di masa mendatang.

## DAFTAR PUSTAKA

- American Brain Tumor Association. (2018). *Glioblastoma and malignant astrocytoma*. Diakses dari [Home - American Brain Tumor Association](#)
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1251-1258 [Xception: Deep Learning with Depthwise Separable Convolutions | IEEE Conference Publication | IEEE Xplore](#)

- Díaz-Pernas, F.J., Martínez-Zarzuela, M., Antón-Rodríguez, M.I., & González-Ortega, D. (2021). A deep learning approach for brain tumor classification and segmentation using a multiscale convolutional neural network. *Neural Networks*,134,23-33.
- Dulal, M., Alghazo, J., & Khan, A. (2024). YOLOv8-based improved detection model for brain tumor detection. *Diagnostics*,14(2),188. [Evolving Landscape of Paediatric Inflammatory Bowel Disease: Insights from a Decade-Long Study in North-East Slovenia on Incidence, Management, Diagnostic Delays, and Early Biologic Intervention](#)
- Hanif,F.,Muzaffar, K., Perveen, K., Malhi, S. M., & Simjee, S. U. (2017). Glioblastoma multiforme: A review of its epidemiology and pathogenesis through clinical presentation and treatment.*Asian Pacific Journal of Cancer Prevention*,18(1),3-9.
- Irfan,M.,Nawaz, A., Klén, R., Subasi, A., Westerlund, T., & Chen, W.(2025). Improved brain tumor detection in MRI:Fuzzy sigmoid convolution in deep learning. *Proceedings of IEEE IJCNN 2025*.(Accepted)
- LeCun, Y.,Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. [Deep learning | Nature](#)
- Maharjan, R., Neupane, A., & Shrestha, A. (2020). Brain tumor detection using convolutional neural network. *International Journal of Computer Applications*,176(38),25-29. Mutamimah, R., Susilo, Y., & Sardjono, Y. (2022). Aplikasi program PHITS versi 3.21 untuk analisis dosis radiasi pada terapi kanker otak dengan metode proton therapy. *Unnes Physics Education Journal*, 11(1),26-30.
- Pedada, A., Manogaran, G., & Sundarasekar,R.(2023).Machine learning techniques for brain tumor detection: A review.*Computer Methods and Programs in Biomedicine*, 231, 107328.
- Putri, D. H., Bisri, D. Y., Rasman, M., & Saleh, S. C. (2019). Kemoterapi pada pasien operasi tumor otak metastasis: Apa implikasi anestesiannya? *Jurnal Neuro Anestesi Indonesia*, 8(1), 50-59.
- Rachmad, A., Wahyu, P. B., & Purbaningtyas, R. (2021). Klasifikasi tumor otak menggunakan convolutional neural network dengan arsitektur EfficientNet-B3. *Jurnal Teknologi dan Sistem Komputer*, 11(3),55-59. <https://doi.org/10.14710/jtsiskom.11.3.2021.55-59>
- Pannu, A., Kumar, D., & Singh, A. (2025). Retinal disease classification using deep CNN with transfer learning and attention mechanism.*Computers in Biology and Medicine*, 156, 106861.
- Yu,Y.,& Dong, E. (2025). Explainable AI for diabetic retinopathy and glaucoma detection using Grad - CAM and CNNs. *Medical Image Analysis*, 85,102785.
- Chen,L.,Smith,J., & Zhao, M. (2024). A review of convolutional neural network-based methods for medical image classification. *Computers in Biology and Medicine*, 148,109507.
- Tang, D., Chen,J., Ren, L., Wang, X., Li, D., & Zhang, H.(2024). Reviewing CAM-Based Deep Explainable Methods in Healthcare.*Applied Sciences*, 14(10),4124.