



DETEKSI DINI TERHADAP PENYAKIT TUMOR OTAK MENGGUNAKAN CITRA MAGNETIK RESONANCE IMAGING (MRI) DENGAN PENDEKATAN DEEP CONVOLUTIONAL NEURAL NETWORK

Muhamad Salman¹⁾, Rudi Kurniawan²⁾, Bunga Intan³⁾, Budi Santoso⁴⁾

¹ Program Studi Informatika, Universitas Bina Insan

² Program Studi Informatika, Universitas Bina Insan

³ Program Studi Informatika, Universitas Bina Insan

⁴ Program Studi Informatika, Universitas Bina Insan

email: ¹ 2102020057@mhs.univbinainsan.ac.id, ² rudi.kurniawan@univbinainsan.ac.id,

³ bungaintan@univbinainsan.ac.id, ⁴ budisantoso@univbinainsan.ac.id

ARTICLE INFO

Article History:

Received : 8 Mei 2025

Accepted : 27 Mei 2025

Published : 10 Juli 2025

Keywords:

Tumor Otak

MRI

DCNN

ResNet52V2

IEEE style in citing this article:

M. Salman, R. Kuriawan, B. Intan, B. Santoso, "Judul Artikel", Nama Jurnal, vol. 10, no. 1, pp. 37-42, Jul. 2025.

ABSTRACT

This study aims to develop an early detection system for brain tumors using MRI images with a Deep Convolutional Neural Network (DCNN) based on the ResNet152V2 architecture. Rapid detection of brain tumors is crucial for improving recovery chances; however, manual processes often face challenges due to limitations in technology and medical expertise. Therefore, this research offers an automated solution for analyzing MRI images. The methods used include data collection from public datasets, image preprocessing, and training the DCNN model. The ResNet152V2 model was chosen for its ability to address the vanishing gradient problem and its effectiveness in feature extraction. The results show that the model achieved an accuracy of 92.38% in classifying four types of brain tumors: Meningioma, Glioma, Pituitary, and No Tumor. Evaluation using a confusion matrix and classification report indicates good performance. This research is expected to contribute to the early diagnosis of brain tumors and serve as a reference for future studies in the application of artificial intelligence in the medical field.

1. PENDAHULUAN

Penyakit Tumor otak adalah salah satu penyakit yang memiliki dampak serius terhadap kualitas hidup pasien dan tingkat kematian. Berdasarkan laporan dari World Health Organization (WHO) [1], jumlah kasus tumor otak terus meningkat setiap tahun, menjadikannya sebagai salah satu masalah kesehatan global yang perlu mendapat perhatian serius. Deteksi dini tumor otak sangat penting untuk meningkatkan peluang kesembuhan, mengurangi tingkat keparahan, dan meminimalkan risiko komplikasi [2]. Namun, proses deteksi dini untuk penyakit tumor sering kali menghadapi kendala, seperti kurangnya akses ke teknologi medis canggih, keterbatasan sumber daya tenaga medis, serta waktu yang dibutuhkan untuk menganalisis hasil pemeriksaan secara manual [2].

Teknologi Magnetic Resonance Imaging (MRI) telah menjadi salah satu metode utama dalam mendiagnosis tumor otak. MRI mampu memberikan citra detail struktur otak yang mempermudah identifikasi keberadaan tumor [3]. Namun, interpretasi citra MRI secara manual memerlukan keahlian tinggi dari tenaga medis, yang tidak selalu tersedia di semua fasilitas kesehatan. Selain itu, metode manual rentan terhadap kesalahan akibat faktor manusia, seperti kelelahan atau keterbatasan pengalaman. Oleh karena itu, diperlukan pendekatan yang lebih otomatis cepat, dan akurat untuk mendukung tenaga medis dalam mendiagnosis tumor otak [4].

Dalam beberapa tahun terakhir, teknologi kecerdasan buatan (Artificial Intelligence) telah menunjukkan potensi besar dalam bidang kesehatan, khususnya dalam analisis citra medis. Salah satu pendekatan AI yang paling menjanjikan adalah Deep Convolutional Neural

Network (DCNN) [5]. DCNN merupakan metode deep learning yang dirancang untuk mengolah dan menganalisis data berbasis citra dengan tingkat akurasi yang tinggi. DCNN telah berhasil diterapkan dalam berbagai tugas deteksi dan klasifikasi citra medis, seperti deteksi kanker payudara, penyakit paru-paru, dan gangguan kardiovaskular [6].

Arsitektur DCNN seperti ResNet152V2 menjadi salah satu pilihan unggulan dalam klasifikasi citra medis. ResNet152V2 dikenal karena kemampuannya mengatasi masalah vanishing gradient pada jaringan yang sangat dalam, sehingga memungkinkan model untuk mempelajari fitur kompleks dari citra medis secara lebih efektif. Dengan memanfaatkan pendekatan transfer learning, ResNet152V2 dapat mengadaptasi pengetahuan yang telah diperoleh dari dataset besar, seperti ImageNet, ke dalam dataset spesifik tumor otak, meskipun jumlah data yang tersedia relatif terbatas [7].

Penelitian ini bertujuan untuk mengembangkan sistem deteksi dini terhadap tumor otak dengan menggunakan citra MRI dan pendekatan DCNN berbasis arsitektur ResNet152V2. Sistem ini diharapkan mampu menganalisis citra MRI secara otomatis dan menghasilkan prediksi keberadaan tumor otak dengan akurasi tinggi. Dengan adanya sistem ini, diharapkan dapat mendukung proses pengambilan keputusan klinis, mempercepat diagnosis, serta meningkatkan aksesibilitas terhadap teknologi diagnostik yang lebih canggih. Berdasarkan latar belakang dan permasalahan yang telah diuraikan diatas, maka penulis tertarik untuk melakukan penelitian dengan judul "Deteksi Dini Terhadap Penyakit Tumor Otak Menggunakan Citra Magnetik Resonance Imaging (MRI) Dengan Pendekatan Deep Convolutional Neural Network". Penelitian

3. HASIL DAN PEMBAHASAN

3.1 Hasil Klasifikasi Tumor Otak


Pada eksperimen ini, proses melatih model pembelajaran mendalam menggunakan dataset jenis selama 118 epoch. Tujuan dari pelatihan ini adalah untuk meningkatkan akurasi model dalam mengklasifikasikan data dengan benar, sambil meminimalkan nilai loss, yang mengindikasikan seberapa baik model menyesuaikan diri terhadap data pelatihan.

Tabel 2. Hasil terakhir 5 pelatihan model.

Epoch	Akurasi Training	Loss Training	Akurasi Validasi	Los Validasi
1	0.9160	0.5807	0.9192	0.5488
2	0.9375	0.5370	1.0000	0.4360
3	0.9375	0.5370	0.9159	0.5538
4	0.9009	0.5978	0.9000	0.6299
5	0.9009	0.5977	0.9170	0.5531

Berdasarkan tabel 2. hasil pelatihan model *deep learning* berbasis ResNet152V2 menunjukkan ada epoch pertama, model mencapai akurasi training sebesar 91,60% dengan loss training sebesar 0,5807, sedangkan akurasi validasi mencapai 91,92% dengan loss validasi sebesar 0,5488. Hasil ini menunjukkan performa awal model yang cukup baik dalam memahami pola data.

Secara keseluruhan, hasil pelatihan menunjukkan bahwa model memiliki potensi yang baik dalam memprediksi data validasi. Namun, terdapat indikasi awal overfitting setelah epoch kedua, yang dapat diatasi dengan menambahkan teknik regularisasi, seperti dropout, atau dengan menggunakan *early stopping* untuk menghentikan pelatihan pada epoch terbaik. Hasil pelatihan tersebut didapat grafik akurasi dan *loss* pelatihan yang terdapat pada Gambar 3 dan 4.




Gambar 3. Hasil Akurasi Pelatihan

Berdasarkan gambar 3. hasil pelatihan menunjukkan bahwa performa pada data training dan validasi secara umum mengalami peningkatan seiring bertambahnya jumlah epoch. Namun, terdapat fluktuasi pada akurasi validasi, khususnya pada pertengahan proses pelatihan, yang menunjukkan adanya tantangan dalam mempertahankan konsistensi generalisasi terhadap data validasi. Akurasi validasi sempat mencapai puncaknya pada angka 1.0 atau 100%, mengindikasikan kemampuan model dalam memprediksi data validasi secara sempurna pada tahap tertentu. Meskipun demikian, fluktuasi yang terjadi setelahnya menunjukkan potensi adanya overfitting atau ketidakstabilan selama proses pelatihan.

Perbedaan pola yang muncul antara akurasi training dan validasi pada beberapa epoch juga menjadi tanda bahwa model mungkin terlalu menyesuaikan diri dengan data training, sehingga kehilangan kemampuan generalisasi. Untuk mengatasi hal ini, beberapa langkah dapat dilakukan, seperti menerapkan mekanisme *early stopping* untuk menghentikan pelatihan ketika akurasi validasi tidak lagi meningkat signifikan, menambahkan regularisasi seperti *dropout* atau L2 regularization untuk mengurangi kompleksitas model, dan menggunakan

teknik *data augmentation* guna meningkatkan variasi pada data training. Dengan langkah-langkah tersebut, model diharapkan mampu mempertahankan stabilitas sekaligus meningkatkan kemampuan generalisasi terhadap data validasi.




Gambar 4. Hasil Loss Pelatihan

Berdasarkan Gambar 4, memperlihatkan penurunan nilai loss baik pada data training maupun validasi seiring bertambahnya epoch. Pada awal pelatihan, nilai loss training cenderung lebih tinggi dibandingkan loss validasi, namun secara konsisten menurun hingga mencapai titik yang lebih stabil pada akhir epoch. Hal ini mencerminkan proses optimasi yang berhasil dalam meminimalkan error pada model. Penurunan yang signifikan pada beberapa epoch awal menunjukkan bahwa model dengan cepat mempelajari pola dari data training.

Stabilitas *loss* yang diperoleh menjelang akhir pelatihan menunjukkan bahwa model berhasil belajar dengan baik, meskipun fluktuasi awal pada loss validasi mengindikasikan bahwa penyempurnaan lebih lanjut masih diperlukan. Langkah-langkah seperti data augmentation atau cross-validation dapat diterapkan untuk mengatasi potensi bias atau ketidakstabilan pada validasi. Secara keseluruhan, grafik ini menggambarkan bahwa model memiliki performa yang cukup baik dalam menyelesaikan tugas

yang diberikan. Pengujian dengan confusion matrix dapat dilihat pada Gambar 5 berikut ini.



Gambar 5. Confusion Matrix


Berdasarkan Gambar 5. *confusion matrix* yang disajikan menunjukkan performa model dalam mengklasifikasikan empat jenis kategori data MRI otak untuk diagnosis tumor, yaitu Glioma, Meningioma, No Tumor, dan Pituitary. Secara keseluruhan, model menunjukkan hasil klasifikasi yang baik dengan jumlah prediksi benar yang dominan pada setiap kategori. Pada kategori Glioma, terdapat 124 prediksi benar, dengan kesalahan minor yang terjadi sebanyak 9 kali salah prediksi sebagai Meningioma, 1 kali sebagai No Tumor, dan 2 kali sebagai Pituitary. Untuk kategori Meningioma, model berhasil memprediksi 121 kasus dengan benar, namun terdapat kesalahan prediksi sebesar 6 kasus ke Glioma, 1 kasus ke No Tumor, dan 12 kasus ke Pituitary. Pada kategori No Tumor, akurasi sedikit lebih rendah dibandingkan kategori lainnya, dengan 94 prediksi benar dan 6 kesalahan (5 kasus salah ke Meningioma dan 1 kasus salah ke Pituitary). Kategori Pituitary menunjukkan performa terbaik, dengan 134 prediksi benar dan hanya 2 kesalahan prediksi ke Meningioma. Pengujian dengan classification report dapat dilihat pada Gambar 6.

	precision	recall	f1-score	support
Glioma	0.9538	0.9118	0.9323	136
Meningioma	0.8832	0.8643	0.8736	140
No Tumor	0.9792	0.9400	0.9592	100
Pituitary	0.8993	0.9853	0.9404	136
accuracy			0.9238	512
macro avg	0.9289	0.9253	0.9264	512
weighted avg	0.9250	0.9238	0.9237	512

Gambar 6. *Classification Report*

Berdasarkan Gambar 6. hasil evaluasi model pada data uji menunjukkan performa yang baik dalam mendeteksi berbagai jenis tumor otak, seperti Glioma, Meningioma, dan Pituitary, serta kondisi "No Tumor". Akurasi keseluruhan model mencapai 92,38%, yang menunjukkan kemampuan prediksi yang cukup andal.

Secara keseluruhan, hasil ini menunjukkan bahwa model memiliki performa yang baik dalam mendeteksi berbagai jenis tumor otak, dengan nilai f1-score yang konsisten di atas 87% untuk semua kelas. Namun, analisis lebih lanjut diperlukan untuk meningkatkan performa pada kelas "Meningioma" dan meminimalkan kesalahan prediksi. Untuk evaluasi menggunakan kurva ROC dapat dilihat pada Gambar 7.




Gambar 7. Kurva ROC

Berdasarkan Gambar 7. hasil evaluasi menggunakan *Receiver Operating Characteristic* (ROC) menunjukkan bahwa model memiliki performa yang sangat baik dalam mengklasifikasikan kategori tumor otak. *Area Under Curve* (AUC) untuk kelas Glioma mencapai 0,99, yang menunjukkan kemampuan hampir

sempurna dalam membedakan kasus Glioma dari kategori lainnya. Untuk kelas Meningioma, nilai AUC sebesar 0,97 menunjukkan performa yang sangat baik meskipun sedikit lebih rendah dibandingkan kelas lainnya, kemungkinan disebabkan oleh karakteristik data yang lebih kompleks.

Untuk pengujian model secara actual menggunakan gambar atau citra langsung dapat dilihat pada Gambar 8 berikut ini.

Image Path: /content/drive/MyDrive/Deteksi Tu
Predict
1/1 0s 2s/step
1/1 2s 2s/step
Predicted class: Glioma, Confidence: 1.00
Glioma, Confidence: 1.00



Gambar 8. Testing Actual Model

Pada Gambar 8. hasil pengujian model untuk klasifikasi tumor otak berbasis citra MRI, gambar yang diberikan berhasil diklasifikasikan sebagai kategori "Glioma" dengan tingkat kepercayaan (*confidence*) sebesar 1.00 atau 100%. Hal ini menunjukkan bahwa model sangat yakin terhadap prediksi yang dihasilkan. Visualisasi citra MRI pada layar memperlihatkan ciri-ciri khas yang sesuai dengan kategori Glioma, yang mendukung hasil prediksi model.

4. KESIMPULAN

Hasil penelitian menunjukkan bahwa model dikembangkan untuk klasifikasi varietas beras mencapai performa yang sangat baik. Pada fase pelatihan, model menunjukkan akurasi yang sangat tinggi sebesar 92.38% dengan nilai loss yang sangat rendah yaitu sebesar 0.0464. Model yang dikembangkan sangat efektif dalam mengidentifikasi dan mengklasifikasikan setiap kelas secara tepat, dengan hampir tidak ada kesalahan klasifikasi untuk

setiap label yang diuji. Model memiliki kemampuan yang sangat baik dalam memberikan prediksi yang akurat dan konsisten.

5. REFERENSI

- [1] S. Heranurweni, B. Destyningtias, and A. K. Nugroho, "Klasifikasi Pola Image pada Pasien Tumor Otak Berbasis Jaringan Syaraf Tiruan (Studi Kasus Penanganan Kuratif Pasien Tumor Otak)," *eLEKTRIKAL*, vol. 10, no. 2, pp. 37–40, 2018.
- [2] K. P. K. Nasional, "Pedoman Nasional Pelayanan Kedokteran Tumor Otak," *Kementeri. Kesehat. RI*, vol. 1, no. 1, pp. 146–153, 2019, [Online]. Available: <https://www.kemkes.go.id/article/view/19093000001/penyakit-jantung-%0Apenyebab-kematian-terbanyak-ke-2-di-indonesia.html>.
- [3] A. W. Astuti, I. M. L. Prasetya, and T. Hariyanto, "Teknik Pemeriksaan Magnetic Resonance Imaging (MRI) Brain Dengan Penambahan Sequence Axial 3D-Fiesta Pada Kasus Facial Tic," *Compromise J. Community Proffesional Serv. Journa*, vol. 1, no. 4, pp. 18–28, 2023.
- [4] N. H. Apriantoro and Christianni, "Analisis Perbedaan Citra MRI Brain Pada SEKUENTISE dan T1FLAIR," *Sinergi*, vol. 19, no. 3, pp. 206–210, 2015.
- [5] Y. Fang, J. Zhao, L. Hu, X. Ying, Y. Pan, and X. Wang, "Image classification toward breast cancer using deeply-learned quality," *J. Vis. Commun. Image Represent.*, vol. 64, p. 102609, 2019, doi: 10.1016/j.jvcir.2019.102609.
- [6] M. Harahap, E. M. Laia, L. S. Sitanggang, M. Sinaga, D. F. Sihombing, and A. M. Husein, "Deteksi Penyakit Covid-19 Pada Citra X-Ray Dengan Pendekatan Convolutional Neural Network (CNN)," *J. RESTI*, vol. 6, no. 1, pp. 70–77, 2022.
- [7] D. Setiawan and T. W. E. Suryawijaya, "Algoritma Renet152V2 dalam Melakukan Klasifikasi Penyakit pada Daun Tanaman Tomat," *J. Comput. Sci. Technol.*, vol. 3, no. 2, pp. 37–42, 2023.
- [8] Arnita, F. Marpaung, F. Aulia, Nita Suryani, and R. C. Nabila, *Computer Vision Dan Pengolahan Citra Digital*. Surabaya, Jawa Timur: Pustaka Aksara, 2022.
- [9] Y. Amrozi, D. Yuliaty, A. Susilo, N. Novianto, and R. Ramadhan, "Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM," *J. SISFOKOM (Sistem Inf. dan Komputer)*, vol. 11, no. 3, pp. 394–399, 2022.