

Penerapan Optimasi *Convolutional Neural Network* untuk Klasifikasi Multi-Kelas Tumor Otak pada Citra MRI

Vina Ayumi

Fakultas Teknik dan Informatika, Universitas Dian Nusantara, Indonesia

vina.ayumi@dosen.undira.ac.id

Article Info

Article history:

Received, 2026-01-24

Revised, 2026-01-29

Accepted, 2026-01-30

Kata Kunci:

Tumor otak;
Citra MRI;
Convolutional Neural Network;
Klasifikasi multi-kelas;
Deep learning

Keywords:

Brain tumor;
MRI images;
Convolutional Neural Network;
Multi-class classification;
Deep learning

ABSTRAK

Tumor otak merupakan salah satu penyakit berbahaya yang memerlukan diagnosis dini dan akurat untuk menentukan penanganan medis yang tepat. Pemeriksaan *Magnetic Resonance Imaging* (MRI) banyak digunakan dalam mendeteksi tumor otak karena mampu menghasilkan citra dengan resolusi tinggi, namun proses analisis secara manual masih bergantung pada subjektivitas dan pengalaman tenaga medis. Oleh karena itu, penelitian ini bertujuan untuk menerapkan optimasi *Convolutional Neural Network* (CNN) dalam melakukan klasifikasi multi-kelas tumor otak berbasis citra MRI. Dataset yang digunakan terdiri dari 7.023 citra MRI yang terbagi ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *healthy*, serta dibagi menjadi data latih, validasi, dan uji. Tahapan penelitian meliputi pra-pemrosesan data, perancangan arsitektur CNN, optimasi *hyperparameter*, pelatihan model selama 50 *epoch*, dan evaluasi kinerja model. Hasil pelatihan menunjukkan akurasi data latih sebesar 87,44% dan akurasi validasi sebesar 85%, yang mengindikasikan kemampuan generalisasi model yang baik. Evaluasi pada data uji menggunakan *confusion matrix*, *precision*, *recall*, *F1-score*, dan akurasi menunjukkan bahwa model mencapai akurasi sebesar 77,8%, dengan performa terbaik pada kelas *healthy* dan *pituitary*.

ABSTRACT

Brain tumors are among the most critical neurological diseases and require early and accurate diagnosis to support appropriate medical treatment. *Magnetic Resonance Imaging* (MRI) is widely used for brain tumor detection due to its high-resolution imaging capability; however, manual analysis of MRI images is time-consuming and highly dependent on the expertise of radiologists. Therefore, this study aims to apply an optimized *Convolutional Neural Network* (CNN) for multi-class brain tumor classification using MRI images. The dataset used in this study consists of 7,023 MRI images, categorized into four classes: *glioma*, *meningioma*, *pituitary*, and *healthy*, and divided into training, validation, and testing subsets. The research stages include image preprocessing, CNN architecture design, hyperparameter optimization, model training for 50 epochs, and performance evaluation. The training process achieved an accuracy of 87.44%, while the validation accuracy reached 85%, indicating good model generalization. Model evaluation on the test dataset using a *confusion matrix*, *precision*, *recall*, *F1-score*, and accuracy resulted in an overall accuracy of 77.8%.

This is an open access article under the CC BY-SA license.



Penulis Korespondensi:

Vina Ayumi,
Fakultas Teknik dan Informatika,
Universitas Dian Nusantara, Indonesia
Email: vina.ayumi@dosen.undira.ac.id

1. PENDAHULUAN

Tumor otak merupakan salah satu penyakit yang berpotensi mengancam jiwa dan memerlukan penanganan medis yang cepat serta tepat [1], [2]. Berdasarkan karakteristiknya, tumor otak dapat diklasifikasikan ke dalam beberapa jenis, di antaranya glioma, meningioma, dan pituitary, serta kondisi otak normal (*healthy*) sebagai pembanding. Setiap jenis tumor memiliki karakteristik morfologi, lokasi, dan tingkat keganasan yang berbeda, sehingga proses diagnosis yang akurat menjadi sangat penting dalam menentukan tindakan medis yang sesuai [3], [4], [5], [6].

Pemeriksaan *magnetic resonance imaging* (MRI) merupakan metode pencitraan yang paling umum digunakan untuk mendeteksi dan menganalisis tumor otak karena kemampuannya menghasilkan citra dengan resolusi tinggi serta kontras jaringan lunak yang baik. Namun demikian, proses analisis citra MRI secara manual sangat bergantung pada pengalaman dan subjektivitas dokter spesialis radiologi, sehingga berpotensi menimbulkan kesalahan diagnosis, terutama ketika perbedaan antar kelas tumor memiliki karakteristik visual yang mirip [1], [7].

Perkembangan kecerdasan buatan, mendukung proses diagnosis berbasis citra medis. Salah satu metode yang banyak digunakan adalah *convolutional neural network* (CNN), yang dapat mengekstraksi fitur secara otomatis dan melakukan klasifikasi citra. CNN mampu mempelajari pola kompleks pada citra MRI tumor otak tanpa memerlukan proses ekstraksi fitur manual [8], [9], [10], [11], [12].

Berbagai penelitian telah dilakukan untuk mengklasifikasikan tumor otak berbasis citra MRI dengan memanfaatkan pendekatan *deep learning*. Kumar et al. (2023) mengusulkan metode klasifikasi tumor otak menggunakan *deep neural network* (DNN) yang dikombinasikan dengan *transfer learning*. Penelitian tersebut bertujuan untuk mengotomatisasi proses klasifikasi tumor otak guna membantu diagnosis medis. Hasil penelitian menunjukkan bahwa penerapan *transfer learning* mampu meningkatkan akurasi klasifikasi secara dibandingkan model DNN yang dilatih dari awal [13].

Pendekatan *hybrid deep learning* juga dikaji oleh Raza et al. (2022), yang mengembangkan model klasifikasi tumor otak berbasis kombinasi beberapa teknik *deep learning*. Penelitian ini berfokus pada klasifikasi tiga jenis tumor otak, yaitu *glioma*, *meningioma*, dan *pituitary tumor*, menggunakan citra MRI. Hasil eksperimen menunjukkan bahwa pendekatan *hybrid* mampu mengungguli beberapa metode CNN konvensional, meskipun kompleksitas model meningkat [14]. Rasheed et al. (2023) meneliti klasifikasi tumor otak menggunakan citra MRI dengan mengombinasikan *image enhancement* dan *convolutional neural network* (CNN). Penelitian ini menekankan pentingnya peningkatan kualitas citra sebelum proses klasifikasi, sehingga fitur tumor dapat diekstraksi secara lebih optimal. Model yang diusulkan terbukti mampu menangkap karakteristik spesifik tumor dengan baik tanpa memerlukan beban komputasi yang berlebihan, serta menunjukkan performa yang kompetitif dibandingkan metode *deep learning* lainnya [15].

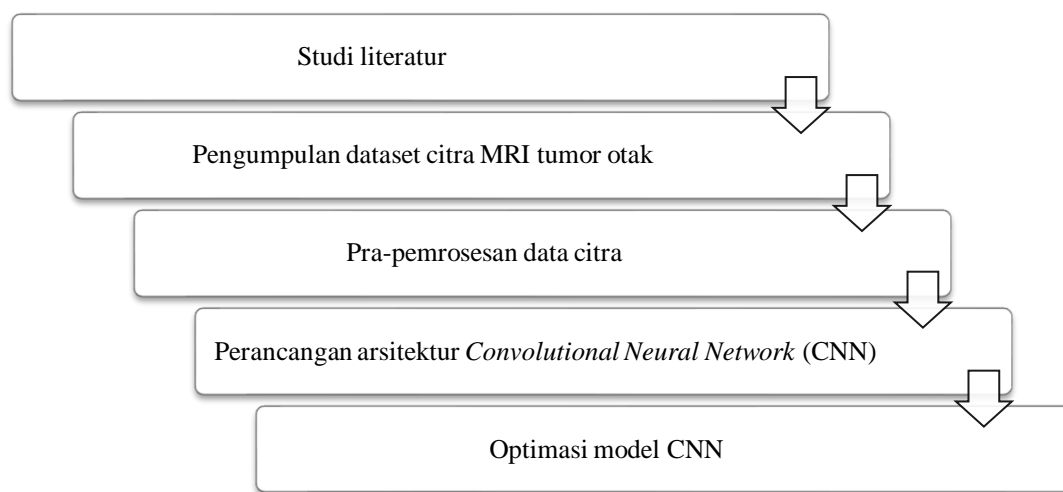
Sementara itu, Aamir et al. (2022) mengusulkan pendekatan *deep learning* untuk klasifikasi tumor otak berbasis citra MRI dengan menyoroti keterbatasan diagnosis manual yang bergantung pada pengalaman radiolog. Penelitian ini menunjukkan bahwa CNN mampu mengklasifikasikan tumor otak secara otomatis dan mengurangi potensi kesalahan subjektif dalam proses diagnosis manual [1]. Meskipun demikian, penerapan CNN dalam klasifikasi multi-kelas tumor otak masih menghadapi beberapa tantangan, seperti ketidakseimbangan karakteristik antar kelas, variasi intensitas citra MRI, serta penentuan parameter dan arsitektur CNN yang optimal. CNN dengan konfigurasi parameter yang tidak optimal dapat menyebabkan *overfitting*, *underfitting*, atau penurunan akurasi klasifikasi, khususnya pada kasus multi-kelas yang kompleks.

Oleh karena itu, diperlukan optimasi pada model *Convolutional Neural Network* guna meningkatkan kinerja klasifikasi citra MRI tumor otak. Optimasi dapat dilakukan melalui penyesuaian hyperparameter, arsitektur jaringan, maupun strategi pelatihan agar model mampu membedakan secara akurat antara kelas glioma, meningioma, pituitary, dan *healthy*. Dengan model CNN yang teroptimasi, diharapkan sistem klasifikasi yang dihasilkan dapat memberikan performa yang lebih baik, konsisten, dan andal sebagai alat bantu diagnosis medis. Berdasarkan permasalahan tersebut, penelitian ini difokuskan pada penerapan optimasi *Convolutional Neural Network* untuk klasifikasi multi-kelas tumor otak pada citra MRI, dengan tujuan meningkatkan akurasi dan efektivitas sistem klasifikasi sebagai dukungan dalam proses diagnosis tumor otak secara otomatis.

Berdasarkan permasalahan dan kajian penelitian sebelumnya, penelitian ini berfokus pada penerapan optimasi *Convolutional Neural Network* (CNN) untuk klasifikasi multi-kelas tumor otak berbasis citra MRI. Kontribusi utama penelitian ini terletak pada perancangan arsitektur CNN teroptimasi serta evaluasi kinerjanya menggunakan dataset empat kelas tumor otak yang relatif seimbang, yaitu *glioma*, *meningioma*, *pituitary*, dan *healthy*. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem pendukung diagnosis medis berbasis kecerdasan buatan.

2. METODE PENELITIAN

Penelitian ini diawali dengan studi literatur terhadap sumber ilmiah yang membahas klasifikasi tumor otak berbasis citra MRI, *deep learning*, *Convolutional Neural Network* (CNN), serta teknik optimasi dan *transfer learning* untuk memahami metode yang telah ada dan menentukan celah penelitian. Selanjutnya, dataset citra MRI otak yang terdiri dari empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *healthy*, dikumpulkan dan dibagi menjadi data latih, data validasi, dan data uji. Data kemudian melalui tahap pra-pemrosesan yang meliputi normalisasi nilai piksel, penyesuaian ukuran citra, serta penerapan *data augmentation*. Model klasifikasi dirancang menggunakan arsitektur CNN yang terdiri dari lapisan konvolusi, *pooling*, dan *fully connected* untuk mengekstraksi fitur. Selanjutnya dilakukan optimasi model melalui penyesuaian *hyperparameter* dan strategi pelatihan guna meningkatkan kinerja klasifikasi. Model CNN kemudian dilatih menggunakan data latih dengan pemantauan kinerja melalui data validasi. Evaluasi akhir dilakukan menggunakan data uji dengan metrik confusion matrix, akurasi, *precision*, *recall*, dan *F1-score* untuk menilai kemampuan model dalam mengklasifikasikan citra MRI tumor otak. Tahap penelitian dapat dilihat pada Gambar 1.



Gambar 1 Tahap Penelitian

Penelitian diawali dengan melakukan studi literatur terhadap artikel yang membahas klasifikasi tumor otak berbasis citra MRI, *deep learning*, *Convolutional Neural Network* (CNN), serta teknik optimasi dan *transfer learning*. Dataset yang digunakan dalam penelitian ini berupa citra MRI otak yang terbagi ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *healthy*. Dataset dibagi menjadi tiga *subset*, yakni data latih, data validasi, dan data uji, guna mendukung proses pelatihan, pemantauan kinerja, dan evaluasi akhir model. Pembagian dataset dilakukan untuk memastikan bahwa proses evaluasi model dilakukan tidak bias seperti pada Tabel 1.

Tabel 1 Dataset Penelitian

Kelas Tumor	Data Latih (Train)	Data Validasi (Validation)	Data Uji (Test)	Total
<i>Pituitary</i>	1.229	263	265	1.757
<i>Meningioma</i>	1.151	246	248	1.645
<i>Healthy</i>	1.400	300	300	2.000
<i>Glioma</i>	1.134	243	244	1.621
Total	4.914	1.052	1.057	7.023

Pada tahap pra-pemrosesan, citra MRI disiapkan agar sesuai dengan kebutuhan input model CNN. Proses ini meliputi normalisasi nilai piksel melalui *rescaling*, penyesuaian ukuran citra, serta penerapan data augmentation pada data latih, seperti rotasi, *zoom*, dan *flipping horizontal*. Arsitektur model klasifikasi dirancang menggunakan *Convolutional Neural Network* (CNN) yang terdiri dari beberapa lapisan konvolusi, *pooling*, dan *fully connected*. Model CNN dirancang untuk mampu mengekstraksi fitur secara otomatis dari citra MRI serta mempelajari pola kompleks yang membedakan setiap kelas tumor otak.

Optimasi model CNN dilakukan untuk meningkatkan kinerja klasifikasi dan stabilitas model. Proses optimasi mencakup penyesuaian *hyperparameter*, seperti *learning rate*, *batch size*, jumlah *epoch*, serta pemilihan *optimizer* yang sesuai. Pada tahap pelatihan, model CNN dilatih menggunakan data latih dengan memanfaatkan

data validasi sebagai acuan untuk memantau performa model selama proses training. Proses pelatihan dilakukan secara iteratif hingga mencapai jumlah *epoch* yang ditentukan atau hingga model menunjukkan konvergensi. Data validasi digunakan untuk mengidentifikasi potensi *overfitting* dan memastikan bahwa model mampu melakukan generalisasi dengan baik. Evaluasi kinerja model dilakukan menggunakan data uji yang tidak terlibat dalam proses pelatihan. Evaluasi dilakukan dengan menggunakan beberapa metrik, antara lain *confusion matrix*, akurasi, *precision*, *recall*, dan *F1-score*.

3. HASIL DAN ANALISIS

Model klasifikasi yang digunakan dalam penelitian ini merupakan arsitektur *Convolutional Neural Network* (CNN) yang dirancang secara bertahap untuk mengekstraksi fitur dari citra MRI tumor otak dan melakukan klasifikasi multi-kelas. Model menerima citra masukan berukuran $224 \times 224 \times 3$ dan terdiri dari tiga blok konvolusi utama yang diikuti oleh lapisan fully connected. Blok konvolusi pertama terdiri dari lapisan Conv2D dengan 32 filter berukuran kernel 3×3 yang berfungsi untuk mengekstraksi fitur dasar seperti tepi dan tekstur awal. Lapisan ini diikuti oleh *Batch Normalization* untuk menstabilkan proses pelatihan serta MaxPooling2D dengan ukuran pool 2×2 untuk mengurangi dimensi spasial dan kompleksitas komputasi. Blok konvolusi kedua menggunakan lapisan Conv2D dengan 64 filter berukuran 3×3 yang bertujuan untuk mengekstraksi fitur tingkat menengah. Seperti pada blok sebelumnya, lapisan ini diikuti oleh Batch Normalization dan MaxPooling2D guna meningkatkan stabilitas pelatihan dan efisiensi model.

Blok konvolusi ketiga terdiri dari lapisan Conv2D dengan 128 filter berukuran 3×3 yang berfungsi untuk menangkap fitur tingkat tinggi dan pola kompleks yang berkaitan dengan karakteristik masing-masing jenis tumor otak. Lapisan ini kembali diikuti oleh *Batch Normalization* dan MaxPooling2D untuk mempertahankan performa model dan mengurangi dimensi fitur. Hasil keluaran dari blok konvolusi kemudian diratakan menggunakan lapisan Flatten, menghasilkan vektor fitur berdimensi besar. Vektor ini diteruskan ke lapisan Dense dengan 256 neuron sebagai lapisan fully connected untuk melakukan pembelajaran representasi tingkat tinggi. Untuk mengurangi risiko *overfitting*, diterapkan lapisan Dropout sebelum lapisan keluaran. Lapisan keluaran menggunakan Dense layer dengan 4 neuron yang sesuai dengan jumlah kelas klasifikasi, yaitu *glioma*, *meningioma*, *pituitary*, dan *healthy*, dengan fungsi aktivasi *softmax* untuk menghasilkan probabilitas pada setiap kelas.

Proses pelatihan model *convolutional neural network* (CNN) dilakukan selama 50 epoch dengan memanfaatkan data latih dan data validasi. Berdasarkan hasil pelatihan, model mencapai akurasi data latih sebesar 0,8744 (87,44%), sedangkan akurasi data validasi mencapai 0,85 (85%) pada akhir epoch ke-50. Nilai akurasi ini menunjukkan bahwa model mampu mempelajari pola dan karakteristik citra MRI tumor otak dengan baik. Perbedaan akurasi antara data latih dan data validasi relatif kecil, yaitu sekitar 2,44%, yang mengindikasikan bahwa model tidak mengalami *overfitting*. Hal ini menunjukkan bahwa penerapan teknik pra-pemrosesan, data augmentation, serta penggunaan batch normalization dan dropout pada arsitektur CNN berkontribusi dalam meningkatkan kemampuan generalisasi model. Selain itu, pelatihan selama 50 *epoch* dinilai cukup untuk mencapai konvergensi model, di mana peningkatan akurasi mulai stabil pada *epoch-epoch* akhir. Hasil ini menunjukkan bahwa model CNN teroptimasi memiliki performa yang konsisten dan mampu melakukan klasifikasi citra MRI tumor otak secara cukup akurat pada data yang belum pernah dilihat sebelumnya.

Evaluasi kinerja model Convolutional Neural Network (CNN) dilakukan menggunakan data pengujian (testing data) yang tidak terlibat dalam proses pelatihan maupun validasi model. Hal ini bertujuan untuk memperoleh gambaran objektif mengenai kemampuan model dalam menggeneralisasi dan mengklasifikasikan citra MRI tumor otak pada data baru. Data pengujian terdiri dari empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *healthy*. Proses evaluasi dilakukan dengan menghasilkan prediksi kelas untuk setiap citra MRI tumor otak pada data pengujian, kemudian membandingkannya dengan label aktual yang merepresentasikan jenis tumor, yaitu *glioma*, *meningioma*, *pituitary*, serta kondisi otak normal (*healthy*). Hasil perbandingan antara label prediksi dan label aktual tersebut disusun dalam bentuk *confusion matrix*, yang menggambarkan jumlah citra MRI yang berhasil diklasifikasikan dengan benar maupun yang mengalami kesalahan klasifikasi pada masing-masing kelas tumor otak. seperti pada Gambar 2.

Kelas Aktual \ Prediksi	<i>Glioma</i>	<i>Healthy</i>	<i>Meningioma</i>	<i>Pituitary</i>
<i>Glioma</i>	189	1	13	41
<i>Healthy</i>	5	285	5	5
<i>Meningioma</i>	60	25	87	76
<i>Pituitary</i>	2	1	1	261

Gambar 2 *Confusion Matrix* Klasifikasi Tumor Otak pada Data Uji

Berdasarkan *confusion matrix* pada Gambar 2, kesalahan klasifikasi paling banyak terjadi pada kelas meningioma. Hal ini diduga disebabkan oleh kemiripan karakteristik visual antara citra meningioma dengan kelas glioma dan pituitary, terutama pada tekstur dan intensitas citra MRI. Selain itu, variasi bentuk dan ukuran tumor meningioma pada dataset juga berpengaruh terhadap kemampuan model dalam mengenali pola secara konsisten. *Precision* mengukur tingkat ketepatan model dalam mengklasifikasikan citra MRI ke dalam kelas tumor tertentu, yang menunjukkan seberapa besar proporsi citra MRI yang diprediksi sebagai suatu jenis tumor benar-benar berasal dari kelas tersebut. *Recall* mengukur kemampuan model dalam mengenali seluruh citra MRI yang benar pada suatu kelas tumor otak, yang mencerminkan tingkat sensitivitas model dalam mendeteksi jenis tumor tertentu. Sementara itu, *F1-score* merupakan rata-rata harmonik dari *precision* dan *recall* yang digunakan untuk memberikan gambaran kinerja model secara seimbang, terutama pada klasifikasi multi-kelas tumor otak dengan distribusi data yang beragam, sebagaimana ditunjukkan pada **Tabel 2**.

Tabel 2 Hasil Evaluasi Kinerja Model CNN pada Data Penujian

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Glioma</i>	0,75	0,79	0,77
<i>Healthy</i>	0,93	0,96	0,95
<i>Meningioma</i>	0,84	0,36	0,51
<i>Pituitary</i>	0,69	1,00	0,82

Perbedaan nilai *precision*, *recall*, dan *F1-score* antar kelas menunjukkan bahwa model CNN memiliki performa terbaik pada kelas healthy dan pituitary. Hal ini mengindikasikan bahwa karakteristik visual kedua kelas tersebut lebih mudah dikenali oleh model dibandingkan kelas meningioma yang memiliki variasi fitur lebih kompleks. Kondisi ini menjadi salah satu faktor penyebab rendahnya nilai recall pada kelas meningioma.

Akurasi klasifikasi tumor otak pada data uji diperoleh dengan membandingkan jumlah prediksi yang benar terhadap total seluruh data pengujian. Berdasarkan hasil evaluasi, model CNN berhasil mengklasifikasikan 822 citra MRI tumor otak secara benar dari total 1.057 citra MRI pada data uji, sehingga diperoleh nilai akurasi sebesar 77,8%. Nilai akurasi ini menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam membedakan citra MRI tumor otak ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *healthy* yang dihitung dengan menggunakan rumus pada Persamaan (1).

$$\begin{aligned} \text{Akurasi} &= \frac{\text{Jumlah prediksi benar}}{\text{Total data}} \times 100\% \\ \text{Akurasi} &= \frac{822}{1057} \times 100\% \approx 77,8\% \end{aligned} \quad (1)$$

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan *Convolutional Neural Network* (CNN) teroptimasi mampu digunakan untuk melakukan klasifikasi multi-kelas tumor otak berbasis citra MRI ke dalam empat kelas, yaitu glioma, meningioma, pituitary, dan healthy. Model CNN yang dirancang dengan tiga blok konvolusi serta didukung oleh teknik pra-pemrosesan dan data augmentation mampu mengekstraksi fitur citra MRI. Hasil pelatihan model selama 50 epoch menunjukkan akurasi data latih sebesar 87,44% dan akurasi data validasi sebesar 85%, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting*. Evaluasi kinerja pada data uji menghasilkan akurasi sebesar 77,8%, dengan performa terbaik pada kelas *healthy* dan *pituitary*, sementara kelas meningioma masih menunjukkan tingkat kesalahan klasifikasi yang relatif lebih tinggi. Berdasarkan hasil dan keterbatasan penelitian ini, beberapa arah pengembangan yang dapat dilakukan pada penelitian selanjutnya antara lain dengan meningkatkan jumlah dan keragaman dataset, khususnya pada kelas tumor yang masih memiliki tingkat kesalahan klasifikasi tinggi seperti meningioma. Penambahan dataset dari berbagai sumber dan variasi citra MRI diharapkan dapat meningkatkan kemampuan generalisasi model. Penelitian selanjutnya juga disarankan untuk menerapkan arsitektur *deep learning* yang lebih kompleks atau berbasis *transfer learning*, seperti *EfficientNet*, *ResNet*, atau *DenseNet*, guna memperoleh representasi fitur yang lebih kaya dan akurat. Selain itu, eksplorasi teknik optimasi hyperparameter yang lebih sistematis, seperti *Grid Search*, *Bayesian Optimization*, atau algoritma *metaheuristic*, dapat dilakukan untuk memperoleh konfigurasi model yang lebih optimal.

UCAPAN TERIMA KASIH

Terima kasih kepada Lembaga Riset dan Pengabdian kepada Masyarakat (LRPM) Universitas Dian Nusantara (UNDIRA) yang telah mendanai penelitian ini melalui skema penelitian internal.

REFERENSI

- [1] M. Aamir *et al.*, “A deep learning approach for brain tumor classification using MRI images,” *Comput. Electr. Eng.*, vol. 101, p. 108105, 2022.
- [2] S. Saeed, A. Abdullah, N. Z. Jhanjhi, M. Naqvi, and A. Nayyar, “New techniques for efficiently k-NN algorithm for brain tumor detection,” *Multimed. Tools Appl.*, vol. 81, no. 13, pp. 18595–18616, 2022.
- [3] S. B. Shaheema and N. B. Muppalaneni, “Explainability based Panoptic brain tumor segmentation using a hybrid PA-NET with GCNN-ResNet50,” *Biomed. Signal Process. Control*, vol. 94, p. 106334, 2024.
- [4] S. Preethi and P. Aishwarya, “An efficient wavelet-based image fusion for brain tumor detection and segmentation over PET and MRI image,” *Multimed. Tools Appl.*, vol. 80, no. 10, pp. 14789–14806, 2021.
- [5] R. Ranjbarzadeh, A. Caputo, E. B. Tirkolaee, S. J. Ghouschi, and M. Bendechache, “Brain tumor segmentation of MRI images: A comprehensive review on the application of artificial intelligence tools,” *Comput. Biol. Med.*, p. 106405, 2022.
- [6] A. S. S. M. N. Arefin, S. M. I. A. K. Ishti, M. M. Akter, and N. Jahan, “Deep learning approach for detecting and localizing brain tumor from magnetic resonance imaging images,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 29, no. 3, pp. 1729–1737, 2023.
- [7] L. Sun, H. Huang, X. Ding, Y. Huang, X. Liu, and Y. Yu, “Fast Magnetic Resonance Imaging on Regions of Interest: From Sensing to Reconstruction,” pp. 97–106, 2021, doi: 10.1007/978-3-030-87231-1_10.
- [8] V. K. Kukreja, R. Sharma, and S. Vats, “Revolutionizing Rice Farming: Automated Identification and Classification of Rice Leaf Blight Disease Using Deep Learning,” pp. 586–591, 2023, doi: 10.1109/ICSCCC58608.2023.10176408.
- [9] E. Elizar, M. A. Zulkifley, R. Muharar, M. H. M. Zaman, and S. M. Mustaza, “A Review on Multiscale-Deep-Learning Applications,” *Sensors*, vol. 22, no. 19, p. 7384, Sep. 2022, doi: 10.3390/s22197384.
- [10] R. Rosalina, G. Sahuri, and H. Desriva, “A mobile-optimized convolutional neural network approach for real-time batik pattern recognition,” *IAES Int. J. Artif. Intell.*, vol. 13, no. 3, p. 3018, Sep. 2024, doi: 10.11591/ijai.v13.i3.pp3018-3027.
- [11] M. Purba *et al.*, “Effect of Random Splitting and Cross Validation for Indonesian Opinion Mining using Machine Learning Approach,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 9, 2022, doi: 10.14569/IJACSA.2022.0130917.
- [12] H. Noprisson, V. Ayumi, E. D. Putra, M. Utami, and N. Ani, “Model GHT-SVM for Traffic Sign Detection Using Support Vector Machine Algorithm Based On Gabor Filter and Top-Black Hat Transform,” *J. Nas. Pendidik. Tek. Inform. JANAPATI*, vol. 13, no. 3, pp. 633–641, 2024.
- [13] S. Kumar, S. Choudhary, A. Jain, K. Singh, A. Ahmadian, and M. Y. Bajuri, “Brain tumor classification using deep neural network and transfer learning,” *Brain Topogr.*, vol. 36, no. 3, pp. 305–318, 2023.
- [14] A. Raza *et al.*, “A hybrid deep learning-based approach for brain tumor classification,” *Electronics*, vol. 11, no. 7, p. 1146, 2022.
- [15] Z. Rasheed *et al.*, “Brain tumor classification from MRI using image enhancement and convolutional neural network techniques,” *Brain Sci.*, vol. 13, no. 9, p. 1320, 2023.