

Klasifikasi Jenis Penyakit Tumor Otak Menggunakan *Convolutional Neural Network* Arsitektur *Inception-V3*

Hendra Ady Juliartadi^{1*}, Andi Kurniawan Nugroho¹, Sri Heranurweni¹, Titik Nurhayati¹

¹ Teknik Elektro Fakultas Teknik Universitas Semarang; Jl. Soekarno Hatta, RT.7/RW.7, Tlogosari Kulon, Kec. Pedurungan, Kota Semarang, Jawa Tengah 50196

Received: 17-07-2025
Accepted: 22-07-2025

Keywords:

Tumor Otak;
CNN;
CLAHE;
Inception-V3;

Correspondent Email:

hendraady1607@gmail.com

Abstrak. Tumor otak merupakan salah satu penyakit yang paling mengancam nyawa dan memerlukan diagnosis yang akurat. Salah satu tantangan utama dalam mendiagnosis tumor otak terletak pada kesamaan visual antara jenis tumor pada gambar MRI, yang seringkali menyulitkan klasifikasi manual. Untuk mengatasi hal ini, sistem klasifikasi berbasis deep learning dikembangkan menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur Inception-V3. Data yang digunakan diperoleh dari Kaggle dan terdiri dari empat kelas glioma, meningioma, pituitari, dan notumor. Penelitian ini menerapkan teknik pre-procesing seperti Contrast Limited Adaptive Histogram Equalization (CLAHE) dan augmentasi data untuk meningkatkan kinerja model. Berbagai kombinasi hyperparameters diuji, dan kinerja terbaik dicapai dengan batch size 32 dan learning rate 0,0001. Model mencapai accuracy 97,92%, precision 98%, recall 98%, dan F1-score 98%. Selain itu, arsitektur Inception-V3 dibandingkan dengan arsitektur lain yaitu MobileNetV2 dan ResNet50, yang mencapai accuracy 83,67% dan 71,79%. Hasil menunjukkan bahwa arsitektur Inception-V3 unggul dalam mengklasifikasikan jenis tumor otak dari gambar MRI. Penelitian ini diharapkan dapat berkontribusi dalam meningkatkan akurasi dan kecepatan diagnosis tumor otak bagi medis.

Abstract. Brain tumors are one of the most life-threatening diseases and require accurate diagnosis. One of the main challenges in diagnosing brain tumors lies in the visual similarity between tumor types in MRI images, which often makes manual classification difficult. To address this issue, a deep learning-based classification system was developed using the Convolutional Neural Network (CNN) method with the Inception-V3 architecture. The data used was obtained from Kaggle and consisted of four classes: glioma, meningioma, pituitary, and non-tumor. This study applied pre-processing techniques such as Contrast Limited Adaptive Histogram Equalization (CLAHE) and data augmentation to improve model performance. Various combinations of hyperparameters were tested, and the best performance was achieved with a batch size of 32 and a learning rate of 0.0001. The model achieved an accuracy of 97.92%, precision of 98%, recall of 98%, and an F1-score of 98%. Additionally, the Inception-V3 architecture was compared with other architectures, namely MobileNetV2 and ResNet50, which achieved accuracies of 83.67% and 71.79%, respectively. The results indicate that the Inception-V3 architecture excels in classifying brain tumor types from MRI images. This study is expected to contribute to improving the accuracy and speed of brain tumor diagnosis for medical professionals.

1. PENDAHULUAN

Penyakit yang mematikan di dunia dan dapat menyerang siapa saja salah satunya yaitu tumor otak, penyakit ini ditandai dengan pertumbuhan sel atau jaringan abnormal di otak ini secara medis dapat mengancam nyawa seseorang jika tidak ditandai dengan baik. Data dari WHO total kasus baru penyakit tumor otak di negara Indonesia mencapai 5.734 kasus serta angka kematian berada di posisi 11 dengan total 5.259 kasus [1].

Diagnosis penyakit tumor otak saat ini dilakukan oleh radiolog dan dokter ahli menggunakan teknologi (MRI) *Magnetic Resonance Imaging* agar menghasilkan gambar citra detail organ dalam tubuh manusia secara rinci. Diagnosis gambar medis oleh dokter ahli sering kali terbatas oleh subjektivitas dan ketidakpastian. Tantangan utama muncul dari kemiripan hasil visual citra antara jenis tumor otak tersebut. Oleh karena itu, diperlukan solusi yang lebih objektif dan konsisten dalam pengenalan dan klasifikasi penyakit otak melalui hasil citra MRI.

Dengan kemajuan teknologi, pengolahan citra digital dan algoritma kecerdasan buatan telah menjadi alternatif yang efektif untuk menggantikan proses manual tersebut. Metode *deep learning* merupakan teknologi yang menjanjikan dalam bidang klasifikasi, salah satunya menggunakan pendekatan metode *Convolutional Neural Network*. CNN adalah metode kecerdasan buatan yang menggunakan operasi konvolusi untuk mengekstrak fitur dari gambar. CNN memiliki berbagai model arsitektur yang baik digunakan untuk klasifikasi gambar, deteksi objek, segmentasi citra, dan lain-lain [2].

Hasil penerapan metode CNN dalam berbagai penelitian menunjukkan performa akurasi yang beragam. Penelitian sebelumnya menerapkan pendekatan CNN untuk mendeteksi tumor otak yang memiliki jenis glioma, meningioma, pituitary dan notumor dari gambar MRI yang di dapatkan di kaggle. Teknik yang di gunakan untuk proses klasifikasi yaitu *pre-processing* dengan augmentasi. Kemudian menghasilkan akurasi sebanyak 90% [3].

Penelitian lain menggunakan dataset yang berasal dari Kaggle, terdiri dari 253 citra MRI. Data diproses melalui normalisasi dan

pengubahan ukuran menjadi 224x224 piksel. Model menggunakan teknik *transfer learning* dengan *pretrained weights* dari ImageNet. Penelitian menghasilkan bahwa model EfficientNetB3 mencapai akurasi keseluruhan sebesar 86% [4]. Sementara itu pada penelitian lain dataset yang di gunakan pada penelitian ini berjumlah 3064 citra MRI. Pengklasifikasi memanfaatkan model Inception V3 yang telah dilatih. Sistem mencapai akurasi tinggi 97,84% [5].

Penelitian lain menerapkan metode CNN dengan arsitektur MobileNetV2, dan menggunakan 3167 citra MRI. Model dilatih menggunakan *adam optimizer*, dengan 32 batch dan 30 epoch. Pada penelitian ini didapatkan nilai akurasi sebesar 88.64%, precision 90% dan recall 89% [6]. Pada penelitian ini menggunakan dataset kanker paru-paru yang memiliki 309 data. Teknik uji yang digunakan pada dataset kanker paru-paru ini adalah *percentage split* dan *k-fold cross validation* dengan algoritma Naive Bayes dan Iterative Dichotomizer3 (ID3). Hasil penelitian yang menggunakan teknik uji *percentage split*, diperoleh nilai akurasi, presisi dan recall tertinggi pada algoritma Naive Bayes yaitu akurasi sebesar 87%, presisi sebesar 91% dan recall sebesar 94% untuk kelas YES (*positif lung cancer*) [7]. Penelitian berikutnya bertujuan untuk mengevaluasi kinerja dua arsitektur (CNN), yaitu InceptionV3 dan VGG16, dalam klasifikasi deteksi kanker otak menggunakan dataset MRI. Hasil penelitian menunjukkan bahwa model InceptionV3 mencapai akurasi sebesar 91,67% dengan test loss 0,3329, sementara VGG16 mencapai akurasi sebesar 82,14% dengan test loss 0,5027 [8].

Berdasarkan penelitian sebelumnya yang sudah dilakukan, maka solusi untuk masalah penelitian ini adalah dengan menggunakan metode *deep learning* CNN. Penelitian ini bertujuan untuk mengembangkan model klasifikasi tumor otak menggunakan teknologi kecerdasan buatan, khususnya menggunakan penerapan metode *Convolutional Neural Network* dengan arsitektur Inception-V3 dengan menerapkan fungsi *pre-procesing* menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dan augmentasi serta melakukan uji coba *hyperparameters* untuk mendapatkan hasil

akurasi yang bagus. Beberapa model arsitektur seperti MobileNetV2, ResNet50 juga di terapkan sebagai perbandingan evaluasi hasil. Tujuan utamanya adalah menciptakan model *deep learning* yang dapat membedakan atau klasifikasi jenis-jenis tumor otak seperti glioma, meningioma, pituitary, dan notumor dari citra medis dengan tingkat akurasi yang paling tinggi.

2. TINJAUAN PUSTAKA

2.1. Tumor Otak

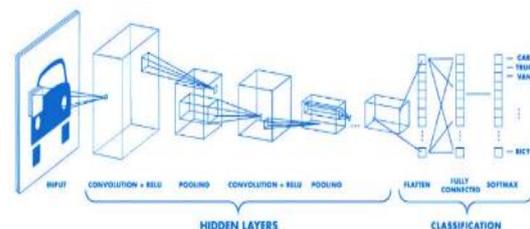
Tumor adalah pertumbuhan sel yang tidak normal. Tubuh secara konstan membuat sel baru untuk membantu kita tumbuh, mengganti jaringan yang sudah usang, dan menyembuhkan cedera. Secara normal, sel berkembang biak dan mati secara teratur, sehingga setiap sel baru menggantikan sel yang hilang. Namun, terkadang, sel menjadi tidak normal dan terus tumbuh pada kanker padat, seperti tumor otak, sel-sel yang tidak normal membentuk massa atau benjolan yang disebut tumor.

Secara umum, tumor otak dibagi menjadi tumor otak primer dan tumor otak sekunder. Tumor otak primer merupakan jenis kanker yang muncul langsung di dalam otak. Kanker ini dapat menyebar ke bagian lain dari saraf. Tumor otak kelompok sekunder adalah kanker bermula di bagian lain dari tubuh dan kemudian bergerak melalui aliran darah. Hal ini dikenal sebagai kanker sekunder atau metastasis [9].

2.2. Convolutional Neural Network

CNN adalah arsitektur jaringan saraf dalam feed-forward yang terdiri dari beberapa layer konvolusi, masing-masing diikuti oleh layer penyatuan, fungsi aktivasi, dan normalisasi batch opsional. Saat gambar bergerak melalui jaringan, itu menjadi lebih kecil, sebagian besar karena pengumpulan maksimal. Layer terakhir menampilkan prediksi probabilitas kelas [10]. CNN adalah algoritma pembelajaran mendalam yang populer, umumnya digunakan untuk menganalisis citra seperti pengenalan objek, klasifikasi objek, dan lain-lain. Gambar 1 merupakan tampilan dari jaringan CNN. Jaringan tersebut terdiri dari beberapa lapisan dan masing-masing memiliki fungsi. Fungsi dari *convolution layer* atau lapisan konvolusi yaitu menjalankan operasi konvolusi pada

gambar masukan dengan sejumlah penapis. Setiap penapis menghasilkan luaran yang disebut *feature map* [11].



Gambar 1. Jaringan CNN

Pooling layer berfungsi untuk mengurangi ukuran spasial dari matriks fitur hasil konvolusi. Hal tersebut bertujuan untuk mengurangi daya komputasi yang diperlukan untuk memproses data melalui pengurangan dimensi, kemudian terdapat dua jenis *pooling* yaitu *max pooling* dan *average pooling*. Kemudian *activation layer* merupakan keluaran yang disaring menyediakan yang lain fungsi matematika lain yang disebut aktivasi. ReLU, singkatan dari *rectified linear unit*, adalah fungsi aktivasi yang paling umum dalam ekstraksi fitur. Tujuan utama dari fungsi aktivasi adalah untuk menentukan output akhir dari jaringan saraf, seperti 'ya' atau 'tidak'. Aktivasi memetakan nilai keluaran antara -1 dan 1, 1 dan 0, dan seterusnya [12].

Fully connected layer ini semua nilai yang sebelumnya berbentuk matriks berubah menjadi sebuah matriks satu dimensi, atau yang lebih dikenal sebagai vector sebelum nilai dari aktivasi tersebut dapat masuk pada layer ini. Lapisan *fully connected layer* (FC) menghasilkan vektor dimensi K, dalam hal ini K adalah jumlah kelas yang dapat diprediksi oleh jaringan. Selanjutnya *softmax function* adalah perhitungan kemungkinan dari masing – masing kelas target data semua kelas target yang memungkinkan dan membantu untuk menentukan kelas target untuk input yang diberikan.

2.3. Arsitektur Inception-V3

Arsitektur inception-V3 ini merupakan model *pre-trained* untuk melakukan proses klasifikasi, Inception-V3 juga merupakan perpaduan dari peningkatan Inception-V2 yang mempunyai beberapa keunggulan yaitu proses konvolusi yang lebih kecil dan pengurangan

ukuran grid yang dapat meminimalisir perhitungan [13]. Arsitektur Inception-V3 secara konsisten dianggap unggul untuk tugas klasifikasi citra medis seperti MRI otak karena kemampuannya mengekstraksi fitur multiskala secara efisien. Modul Inception menggabungkan konvolusi dengan berbagai ukuran kernel (1×1, 3×3, 5×5) secara paralel, sehingga memungkinkan model mengenali pola lokal sekaligus global dalam satu citra [14].

2.4. Confusion Matrix

Kinerja suatu model klasifikasi dapat diukur berdasarkan kinerja akurasinya berdasarkan *Confusion Matrix* [15]. Untuk menilai keefektifan model yang dikembangkan dalam mengklasifikasikan kelas-kelas yang berbeda dari data input, kami menggunakan empat metrik, *accuracy*, sensitivitas atau *recall*, *precision*, dan nilai *F1-score*. Nilai-nilai metrik ini diukur dan diperoleh melalui *confusion matrix*.

Accuracy merupakan rasio dari jumlah prediksi yang benar mengenali seberapa baik model bekerja. *Recall* didefinisikan sebagai proporsi antara jumlah total nilai aktual dan nilai positif yang diantisipasi dengan benar. *Precision* adalah rasio dari jumlah prediksi benar terhadap total jumlah prediksi positif. Sedangkan *F1-Score* adalah rata-rata harmonis dari skor *precision* dan *recall* sehingga memberikan gambaran terkait keseimbangan model yang dihasilkan [16]. Berikut merupakan rumus perhitungan pada masing-masing metrik evaluasi tersebut.

$$Accuracy = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (1)$$

$$Recall = \frac{TP}{(TP+FN)} \quad (2)$$

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

$$F1 - score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (4)$$

Keterangan :

TP = True Positif

TN = True Negatif

FP = False Positif

FN = False Negatif

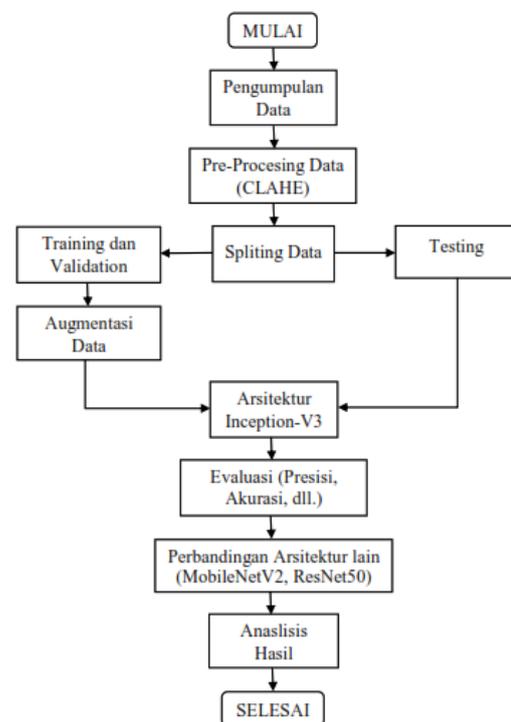
3. METODE PENELITIAN

Penelitian ini dikerjakan melalui beberapa prose atau tahapan yang saling

berkaitan, meliputi pengumpulan dataset, *pre-processing*, pembagian dataset, augmentasi data, klasifikasi menggunakan metode CNN arsitektur Inception-V3 dengan menerapkan uji coba *hyperparameters*, evaluasi hasil, perbandingan dengan arsitektur lainnya, dan menganalisa hasil.

3.1. Diagram Proses Sistem

Diagram proses sistem klasifikasi jenis penyakit tumor otak dapat dilihat pada Gambar 2 berikut ini.



Gambar 2. Diagram Proses Sistem

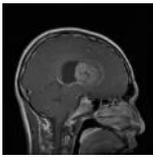
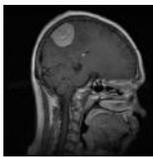
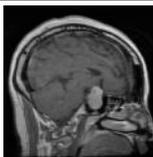
Gambar 2 merupakan proses perancangan sistem klasifikasi jenis penyakit tumor otak menggunakan CNN dengan arsitektur Inception-V3 yang membutuhkan beberapa tahapan. Tahapan pertama melakukan studi literature terhadap penelitian terdahulu yang bertujuan untuk dijadikan pondasi dalam penyusunan penelitian, selanjutnya yaitu pengumpulan data yang diperlukan pada penelitian ini. Tahapan ketiga dilakukan pra-pengolahan dataset seperti preproceasing, augmentasi dan spliting pada data sehingga data siap digunakan. Tahapan berikutnya adalah melatih dan menguji menggunakan model utama yang digunakan adalah CNN dengan arsitektur Inception-V3, pada data yang sudah

dilakukan pra-pengolahan dataset serta arsitektur MobileNetV2 dan ResNet50 sebagai model pembanding. Tahapan terakhir adalah analisis, evaluasi hasil performa terbaik yang didapatkan.

3.2. Pengumpulan Data

Proses awal yang dilakukan yaitu pencarian dan pengumpulan data sesuai kriteria yang diinginkan. Dataset yang digunakan pada penelitian ini berasal dari website Kaggle [17]. Dataset ini terdiri dari 4 kelas dengan total gambar yaitu 7.157 dan kelas glioma tumor terdiri dari 1.621 gambar, kelas meningioma tumor terdiri dari 1.775 gambar, kelas pituitary tumor tumor terdiri dari 1.757 gambar, dan kelas notumor terdiri dari 2.000 gambar. Berikut Tabel 1 merupakan contoh gambar dataset dari 4 kelas tumor.

Tabel 1. Jenis Tumor Otak

Contoh Gambar	Jenis Tumor
	Glioma
	Meningioma
	Pituitary
	Notumor

3.3. Pre-processing

Pada tahap *pre-processing* data ini gambar diubah ukurannya dimensinya untuk mengurangi dimensi data tanpa kehilangan fitur-fitur penting. Tujuannya adalah meningkatkan efisiensi komputasi selama pelatihan dengan mengubah ukuran dimensi gambar dari 512x512 *pixel* menjadi 299x299 *pixel*. Gambar yang lebih kecil mempercepat pelatihan, serta membantu jaringan

menggeneralisasi lebih baik karena ada lebih sedikit data yang disesuaikan.

Untuk meningkatkan kontras gambar sebelum input ke arsitektur Inception-V3 digunakanlah fungsi CLAHE atau *Contrast Limited Adaptive Histogram Equalization*. Oleh karena itu, penggunaan CLAHE sebagai tahap pra-pemrosesan dapat membantu arsitektur Inception-V3 dalam menangani tugas-tugas pengolahan gambar yang kompleks.

3.4. Pembagian Data

Pembagian data atau *Splitting* data di gunakan untuk memisahkan dataset yang awalnya terdiri dari 7.157 file kemudian dibagi menjadi tiga bagian yaitu data pelatihan (train) sebanyak 70%, data validasi (val) sebanyak 15%, dan data pengujian (test) sebanyak 15%. Setiap masing-masing file terdapat 4 jenis tumor, hasil dari proses *splitting* data dapat dilihat pada Tabel 2. Data pelatihan mendapatkan bagian yang banyak karena data tersebut nanti di gunakan untuk pelatihan model. Data validasi digunakan untuk menguji dan memvalidasi model yang telah dilatih dengan dataset pelatihan.

Tabel 2. Pembagian Data

Tumor	Asli	Train	Val	Test
Glioma	1.621	1.134	243	244
Meningioma	1.775	1.175	252	252
Pituitary	1.757	1.229	263	263
Notumor	2.000	1.400	300	300

3.5. Augmentasi

Augmentasi adalah metode yang efektif untuk mengurangi *overfitting* pada arsitektur yang disebabkan oleh data sampel yang terbatas. Teknik ini bekerja dengan memperkirakan ruang probabilitas data dengan memanipulasi sampel input. Data augmentasi bermanfaat untuk membangun model *Deep Learning* yang baik, dimana error validasi harus terus berkurang seiring dengan error training dan meningkatkan hasil akurasi dari program [18].

3.6. Arsitektur Inception-V3

Proses pembangunan model CNN dengan arsitektur Inception-V3 untuk klasifikasi jenis penyakit tumor otak dalam gambar MRI. Model dalam arsitektur ini

mencakup komponen-komponen sebagai berikut. Lapisan pada bagian input yang diatur sebesar 299×299 dan 3 sebagai penanda citra RGB, *Global Average Pooling* 2D, lapisan *Dense* (1024), lapisan *Dense* terakhir 4. Lapisan *Global Average Pooling* 2D berfungsi untuk menyederhanakan data, mengurangi jumlah parameter, menekan *overfitting*, serta mendukung arsitektur Inception-V3 dalam menghasilkan representasi global citra secara lebih efisien. *Global Average Pooling* 2D membantu mempertahankan informasi penting yang dibutuhkan untuk tugas klasifikasi dan mengurangi kompleksitas model.

Sementara lapisan *Dense* 1024 membantu dalam proses pembelajaran yang lebih dalam dan kompleks, mendukung ekstraksi fitur yang lebih baik dari data gambar pra-pemrosesan yang telah diekstraksi melalui *Global Average Pooling* 2D, penggunaan *Batch Normalization* menstabilkan dan mempercepat pelatihan model dan membantu menangani risiko *overfitting*. Penggunaan *Dense* 4 dengan aktivasi *softmax* berfungsi untuk menghasilkan jumlah output yaitu 4 kelas jenis penyakit tumor.

Pada proses *training* atau pelatihan arsitektur yang sudah di buat di atas kemudian di uji menggunakan *Adam Optimizer* dan jumlah *epoch* yang di gunakan yaitu 20 epoch. Kemudian di lakukan uji coba *hyperparameters* dari jenis *learning rate* nya yaitu 0.01, 0.001, 0.0001, dan 0.00001. Untuk ukuran *batch size* yang di uji coba yaitu 8, 16, dan 32.

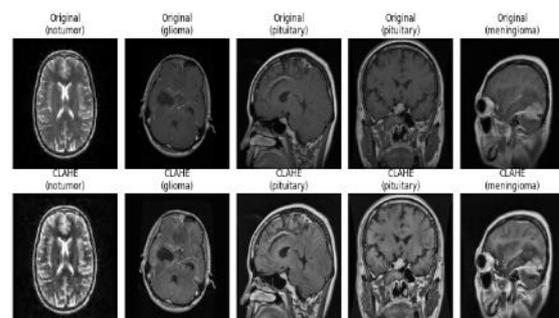
3.6. Evaluasi Hasil

Metode yang di gunakan untuk evaluasi performa pada hasil *training* arsitektur ini menggunakan *Confusion Matrix* sehingga menghasilkan laporan klasifikasi gambaran yang komprehensif tentang kualitas model dan membantu dalam mengevaluasi kinerjanya secara keseluruhan. Evaluasi performa dilakukan dengan menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* pada dataset klasifikasi tumor otak untuk menilai seberapa baik model dapat belajar dan mengenali citra secara akurat yang sesuai dengan tingkat akurasi tertinggi.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pre-processing

Pre-processing merupakan langkah penting sebelum citra dimasukkan ke proses selanjutnya, yaitu pelatihan dan pengujian model. Dalam penelitian ini, untuk meningkatkan efisiensi komputasi selama pelatihan dengan dilakukan perubahan ukuran dimensi gambar atau disebut *resize* dari ukuran gambar dataset asli sebesar 512×512 *pixel* kemudian diubah menjadi ukuran 299×299 *pixel*. Kemudian fungsi *Contrast Limited Adaptive Histogram Equalization* (CLAHE) diterapkan pada citra MRI tumor otak untuk meningkatkan kualitas dan kontras citra. Penggunaan CLAHE bertujuan demi mendapatkan citra yang lebih rinci, lebih jelas, dan lebih mudah dibedakan, sehingga dapat membantu proses ekstraksi fitur dan belajar pada saat pelatihan nantinya. Gambar 3 berikut ini merupakan hasil gambar dari *pre-processing* menggunakan CLAHE.



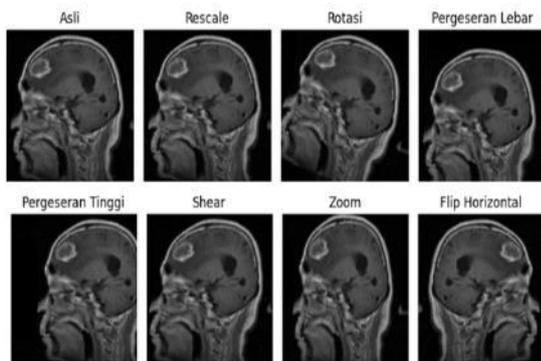
Gambar 3. Hasil *Pre-processing* CLAHE

4.2. Hasil Augmentasi

Dalam penelitian ini, menggunakan *library Image Data Generator* dari pustaka *Keras* untuk melakukan augmentasi data pada gambar. Setelah itu, dilakukan normalisasi dengan mengonversi nilai piksel gambar ke dalam rentang $[0,1]$ menggunakan fungsi *rescale*, sehingga model dapat memproses data secara lebih efisien dan meningkatkan stabilitas dalam pelatihan.

Dalam proses augmentasi data diterapkan beberapa fungsi, seperti *rescale* dengan parameter $1/255$, kemudian *rotation* dengan parameter 20° . Fungsi *width_shift* dan fungsi *height_shift* dengan parameter 0.2. Berikutnya fungsi *shear_range* atau transformasi *shearing* gambar dengan parameter 0.2. Berikutnya fungsi *zoom_range*

atau memperbesar gambar secara acak dengan parameter 0.2. Kemudian fungsi *horizontal_flip* atau membalik gambar secara mendatar dengan parameter 0.2, Gambar 4 berikut ini merupakan hasil dari proses augmentasi data.



Gambar 4. Hasil Augmentasi

4.3. Uji Coba Hyperparameters

Dalam proses pelatihan model klasifikasi jenis tumor otak berbasis CNN menggunakan arsitektur Inception-V3, dilakukan serangkaian uji coba terhadap *hyperparameters* untuk menemukan konfigurasi yang optimal. *Hyperparameters* yang diuji dalam eksperimen ini adalah *Batch Size* dan *Learning Rate*, karena keduanya memiliki pengaruh signifikan terhadap kinerja dan konvergensi model selama proses pelatihan.

Uji coba dilakukan dengan cara memvariasikan *batch size*, yaitu menggunakan nilai 8, 16, dan 32. Untuk *learning rate*, yaitu 0.01, 0.001, 0.0001, dan 0.00001 serta menggunakan *Adam Optimizer*. Seluruh kombinasi antara *batch size* dan *learning rate* tersebut diuji dengan tetap menggunakan arsitektur InceptionV3 dan *preprocessing* gambar yang telah distandarkan. Hasil dari uji coba ini digunakan sebagai dasar pemilihan konfigurasi *hyperparameters* terbaik yang selanjutnya diterapkan pada proses pelatihan akhir model.

Tabel 3 merupakan hasil pengujian bahwa kombinasi *hyperparameters* sangat mempengaruhi kinerja model. Pada pengujian ke 11 konfigurasi dengan *batch size* 32 dan *learning rate* 0.0001 memberikan hasil terbaik dengan nilai *accuracy* sebesar 97,92%. Tujuan dari uji coba ini adalah untuk menemukan konfigurasi *hyperparameters* terbaik yang memiliki kinerja paling baik dalam melakukan klasifikasi jenis penyakit tumor otak

berdasarkan nilai *accuracy* dari masing-masing konfigurasi tersebut.

Tabel 3. *Hyperparameters*

Batch Size	Learning Rate	Epoch	Accuracy
8	0,01	20	94,50
8	0,001	20	96,41
8	0,0001	20	95,84
8	0,00001	20	93,11
16	0,01	20	95,66
16	0,001	20	96,98
16	0,0001	20	96,41
16	0,00001	20	93,39
32	0,01	20	95,56
32	0,001	20	96,79
32	0,0001	20	97,92
32	0,00001	20	93,77

4.4. Evaluasi Hasil

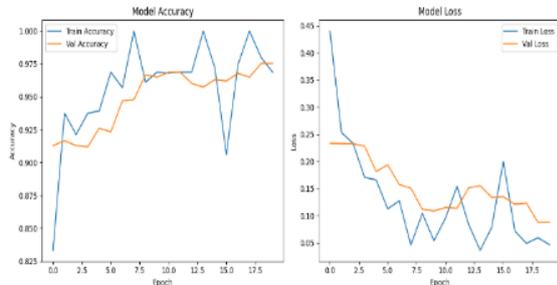
Hasil proses implementasi *hyperparameters* pada pengujian dilakukan menggunakan metode CNN dengan arsitektur *Inception-V3* dan *Adam Optimizer* untuk meningkatkan hasil akurasi. Hasil tersebut yang paling tinggi akurasi mencapai 97,92 % dimana proses tersebut dijelaskan sebagai berikut.

4.4.1. Training

Proses *training* dan *validation* dilakukan dengan menggunakan dataset yang telah ditingkatkan menggunakan CLAHE dan augmentasi, terdiri dari 2.725 sampel untuk data *training*, memiliki 4.938 sampel. Sedangkan untuk *validation*, terdapat 1059 sampel. Hasil dari *training* dan *validation* ditampilkan dalam bentuk grafik yang menunjukkan *accuracy* dan kerugian *loss*, serta hasil dari konfigurasi *hyperparameters* yang telah diaplikasikan.

Gambar 5 menampilkan grafik *accuracy* dan *loss* untuk berbagai konfigurasi. Hasil *training* arsitektur *Inception-V3* menunjukkan bahwa proses *training* berlangsung secara optimal dan stabil. Akurasi pelatihan meningkat secara konsisten hingga mendekati 99%, sementara akurasi validasi juga meningkat dan stabil di atas 96%. Pada grafik *loss*, terlihat penurunan yang signifikan pada nilai *loss* pelatihan dari sekitar 0,43 menjadi di bawah 0,05, dan meskipun terdapat sedikit fluktuasi pada *loss* validasi, nilainya tetap rendah dan tidak menunjukkan gejala *overfitting*.

Grafik ini menunjukkan bahwa model mampu mengoptimalkan bobotnya dengan baik dan menghasilkan prediksi yang akurat dan konsisten.



Gambar 5. Grafik Arsitektur Inception-V3

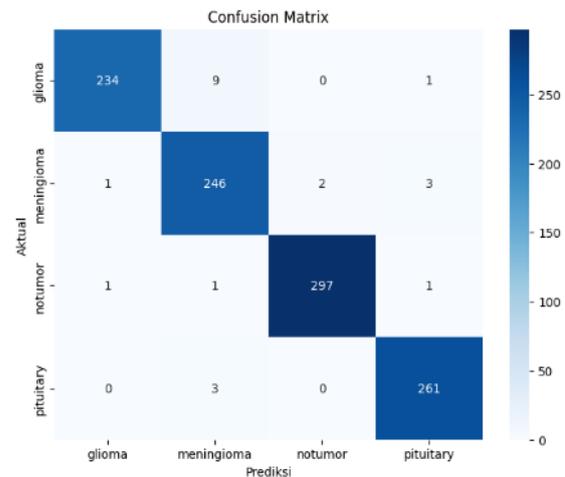
4.4.2. Testing

Proses *testing*, dilakukan untuk mengevaluasi model seberapa akurat sistem dalam mengklasifikasikan data *testing* yang terdiri dari 4 kelas dan berjumlah 1060 citra. Untuk mengukur tingkat akurasi, digunakan *Confusion Matrix* yang membantu dalam menghitung nilai *accuracy*, *precision*, *recall*, dan *F1-score*.

Tabel 4. Hasil Klasifikasi Inception-V3

Jenis Tumor	Precision	Recall	F1-score
Glioma	0,99	0,96	0,97
meningioma	0,95	0,98	0,96
Notumor	0,99	0,99	0,99
Pituitary	0,98	0,99	0,98
Accuracy			0,98
Macro Avg	0,98	0,98	0,98
Weight Avg	0,98	0,98	0,98

Tabel 4 ini menyajikan hasil klasifikasi evaluasi performa model klasifikasi jenis penyakit tumor otak berdasarkan empat kelas: glioma, meningioma, notumor, dan pituitary. Metrik evaluasi yang digunakan mencakup *precision*, *recall*, dan *F1-score*. Gambar 6 merupakan hasil evaluasi *Confusion Matrix* model klasifikasi yang dihasilkan pada *training* dengan *hyperparameter batch size 32 learning rate 0,0001* dan menghasilkan nilai *accuracy* mencapai 97,92%, *precision 98%*, *recall 98%*, dan *F1-score 98%* yang dapat dilihat pada Tabel 4.



Gambar 6. Confusion Matrix Inception-V3

4.5. Perbandingan Arsitektur MobileNet-V2 dan ResNet50

Dalam penelitian ini, dilakukan perbandingan arsitektur yang digunakan dalam *Convolutional Neural Network (CNN)* Inception-V3 dengan dua arsitektur CNN populer lainnya yaitu MobileNetV2 dan ResNet50. Tujuan dari perbandingan ini adalah untuk menilai efektivitas arsitektur dalam mengklasifikasikan jenis penyakit tumor otak berdasarkan gambar MRI.

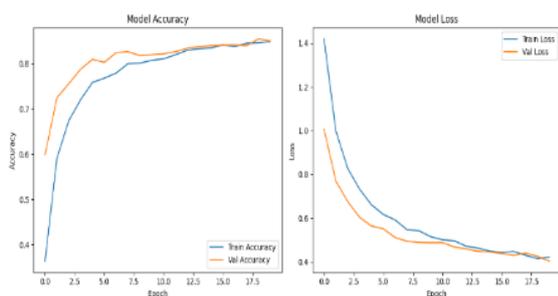
Tabel 5. Perbandingan Arsitektur

Arsitektur	Batch Size	Learning Rate	Epoch	Accuracy
Inception-V3	32	0,0001	20	97,92
Mobile-NetV2	32	0,0001	20	83,67
ResNet50	32	0,0001	20	71,79

Tabel 5 merupakan hasil klasifikasi perbandingan arsitektur yang digunakan pada penelitian ini. Klasifikasi tersebut menggunakan *batch size* dan *learning rate* yang sama dan menggunakan *adam* sebagai *optimizer* utama. Berikut ini merupakan hasil proses klasifikasi dan *confusion matrix* dari kedua arsitektur tersebut yang digunakan sebagai pembanding.

4.5.1. MobileNetV2

Dalam proses perbandingan klasifikasi jenis tumor otak yang pertama menggunakan arsitektur *MobileNetV2* ini telah di uji coba menggunakan *batch size* 32, *learning rate* 0,0001 dan menggunakan *adam optimizer* arsitektur tersebut di *training* menggunakan *epoch* yang berjumlah 20, hasil dari proses *training* dapat dilihat Gambar 7. Kemudian hasil *testing* dari klasifikasi arsitektur ini dapat dilihat pada Gambar 8 dan Tabel 6.



Gambar 7. Grafik Arsitektur MobileNetV2

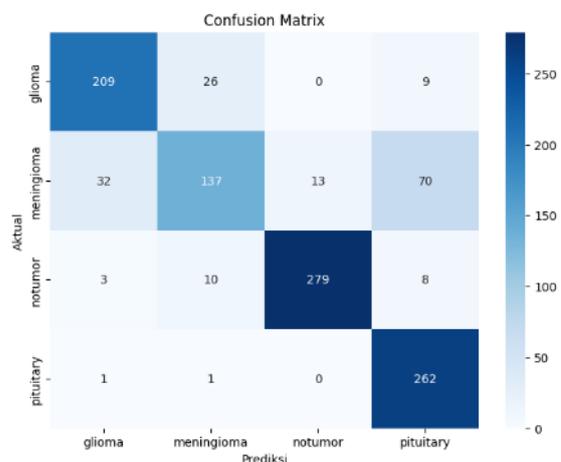
Gambar 7 menunjukkan hasil grafik pelatihan arsitektur *MobileNetV2* menunjukkan peningkatan akurasi dan penurunan loss secara konsisten pada data pelatihan dan validasi. Pada pelatihan *epoch* ke 5 mulai mengalami peningkatan yang dapat membrikan hasil akurasi yang baik. Akurasi rata-rata pada grafik pelatihan dan validasi model tersebut mendekati angka 88%, serta nilai *loss* atau kerugian keduanya terus menurun dan stabil, menandakan model belajar dengan baik.

Tabel 6. Hasil Klasifikasi MobileNetV2

Jenis Tumor	Precision	Recall	F1-score
Glioma	0,85	0,86	0,85
Meningioma	0,79	0,54	0,64
Notumor	0,96	0,93	0,94
Pituitary	0,75	0,99	0,85
Accuracy			0,84
Macro Avg	0,84	0,83	0,82
Weight Avg	0,84	0,84	0,83

Tabel 6 ini menyajikan hasil klasifikasi evaluasi performa model klasifikasi jenis penyakit tumor otak dari arsitektur *mobilenetv2* berdasarkan

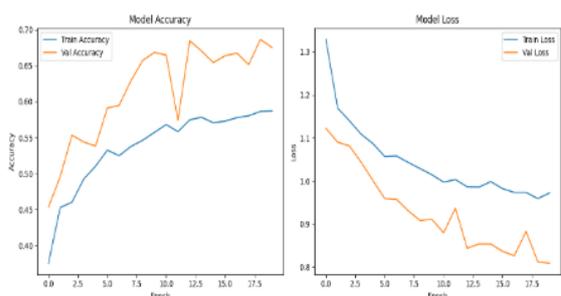
empat kelas yang terdiri dari glioma, meningioma, notumor, dan pituitary. Menghasilkan metrik evaluasi yang digunakan mencakup *precision*, *recall*, *F1-score*, dan menghasilkan *accuracy* sebanyak 83,67%. Gambar 8 merupakan hasil *confusion matrix* yang ditampilkan, model klasifikasi menunjukkan performa yang cukup baik secara umum, dibuktikan dengan jumlah prediksi benar, dan prediksi salah yang ada dalam gambar tersebut, namun masih memiliki kelemahan dan kesalahan dalam mengenali kelas tertentu.



Gambar 8. Confusion Matrix MobileNetV2

4.5.2. ResNet50

Dalam proses perbandingan klasifikasi jenis tumor otak yang kedua menggunakan arsitektur *ResNet50* ini telah di uji coba menggunakan *batch size* 32, *learning rate* 0,0001 dan menggunakan *adam optimizer* arsitektur tersebut di *training* menggunakan *epoch* yang berjumlah 20, hasil dari proses *training* dapat dilihat pada Gambar 9. Hasil *testing* dari klasifikasi arsitektur ini dapat dilihat pada Gambar 10 dan Tabel 7.



Gambar 9. Grafik Arsitektur ResNet50

Gambar 9 menunjukkan grafik pelatihan arsitektur *ResNet50* menunjukkan bahwa akurasi validasi lebih tinggi dari akurasi pelatihan, menandakan model mampu menghindari *overfitting*. Akurasi rata-rata pada grafik pelatihan dan validasi model tersebut mendekati angka 72%. Penurunan loss pada kedua grafik menunjukkan proses pembelajaran berjalan baik, namun fluktuasi akurasi validasi mengindikasikan bahwa model masih kurang stabil.

Tabel 7. Hasil Klasifikasi ResNet50

Jenis Tumor	Precision	Recall	F1-score
Glioma	0,66	0,61	0,63
Meningioma	0,70	0,42	0,52
Notumor	0,90	0,85	0,87
Pituitary	0,63	0,95	0,76
Accuracy			0,72
Macro Avg	0,72	0,71	0,70
Weight Avg	0,73	0,72	0,71

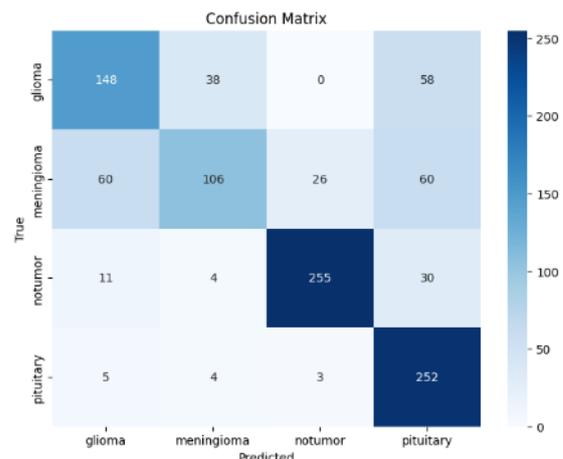
Tabel 7 menunjukkan hasil klasifikasi evaluasi performa model klasifikasi jenis penyakit tumor otak berdasarkan empat kelas: glioma, meningioma, notumor, dan pituitary. Menghasilkan metrik evaluasi yang digunakan seperti *precision*, *recall*, *F1-score*, dan menghasilkan *accuracy* sebanyak 71,79%. Gambar 10 merupakan hasil *confusion matrix* yang ditampilkan, model klasifikasi menunjukkan performa yang cukup baik secara umum, namun masih memiliki banyak kelemahan dan kesalahan dalam mengenali kelas tertentu.

4.6. Analisa Hasil

Berdasarkan hasil pelatihan, validasi dan pengujian yang dilakukan, arsitektur Inception-V3 menunjukkan performa klasifikasi yang sangat baik dalam mendeteksi jenis penyakit tumor otak melalui citra MRI. Model ini berhasil mencapai nilai akurasi sebesar 97,92%, dengan *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,98. Hasil ini menunjukkan bahwa Inception-V3 tidak hanya unggul dalam mengklasifikasikan satu kelas tertentu, tetapi juga mampu mengenali keempat kelas tumor

otak secara seimbang dan konsisten. Hal ini juga didukung oleh hasil dari *confusion matrix*

Analisa berikutnya dilakukan dengan membandingkan hasil klasifikasi menggunakan arsitektur MobileNetV2 dan ResNet50. Kedua model tersebut menggunakan konfigurasi *hyperparameters* yang sama dengan Inception-V3, yaitu *batch size* 32 dan *learning rate* 0.0001 selama 20 epoch. Hasil pengujian menunjukkan bahwa arsitektur MobileNetV2 memperoleh akurasi sebesar 83,67%, sedangkan arsitektur ResNet50 hanya mencapai 71,79%. Meskipun arsitektur MobileNetV2 unggul dari segi efisiensi dan waktu pelatihan, namun akurasinya masih lebih rendah dibandingkan arsitektur Inception-V3. Begitu pula dengan ResNet50, meskipun memiliki kedalaman jaringan yang tinggi, performanya kurang stabil dalam mendeteksi detail tumor otak yang kompleks.



Gambar 10. Confusion Matrix ResNet50

5. KESIMPULAN

Berdasarkan dari hasil penelitian, perancangan, pembuatan, pengujian hingga analisa sistem klasifikasi jenis penyakit tumor otak menggunakan metode CNN dengan arsitektur Inception-V3, didapatkan kesimpulan yaitu :

- Dengan menggunakan metode CNN dengan arsitektur Inception-V3 sangat efektif dalam mengklasifikasikan jenis penyakit tumor otak berdasarkan citra MRI. Dengan menerapkan teknik *pre-processing* menggunakan CLAHE, augmentasi data untuk meningkatkan performa model, pembagian dataset ke dalam *training*,

validation, dan *test*, hingga pelatihan model dengan uji coba *hyperparameters* yang terbaik menggunakan *batch size* 32 dan *learning rate* 0,0001. Pada proses *testing* yang menghasilkan *confusion matrix* model berhasil mencapai akurasi tinggi hingga 97,92% dengan nilai *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,98% dan menghasilkan prediksi citra yang benar atau *true positif* pada jenis glioma sebanyak 234, meningioma sebanyak 246, notumor sebanyak 297, dan pituitary sebanyak 261. Hasil ini menunjukkan bahwa model tidak hanya akurat secara umum, tetapi juga mampu menjaga konsistensi kinerja antar kelas.

- b. Evaluasi performa arsitektur Inception-V3 menunjukan bahwa hasilnya lebih unggul dalam seluruh metrik evaluasi *accuracy*, *precision*, *recall*, dan *F1-score* dibandingkan dengan arsitektur lain seperti MobileNetV2 dan ResNet50. Dengan metode teknik yang sama serta *batch size*, *learning rate*, *optimizer* yang sama menunjukan hasil dari arsitektur MobileNetV2 mencapai nilai *accuracy* 83,67%, *precision* 0,84%, *recall* 0,83%, dan *F1-score* 0,82%. Kemudian arsitektur ResNet50 mencapai nilai *accuracy* 71,79%, *precision* 0,72%, *recall* 0,71%, dan *F1-score* 0,70%. Hal ini menunjukan bahwa arsitektur kedua yang paling baik dalam penggunaannya sebagai klasifikasi jenis tumor otak yaitu arsitektur MobileNetV2 dan yang ketiga yaitu arsitektur ResNet50.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak program studi Teknik Elektro Fakultas Teknik Universitas Semarang, serta semua tim dan pihak-pihak terkait yang telah sama-sama saling memberikan dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] Global Cancer Observatory, "Global Cancer Observatory in Indonesia, 2022," *Int. J. Cancer*, vol. 149, no. 4, pp. 778–789, 2022, doi: 10.1002/ijc.33588.
- [2] N. Abiwinanda, M. Hanif, S. T. Hesaputra, A. Handayani, and T. R. Mengko, "Brain Tumor Classification Using Convolutional

Neural," L. Lhotska, L. Sukupova, I. Lacković, and G. S. Ibbott, Eds., Singapore: Springer Nature Singapore, 2019, pp. 183–189.

- [3] N. P. Arsyad, R. Wulanningrum, and ..., "Implementasi Convolutional Neural Network Pada Deteksi Tumor Otak," *Pros. SEMNAS ...*, vol. 8, pp. 1316–1323, 2024, [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/inotek/article/view/5069>
- [4] D. Lizard, S. Dimara, S. W. Putri, and R. Amelia, "Penerapan Convolutional Neural Network (CNN) dalam Klasifikasi Citra MRI untuk Deteksi Tumor Otak Manusia," vol. 4, no. 2, pp. 70–77, 2023, doi: 10.31284/j.kernel.2023.v4i2.6960.
- [5] M. Agarwal, G. Rani, A. Kumar, P. K. K, R. Manikandan, and A. H. Gandomi, "Deep learning for enhanced brain Tumor Detection and classification," *Results Eng.*, vol. 22, no. March, p. 102117, 2024, doi: 10.1016/j.rineng.2024.102117.
- [6] M. N. Winnarto, M. Mailasari, and A. Purnamawati, "Klasifikasi Jenis Tumor Otak Menggunakan Arsitektur Mobilenet V2," *J. SIMETRIS*, vol. 13, no. 2, pp. 1–12, 2022.
- [7] P. Pratiwi, D. Dwifa, A. Desiani, A. Amran, and B. Suprihatin, "Klasifikasi Penyakit Kanker Paru-Paru Menggunakan Algoritma Naïve Bayes dan Iterative Dichotomizer 3 (ID3)," *Electr. J. Rekayasa dan Teknol. Elektro*, vol. 18, no. 1, pp. 69–80, 2024, doi: 10.23960/elc.v18n1.2519.
- [8] B. P. H. Aryo Bimo Wicaksono, "Analisis performa arsitektur cnn inceptionv3 dan vgg16 dalam klasifikasi deteksi kanker otak," vol. 10, no. 2, pp. 938–948, 2025.
- [9] Council Cancer, "Understanding Brain Tumours," *Indian J. Surg.*, vol. 11, no. 2, pp. 86–108, 2024.
- [10] B. Raharjo, *Deep Learning dengan Python*. Semarang: Yayasan Prima Agus Teknik, 2022.
- [11] R. Munir, "Convolutional Neural Network," pp. 1–45, 2022.
- [12] A. Raup, W. Ridwan, Y. Khoeriyah, S. Supiana, and Q. Y. Zaqiah, "Deep Learning dan Penerapannya dalam Pembelajaran," *Jiip - J. Ilm. Ilmu Pendidik.*, vol. 5, no. 9, pp. 3258–3267, 2022, doi: 10.54371/jiip.v5i9.805.
- [13] U. Ungkawa and G. A. L. Hakim, "Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3," vol. 11, no. 3, pp. 731–743, 2023.

- [14] Z. Rasheed *et al.*, “Brain Tumor Classification from MRI Using Image Enhancement and Convolutional Neural Network Techniques,” *Brain Sci.*, vol. 13, no. 9, 2023, doi: 10.3390/brainsci13091320.
- [15] H. Nurrani, A. K. Nugroho, and S. Heranurweni, “Image Classification of Vegetable Quality using Support Vector Machine based on Convolutional Neural Network,” *J. RESTI*, vol. 7, no. 1, pp. 168–178, 2023, doi: 10.29207/resti.v7i1.4715.
- [16] Y. S. Suprpto, Thomhert Siadari; Hanyani, “Pandangan Klasifikasi Penyakit Periodontal Berbasis Citra Gigi Berwarna Menggunakan Jaringan Syaraf Tiruan Konvolusional.PDF,” *JETT J. Elektro dan Telekomun.*, vol. 11, no. 2, pp. 13–19, 2024, doi: <http://doi.org/10.25124/jett.v11i2.8090>.
- [17] Tom Bracket, “Brain Tumor Dataset.” [Online]. Available: <https://www.kaggle.com/datasets/tombacket/brain-tumor-mri-data>.
- [18] D. Tsalsabila Rhamadiyahanti and Kusriani, “Analisa Performa Convolutional Neural Network dalam Klasifikasi Citra Apel dengan Data Augmentasi,” *J. Kaji. Ilm. Inform. dan Komput.*, vol. 5, no. 1, pp. 154–162, 2024, doi: 10.30865/klik.v5i1.2023.