

Penerapan Convolutional Neural Network (CNN) dalam Klasifikasi Citra MRI untuk Deteksi Tumor Otak Manusia

Denis Lizard Sambawo Dimara¹, Shintyadhita Wirawan Putri², Rizky Amelia³

Zalfa Ibtisamah Arishandy⁴, Agung Mustika Rizki⁵

^{1, 2, 3, 4, 5} Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional "Veteran" Jawa Timur

*Penulis Korespondensi :

ABSTRACT

Brain tumors are deadly diseases with a high mortality rate, making early diagnosis crucial to improving patient survival rates. However, manual diagnosis through Magnetic Resonance Imaging (MRI) often requires significant time and is prone to errors. This study developed an MRI image classification method using the EfficientNetB3-based Convolutional Neural Network (CNN) architecture to detect brain tumors. The dataset used was obtained from Kaggle, consisting of 253 brain MRI images, including 98 normal and 155 abnormal images. The data were preprocessed through normalization and resizing to 224x224 pixels. The model employed transfer learning techniques using pretrained weights from ImageNet, enhanced with additional layers to improve performance. Evaluation was conducted using metrics such as accuracy, precision, recall, F1-score, AUC, as well as confusion matrix and classification report analyses. The results showed that the EfficientNetB3 model achieved an overall accuracy of 86%, demonstrating its capability to support brain tumor diagnosis processes quickly and accurately. This implementation is expected to provide a significant contribution to early detection of brain tumors and improve patient care quality in the medical field.

Article History

Received : 27-12-2024
Revised : -
Accepted : 17-01-2025

Keywords

CNN; Deep Learning;
EfficientnetB3; Klasifikasi;
Tumor Otak;

ABSTRAK

Tumor otak merupakan penyakit mematikan dengan tingkat mortalitas yang tinggi, sehingga diagnosis dini sangat penting untuk meningkatkan harapan hidup pasien. Namun, diagnosis manual melalui citra Magnetic Resonance Imaging (MRI) sering memakan waktu lama dan rentan terhadap kesalahan. Penelitian ini mengembangkan metode klasifikasi citra MRI menggunakan arsitektur Convolutional Neural Network (CNN) berbasis EfficientNetB3 untuk mendeteksi tumor otak. Dataset yang digunakan berasal dari Kaggle, terdiri dari 253 citra MRI otak, dengan 98 citra normal dan 155 citra abnormal. Data diproses melalui normalisasi dan perubahan ukuran menjadi 224x224 piksel. Model menggunakan teknik transfer learning dengan pretrained weights dari ImageNet, dilengkapi dengan penambahan lapisan tambahan untuk meningkatkan performa. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, AUC, serta analisis confusion matrix dan classification report. Hasil penelitian menunjukkan bahwa model EfficientNetB3 mencapai akurasi keseluruhan sebesar 86%, membuktikan kemampuan model dalam mendukung proses diagnosis tumor otak secara cepat dan akurat. Dengan implementasi ini, penelitian diharapkan dapat memberikan kontribusi signifikan bagi deteksi dini tumor otak dan peningkatan kualitas perawatan pasien di dunia medis.

PENDAHULUAN

Penyakit tumor otak merupakan salah satu penyakit mematikan bagi manusia. Penyakit ini berada pada posisi ke-10 sebagai penyebab dari kematian manusia dengan angka mortalitas sebesar 4,25 per 100.000 penduduk per tahun (Winnarto et al., 2022). Selain itu, di Indonesia, tumor otak berada pada posisi ke-5 sebagai penyebab kematian pada manusia (Digdoyo et al., 2022). Tumor otak merupakan pertumbuhan abnormal sel-sel didalam otak yang dapat mempengaruhi fungsi otak

normal. Salah satu penyebab penyakit ini merupakan kelainan pada gen yang bertugas untuk mengatur pertumbuhan sel otak akibat perubahan struktur gen atau keabnormalan struktur kromosom sehingga menyebabkan berubahnya cara kerja gen tersebut. Terdapat dua tipe utama tumor pada otak yaitu tumor yang tidak bersifat kanker dan tumor ganas (Jesika et al., 2024).

Melakukan deteksi dini pada penyakit tumor otak dapat berdampak besar bagi pasien untuk meningkatkan harapan hidup. Hal ini dikarenakan sifat tumor yang dapat dengan cepat menyebar serta menyerang ke jaringan lain (Winnarto et al., 2022). Untuk melakukan deteksi penyakit tumor otak, salah satu cara yang dapat dilakukan melalui pencitraan medis *Magnetic Resonance Imaging* (MRI). Citra MRI dapat menghasilkan gambar yang secara detail menampilkan struktur anatomi otak yang kemudian dideteksi secara manual oleh ahli patologi atau ahli radiologi untuk mendiagnosis hasil MRI tersebut (Passa et al., 2023). Namun, diagnosis yang dilakukan secara manual akan membutuhkan durasi yang lebih panjang. Terlebih lagi, jumlah tenaga medis dan peralatan pendukung yang terbatas menjadi salah satu faktor yang menyulitkan proses pemulihan pasien yang mengidap tumor otak (Digdoyo et al., 2022).

Waktu penanganan yang menjadi penentu harapan hidup pasien membuat waktu diagnosa menjadi hal yang krusial untuk dipertimbangkan. Pendeteksian secara manual dapat menghabiskan waktu yang panjang serta rawan risiko kesalahan yang tinggi (Akbar et al., 2023). Sehingga dibutuhkan metode yang dapat meningkatkan efektivitas dalam proses diagnosis serta meningkatkan akurasi dalam pengambilan keputusan untuk menentukan penyakit tumor otak (Jesika et al., 2024). Dengan berkembangnya teknologi saat ini, terdapat terobosan yang dapat menggantikan proses diagnosis secara manual. Hal ini dapat dilakukan dengan menggunakan kecerdasan buatan.

Pada penelitian terdahulu, Jesika et al. (2024) melakukan penelitian untuk mendeteksi tumor otak dan mengklasifikasikan citra MRI ke dalam tiga kelas, yaitu tumor *meningioma*, tumor *pituitary*, dan citra otak sehat, menggunakan algoritma *Naive Bayes* yang menghasilkan akurasi sebesar 68%, presisi 67%, dan *recall* 66%. Selanjutnya, penelitian oleh Winnarto et al. mengklasifikasikan citra MRI menjadi empat kelas, yaitu *Giloma Tumor*, *Meningioma Tumor*, *No Tumor*, dan *Pituitary Tumor*. Penelitian ini mengimplementasikan arsitektur *MobileNetV2* menggunakan teknik *transfer learning*, menghasilkan akurasi sebesar 88.64%, presisi 90%, dan *recall* 89%.

Penelitian ini bertujuan untuk mengimplementasikan arsitektur *EfficientNetB3* dalam klasifikasi penyakit tumor otak pada citra MRI. Arsitektur ini dipilih karena kemampuannya dalam menyeimbangkan efisiensi komputasi dengan akurasi, sehingga diharapkan dapat memberikan hasil yang baik dalam proses identifikasi tumor otak. Dengan pendekatan ini, penelitian ini diharapkan dapat mendukung proses diagnosis yang lebih cepat serta akurat, sehingga dapat membantu meningkatkan kualitas perawatan bagi pasien.

TINJAUAN PUSTAKA

1. Tumor Otak

Tumor otak merupakan salah satu jenis penyakit yang melibatkan pertumbuhan sel-sel abnormal di dalam otak. Kondisi ini dapat mempengaruhi fungsi normal otak dan dibedakan menjadi dua jenis utama, yaitu tumor jinak yang tidak bersifat kanker dan tumor ganas yang memiliki potensi menyebar ke jaringan lain (Jesika et al., 2024). Penyebab utama tumor otak meliputi kelainan genetik, perubahan struktur gen, atau keabnormalan pada kromosom yang mengakibatkan terganggunya regulasi pertumbuhan sel otak.

2. Machine Learning

Machine Learning merupakan pendekatan di mana komputer belajar dari data tanpa aturan eksplisit. Berbeda dengan pemrograman tradisional, Machine Learning fokus pada analisis data, di mana komputer mengenali pola dari contoh dan membuat keputusan berdasarkan data. Tujuan utama dari Machine Learning merupakan komputer mampu belajar dengan sendiri tanpa bantuan dari manusia dan penyesuaian tindakan (Futoma et al. 2020).

3. Deep Learning

Deep learning merupakan cabang dari pembelajaran mesin yang menggunakan jaringan saraf tiruan dengan banyak lapisan untuk memodelkan data secara hierarkis. Teknik ini meniru cara kerja otak manusia dalam memproses informasi, yang memungkinkan komputer untuk mengenali pola yang kompleks dalam data besar, seperti gambar, teks, atau suara. Dalam konteks ini, deep learning berfungsi untuk mengekstraksi fitur dari data input secara bertahap, dari fitur sederhana hingga kompleks, melalui proses pelatihan berbasis algoritma backpropagation (Kaushik, 2023). Proses ini memungkinkan model untuk belajar dari data yang sangat besar dan beragam, yang sering kali tidak dapat ditangani dengan metode pembelajaran mesin tradisional.

4. CNN

Convolutional Neural Network (CNN) merupakan jaringan saraf yang dirancang khusus untuk memproses data berbentuk gambar dengan menggunakan lapisan konvolusi untuk mengekstraksi fitur lokal. Struktur dasar dari CNN terdiri dari beberapa lapisan, termasuk lapisan konvolusi, pooling, dan fully connected. Lapisan konvolusi berfungsi untuk mendeteksi pola lokal dalam gambar, sedangkan lapisan pooling digunakan untuk mengurangi dimensi data dan mengurangi kompleksitas komputasi, yang pada gilirannya membantu dalam menghindari overfitting (Oumarou (2024), Kandel et al., 2020). Dengan pendekatan ini, CNN mampu menangkap representasi spasial hierarkis dari gambar, yang sangat penting dalam pengenalan objek dan klasifikasi gambar (Chen et al., 2020).

5. EfficientNetB3

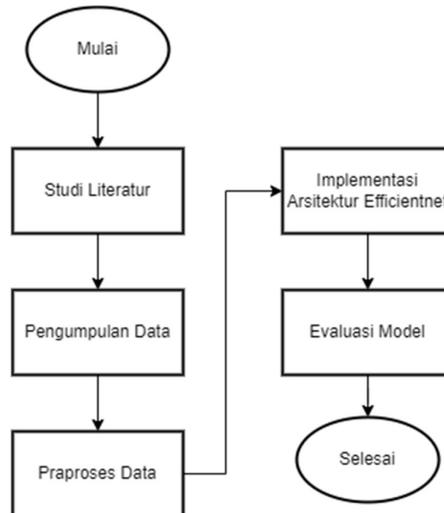
EfficientNetB3 merupakan varian arsitektur EfficientNet yang dirancang untuk klasifikasi citra secara efisien. Model ini diperkenalkan oleh Tan dan Le dalam makalah mereka yang berjudul "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks" pada tahun 2019. Dalam penelitian tersebut, mereka mengembangkan metode scaling kompaun yang mengoptimalkan lebar, kedalaman, dan resolusi citra masukan, sehingga memungkinkan model untuk mencapai performa tinggi dengan efisiensi komputasi yang optimal (Tan, 2019). Teknik scaling ini memungkinkan EfficientNet untuk mengatasi masalah yang sering dihadapi oleh arsitektur CNN tradisional, seperti overfitting dan kebutuhan akan sumber daya komputasi yang tinggi (Tan, 2019).

METODE PENELITIAN

Penelitian ini dilakukan melalui serangkaian langkah sistematis untuk menyelesaikan permasalahan yang diangkat. Proses dimulai dengan studi literatur, diikuti oleh pengumpulan data, tahap praproses data, implementasi arsitektur, hingga evaluasi model. Semua tahapan ini dirancang untuk memastikan penelitian berjalan sesuai dengan tujuan. Diagram alur metodologi penelitian yang menggambarkan tahapan tersebut dapat dilihat pada gambar 1.

Studi Literatur

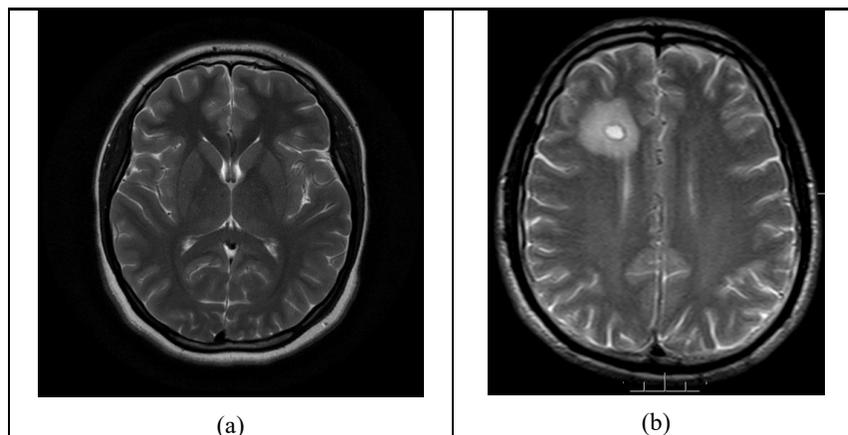
Studi literatur dilakukan untuk mengacu pada teori-teori relevan seperti arsitektur EfficientNetB3, model EfficientNetB3, CNN, dan teknik pendukung lainnya. Sumber yang digunakan meliputi publikasi ilmiah, artikel penelitian, dan diskusi komunitas. Penelusuran ini juga mencakup pemahaman tentang jaringan saraf tiruan, deep learning, pemrosesan citra digital, serta aplikasi MRI dalam diagnosis tumor otak. Referensi yang digunakan disertakan dalam daftar pustaka untuk transparansi dan kemudahan akses.



Gambar 1. Tahapan Metodologi Penelitian

Pengumpulan Data

Pada penelitian ini dataset yang digunakan berasal dari Kaggle, platform penyedia dataset terbuka. Dataset berjudul “Brain MRI Images for Brain Tumor Detection” oleh Navoneel Chakrabarty, berisi 253 gambar MRI otak: 98 gambar normal dan 155 gambar abnormal (dengan tumor). Link dataset dapat diakses di “[Kaggle](#)”. Data tersebut dibagi menjadi dua bagian yaitu untuk data latih dan data uji dimana rasio pembagiannya yaitu 80:20. Berikut contoh sampel citra MRI dari dataset ini.



Gambar 2. (a) MRI otak normal, (b) MRI otak abnormal.

Praproses Data

Pada tahap preprocessing data, citra diubah ke ukuran 224x224 pixel dan dinormalisasi ke skala 0-1. Langkah ini memastikan data input seragam, mengurangi skala data, dan mempercepat konvergensi pelatihan model, meningkatkan efisiensi dan akurasi model dalam mengenali pola.

Implementasi Arsitektur EfficientNetB3

Model yang digunakan untuk klasifikasi citra MRI adalah EfficientNetB3, dipilih karena performa optimal dan efisiensi parameter. Proses implementasi menggunakan input berukuran 224x224 piksel RGB sesuai dengan spesifikasi EfficientNetB3 yang telah dilatih dengan dataset ImageNet. Base model menggunakan konfigurasi `include_top=False` dan bobot dari ImageNet untuk transfer learning. Layer tambahan seperti Batch Normalization, Dense Layer (256 neuron), dan dropout 45% diterapkan untuk meningkatkan performa dan mencegah overfitting. Output layer menggunakan aktivasi softmax untuk klasifikasi multi-kelas. Model dikompilasi dengan Adamax, learning rate 0.001, dan loss function categorical crossentropy, menghasilkan model EfficientNetB3 yang dimodifikasi untuk klasifikasi citra MRI.

Evaluasi Model

Tahap evaluasi bertujuan menilai kinerja model dan memastikan hasil penelitian sesuai tujuan. Dalam klasifikasi citra, metrik seperti akurasi, presisi, recall, F1-score, dan AUC digunakan. Analisis false positive dan false negative membantu mengidentifikasi kelemahan model. Cross-validation digunakan untuk mengukur generalisasi pada data baru. Data augmentasi meningkatkan keragaman data, dan perbandingan dengan model lain menilai keunggulan. Evaluasi juga melibatkan interpretasi hasil untuk memastikan relevansi penelitian.

HASIL DAN PEMBAHASAN

Model Arsitektur

Pada penelitian ini, arsitektur model yang digunakan dirancang untuk klasifikasi pada dataset gambar dengan memanfaatkan transfer learning berbasis EfficientNetB3. Model ini dipilih karena efisiensinya dalam menangani data visual skala besar dan kemampuannya menghasilkan representasi fitur yang berkualitas tinggi. Berikut merupakan Ringkasan arsitektur model setelah dilakukan proses `model.summary()`:

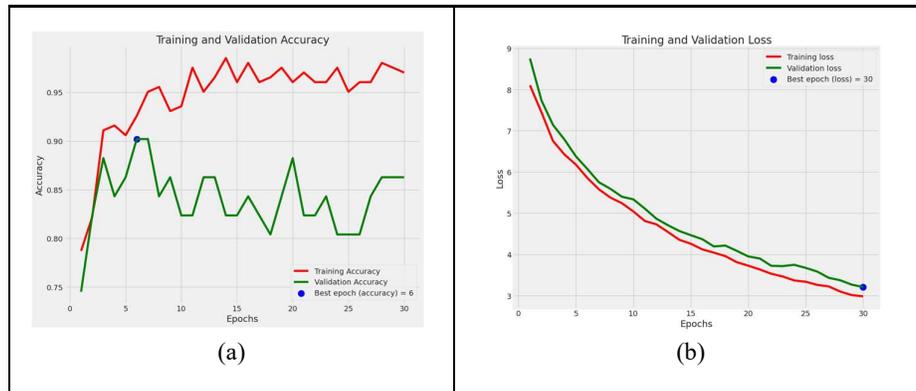
```
----- MODEL -----  
  
Model: "sequential_1"  
-----  
Layer (type)                Output Shape                Param #  
-----  
efficientnetb3 (Functional) (None, 1536)                10783535  
  
batch_normalization_1 (Batc (None, 1536)                6144  
hNormalization)  
  
dense_2 (Dense)              (None, 256)                393472  
  
dropout_1 (Dropout)          (None, 256)                0  
  
dense_3 (Dense)              (None, 2)                  514  
  
-----  
Total params: 11,183,665  
Trainable params: 11,093,290  
Non-trainable params: 90,375  
-----  
  
SUCCESS CREATE...!!
```

Gambar 3. Ringkasan Model Arsitektur

Hasil Model Performance

Pada bagian ini, dilakukan analisis performa model melalui visualisasi grafik training loss, validation loss, serta training accuracy dan validation accuracy. Grafik loss yang menurun menunjukkan model mengurangi kesalahan pada data training dan meningkatkan prediksi pada data

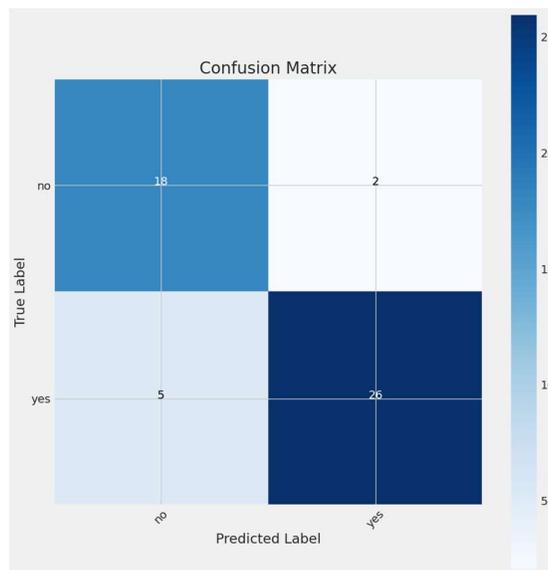
baru. Training accuracy yang meningkat menunjukkan model terlatih dengan baik, namun validation accuracy yang meningkat seiring epoch menandakan kemampuan generalisasi pada data baru. Epoch dengan validasi accuracy terbaik menunjukkan performa optimal model. Hasil visualisasi ini membantu mengevaluasi kemampuan model dalam memprediksi data dengan akurasi tinggi dan memahami tren loss serta akurasi selama pelatihan. Berikut merupakan hasil Model Performance.



Gambar 4. (a) Training and Validation , (b) Training and Validation Loss

Grafik a menunjukkan akurasi training yang stabil meningkat, sementara akurasi validation berfluktuasi dengan best epoch di epoch ke-6. Grafik b menunjukkan penurunan loss pada training dan validation, dengan best epoch di epoch ke-30. Model menunjukkan performa baik, namun fluktuasi pada validation perlu diperhatikan untuk menghindari overfitting.

D. Confusion Matrics and Classification Report



Gambar 5. Confusion Matrics

Confusion Matrix pada Gambar 5 menunjukkan visualisasi dari distribusi prediksi model terhadap data aktual. Matriks ini terdiri dari empat kuadran: True Positive (TP), False Positive (FP), False Negative (FN), dan True Negative (TN). Warna pada matriks mencerminkan intensitas nilai, di mana warna yang lebih gelap menandakan nilai yang lebih tinggi. Hasil ini menggambarkan kemampuan model dalam mengklasifikasikan data dengan benar dan salah untuk masing-masing

kategori. Model pada penelitian ini berhasil melakukan prediksi dengan benar pada 18 sampel kelas “no” dan 26 sampel kelas “yes”. Selain itu, model melakukan salah prediksi pada 2 sampel untuk kelas “no” (False Positive) dan 5 sampel untuk kelas “yes” (False Negative).

	precision	recall	f1-score	support
no	0.78	0.90	0.84	20
yes	0.93	0.84	0.88	31
accuracy			0.86	51
macro avg	0.86	0.87	0.86	51
weighted avg	0.87	0.86	0.86	51

Gambar 6. Classification Report

Classification Report pada Gambar 6 memuat matrik evaluasi seperti precision, recall, F1-score, dan support untuk masing-masing kelas ("no" dan "yes"). Precision mengukur akurasi prediksi positif, recall mengukur kemampuan model mendeteksi semua sampel positif, dan F1-score merupakan rata-rata harmonis antara precision dan recall. Selain itu, nilai akurasi keseluruhan model, macro average, dan weighted average juga disajikan untuk memberikan gambaran kinerja model secara keseluruhan.

Hasil menunjukkan bahwa model memiliki performa yang baik dengan rata-rata F1-score sebesar 0.86, menunjukkan keseimbangan antara precision dan recall. Namun, evaluasi lebih lanjut dapat dilakukan untuk meningkatkan kinerja model jika diperlukan.

KESIMPULAN

Hasil penelitian ini menunjukkan bahwa penerapan dataset citra otak pada model EfficientNetB3 yang didukung oleh proses preprocessing data yang optimal menghasilkan performa yang sangat baik. Hal ini dibuktikan dengan nilai rata-rata F1-score sebesar 0,86, yang mengindikasikan keseimbangan yang baik antara tingkat presisi dan sensitivitas model dalam mengklasifikasikan citra. Analisis lebih lanjut terhadap grafik performa model memperlihatkan kemampuan generalisasi yang cukup solid pada data baru, meskipun terdapat sedikit fluktuasi pada nilai akurasi validasi selama proses pelatihan. Namun, fluktuasi tersebut masih berada dalam batas yang wajar dan tidak mengurangi keandalan model secara keseluruhan. Dengan performa yang baik ini, pendekatan berbasis kecerdasan buatan seperti ini diharapkan dapat memberikan kontribusi yang signifikan dalam mendukung diagnosis medis yang lebih cepat, tepat, dan akurat. Selain itu, pendekatan ini memiliki potensi besar untuk meningkatkan efisiensi dalam proses klasifikasi citra tumor, yang pada akhirnya dapat memberikan dampak positif bagi dunia medis, khususnya dalam penanganan penyakit yang berkaitan dengan tumor otak.

DAFTAR PUSTAKA

- [1] S. Jesika, S. A. P. Zai, W. P. Ananta, R. R. Sitorus, H. Syahputra, dan F. Ramadhani, "Implementasi Algoritma Naive Bayes dalam Meningkatkan Akurasi Diagnosa Penyakit Tumor Otak," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 11, no. 3, pp. 136–144, Sep. 2024.
- [2] O. Akbar, E. Utami, dan D. Ariatmanto, "Deteksi Tumor Otak Melalui Gambar MRI Berdasarkan Vision Transformers dengan TensorFlow dan Keras," *Jurnal Informatika Universitas Pamulang*, vol. 8, no. 3, pp. 385–392, Sep. 2023, DOI: 10.32493/informatika.v8i3.32707.
- [3] M. N. Winnarto, M. Mailasari, dan A. Purnamawati, "Klasifikasi Jenis Tumor Otak Menggunakan Arsitektur MobileNetV2," *Jurnal SIMETRIS*, vol. 13, no. 2, Nov. 2022.

- [4] R. S. Passa, S. Nurmaini, dan D. P. Rini, "Deteksi Tumor Otak pada Magnetic Resonance Imaging Menggunakan YOLOv7," *Jurnal Ilmiah Matrik*, vol. 25, no. 2, pp. 114–122, Aug. 2023.
- [5] A. Digdoyo, T. Surawan, A. S. B. Karno, D. R. Irawati, dan Y. Efendi, "Deteksi Dini Tumor Otak Menggunakan Metode Deep Learning Arsitektur CNN ResNet-152," *Jurnal Teknologi*, vol. 9, no. 2, pp. 114–122, 2022, DOI: <https://doi.org/10.31479/jtek.v9i2.128>.
- [6] Passa, E., Lestari, T., dan Andriani, R., "Peranan MRI dalam deteksi dini tumor otak: Studi komparasi," *Journal of Medical Imaging and Diagnosis*, vol. 11, no. 4, pp. 123-130, 2023.
- [7] Jesika, S., Ramdani, F., dan Fadilah, N., "Klasifikasi tumor otak menggunakan algoritma Naive Bayes pada citra MRI," *Journal of Computer and Health Informatics*, vol. 15, no. 1, pp. 12-20, 2024.
- [8] Kaushik, P. (2023). Deep learning and machine learning to diagnose melanoma. *International Journal of Research in Science and Technology*, 13(01), 58-72. <https://doi.org/10.37648/ijrst.v13i01.008>
- [9] Oumarou, H., Siradj, Y., Rizal, R., & Candra, F. (2024). Stabilization of image classification accuracy in hybrid quantum-classical convolutional neural network with ensemble learning. *Innovation in Research of Informatics (INNOVATICS)*, 6(1). <https://doi.org/10.37058/innovatics.v6i1.10437>
- [10] Kandel, I., Castelli, M., & Popovič, A. (2020). Musculoskeletal images classification for detection of fractures using transfer learning. *Journal of Imaging*, 6(11), 127. <https://doi.org/10.3390/jimaging6110127>
- [11] Chen, B., Huang, Y., Xia, Q., & Zhang, Q. (2020). Nonlocal spatial attention module for image classification. *International Journal of Advanced Robotic Systems*, 17(5). <https://doi.org/10.1177/1729881420938927>
- [12] Tan, M. and Le, Q. V. (2019). Efficientnet: rethinking model scaling for convolutional neural networks.. <https://doi.org/10.48550/arxiv.1905.11946>