

Penerapan Metode Transfer Learning Berbasis EfficientNet untuk Klasifikasi Tumor Otak pada Citra MRI

Dinda Putri Ramadani¹, Kurniabudi², Lola Yorita Astri³

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dinamika Bangsa, Jambi, Indonesia

Email: ¹dindaputriramadani4@gmail.com, ²kurniabudi@unama.ac.id, ³lolayoritaastri@unama.ac.id

Email Penulis Korespondensi: dindaputriramadani4@gmail.com

Artikel Info :

Artikel History :

Submitted : 23-02-2026

Accepted : 07-04-2026

Published : 30-04-2026

Kata Kunci:

Tumor_Otak;

Klasifikasi_Citra;

Transfer_Learning;

EfficientNet-B5; Deep_

Learning

Abstrak— Tumor otak merupakan salah satu penyakit berbahaya yang memerlukan deteksi dan diagnosis secara cepat serta akurat. Salah satu metode pencitraan medis yang umum digunakan dalam diagnosis tumor otak adalah *Magnetic Resonance Imaging* (MRI). Namun, proses identifikasi dan klasifikasi tumor otak pada citra MRI secara manual memerlukan waktu yang lama dan sangat bergantung pada keahlian dokter spesialis. Oleh karena itu, penelitian ini bertujuan untuk menerapkan metode *transfer learning* berbasis arsitektur *EfficientNet-B5* dalam melakukan klasifikasi tumor otak pada citra MRI secara otomatis. Dataset yang digunakan dalam penelitian ini adalah *Brain Tumor MRI Dataset* yang diperoleh dari platform *Kaggle*, yang terdiri dari empat kelas, yaitu *glioma*, *meningioma*, *pituitary tumor*, dan *no tumor*. Tahapan penelitian meliputi *preprocessing* citra, *data augmentation*, pembagian dataset menjadi data latih, data validasi, dan data uji, serta pelatihan model menggunakan pendekatan *transfer learning*. Arsitektur *EfficientNet-B5* digunakan sebagai *feature extractor* dengan penambahan lapisan klasifikasi khusus. Evaluasi performa model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, dan ROC-AUC. Hasil penelitian menunjukkan bahwa model *EfficientNet-B5* mampu memberikan performa klasifikasi yang sangat baik dengan nilai *accuracy* sebesar 98,75%, *precision* 98%, *recall* 98%, *F1-score* 98%, serta nilai ROC-AUC sebesar 0,99 pada klasifikasi multi-kelas. Hasil tersebut menunjukkan bahwa penerapan metode *transfer learning* berbasis *EfficientNet-B5* efektif dalam mengklasifikasikan tumor otak pada citra MRI dan berpotensi membantu tenaga medis dalam proses diagnosis secara lebih cepat dan akurat.

Abstract— Brain tumors are among the most dangerous diseases that require fast and accurate detection and diagnosis. One of the most commonly used medical imaging modalities for brain tumor diagnosis is *Magnetic Resonance Imaging* (MRI). However, manual identification and classification of brain tumors in MRI images are time-consuming and highly dependent on the expertise of medical specialists. Therefore, this study aims to apply a transfer learning method based on the *EfficientNet-B5* architecture for automatic brain tumor classification in MRI images. The dataset used in this research is the *Brain Tumor MRI Dataset* obtained from the *Kaggle* platform, which consists of four classes: *glioma*, *meningioma*, *pituitary tumor*, and *no tumor*. The research stages include image preprocessing, data augmentation, dataset splitting into training, validation, and testing sets, as well as model training using a transfer learning approach. The *EfficientNet-B5* architecture is utilized as a feature extractor with the addition of custom classification layers. Model performance is evaluated using accuracy, precision, recall, F1-score, confusion matrix, and ROC-AUC metrics. The results show that the *EfficientNet-B5* model achieves excellent classification performance with an accuracy of 98.75%, precision of 98%, recall of 98%, F1-score of 98%, and a ROC-AUC value of 0.99 in multi-class classification. These findings indicate that the *EfficientNet-B5*-based transfer learning approach is effective for classifying brain tumors in MRI images and has the potential to assist medical professionals in achieving faster and more accurate diagnostic processes.

Keywords:

Brain_Tumor;

Image_Classification;

Transfer_Learning;

EfficientNet-B5; Deep_

Learning

1. PENDAHULUAN

Perkembangan teknologi digital ini telah membawa perubahan dalam bidang kesehatan, terutama dalam upaya deteksi dan diagnosis penyakit. Salah satu penyakit yang masih menjadi perhatian global adalah tumor otak. Tumor otak adalah pertumbuhan sel abnormal di jaringan otak yang dapat mengganggu fungsi sistem saraf dan berpotensi menyebabkan kematian [1]. Berdasarkan data GLOBOCAN tahun 2022, jumlah kasus baru tumor otak dan sistem saraf pusat mencapai sekitar 321.476 kasus dengan kasus kematian mencapai sekitar 248.305 kasus di seluruh dunia [2]. Di Indonesia, tercatat 5.738 kasus baru tumor otak dengan 5.259 kematian [3]. Data tersebut menunjukkan bahwa kasus tumor otak masih tergolong tinggi dan memerlukan inovasi dalam metode deteksi dini.

Deteksi tumor otak dapat dilakukan dengan berbagai cara, salah satunya dengan anatomi citra kesehatan, contohnya adalah *Magnetic Resonance Imaging* (MRI) [4]. Citra MRI dapat menampilkan struktur otak secara

detail dan digunakan untuk membedakan berbagai jenis tumor otak seperti *glioma*, *meningioma*, *pituitary tumor*, serta kondisi normal tanpa tumor. Tumor otak dapat didiagnosa melalui citra MRI oleh dokter spesialis radiologi dan dokter spesialis saraf (*neurology*). Dalam hal ini, dokter radiologi bertugas menginterpretasikan gambar dan mengidentifikasi adanya kelainan pada jaringan otak, dan dokter spesialis saraf menggunakan hasil interpretasi tersebut untuk menentukan diagnosis selanjutnya dan rencana penanganan yang tepat. Mengdiagnosis tumor otak tidak dapat dilakukan dengan waktu yang singkat karena dokter harus mengidentifikasi dan segmentasi wilayah secara manual pada citra MRI [5].

Untuk mengatasi permasalahan tersebut, pemanfaatan teknologi *Deep Learning* metode *Convolutional Neural Network* (CNN) dalam analisis citra medis dapat membantu dokter dalam mengenali dan mendiagnosis jenis tumor otak pada pasien dengan hasil yang akurat dan tingkat kesalahan yang lebih rendah [1]. *Convolutional Neural Network* (CNN) adalah arsitektur jaringan saraf tiruan yang secara khusus dirancang untuk menganalisis data visual seperti gambar dan video [6]. Model CNN membutuhkan dataset besar dan sumber daya komputasi tinggi, yang sering menjadi kendala dalam penelitian medis dengan data terbatas [7]. Oleh karena itu, pendekatan *transfer learning* memungkinkan pemanfaatan model *Convolutional Neural Network* (CNN) yang sudah dilatih sebelumnya (*pre-trained model*) pada dataset besar seperti *ImageNet*, kemudian disesuaikan kembali (*fine-tuning*) dengan dataset baru yang memiliki karakteristik spesifik terhadap permasalahan yang diteliti [7], [8]. Salah satu arsitektur CNN yang digunakan dalam pendekatan *transfer learning* adalah *EfficientNet* yang mampu menyeimbangkan *depth*, *width*, dan *resolution* jaringan secara proporsional melalui konsep *compound scaling* [9].

Beberapa penelitian sebelumnya telah menunjukkan efektivitas penggunaan metode ini. Penelitian yang dilakukan oleh W. Hastomo yang menunjukkan bahwa, model *EfficientNet-B1* mencapai akurasi 98%, sedangkan *EfficientNet-B2* mencapai 96% dalam klasifikasi tumor otak pada citra MRI yang menggunakan *Dataset* dari *Brain Tumor Kaggle* [10]. Adapun penelitian yang dilakukan oleh S. Deepak dan P. Ameer menunjukkan penggunaan *transfer learning* berbasis *EfficientNet* pada citra MRI otak menghasilkan akurasi hingga 98% dalam klasifikasi jenis tumor otak [11]. Selain itu, penelitian yang dilakukan Vimala dkk. Menggunakan *EfficientNet* (B0–B4) untuk klasifikasi tumor otak yang menunjukkan hasil yang baik dengan akurasi tertinggi sebesar 99,06 % pada *EfficientNet-B2*. Namun, belum mengeksplorasi varian *EfficientNet* yang lebih tinggi, seperti *EfficientNet-B5* dimana memiliki keseimbangan optimal antara kedalaman jaringan, lebar layer, dan *input resolution* [12]. Dalam penelitian ini digunakan model *EfficientNet-B5* karena memiliki keseimbangan yang baik antara kompleksitas dan performa. *EfficientNet-B5* dipilih karena memiliki jumlah parameter dan ukuran model yang masih efisien, namun menawarkan peningkatan resolusi citra input dan kedalaman jaringan yang lebih tinggi dibandingkan varian B0–B4. Hal ini memungkinkan model untuk menangkap detail struktur jaringan otak dengan lebih akurat tanpa memerlukan sumber daya komputasi sebesar varian yang lebih tinggi seperti B6 atau B7 [13].

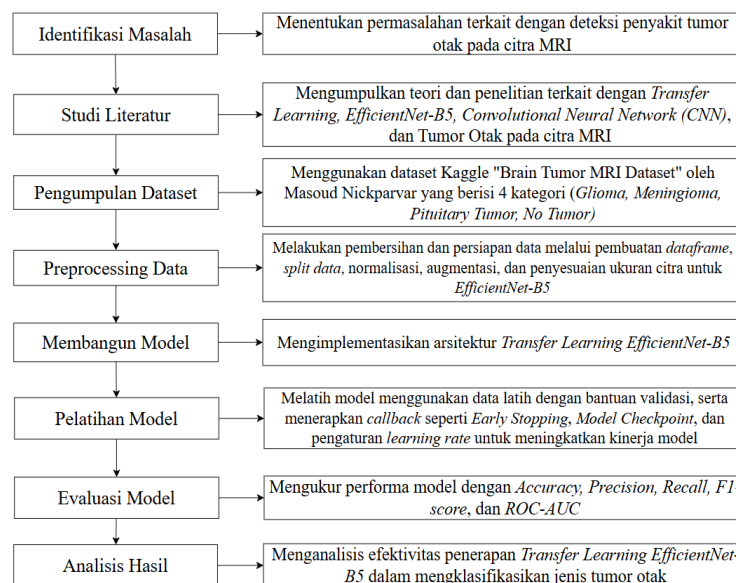
Penelitian sebelumnya yang menggunakan model *EfficientNet-B5* dilakukan oleh Sinaga dalam klasifikasi penyakit pada tanaman padi menunjukkan bahwa arsitektur *EfficientNet-B5* mampu mencapai akurasi sangat tinggi, yaitu 99,05% [14]. Penelitian dilakukan oleh Green Arther Sandag dkk. Menggunakan model *EfficientNet-B5* menunjukkan tingkat akurasi mencapai 99,22% dalam klasifikasi citra MRI penyakit Alzheimer. Hasil ini lebih tinggi dibandingkan dengan model lain seperti *EfficientNet-B1*, *B3*, *B7*, serta arsitektur konvensional seperti VGG16 dan VGG19 [15]. Oleh karena itu, penelitian ini diharapkan dapat mampu memberikan performa klasifikasi tumor otak yang tinggi sekaligus efisien untuk penelitian berbasis citra MRI dalam penggunaan model *EfficientNet-B5*.

Dengan demikian, penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi kinerja model *transfer learning* berbasis *EfficientNet-B5* dalam mengklasifikasikan tumor otak pada citra MRI ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary tumor*, dan *no tumor*. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem klasifikasi otomatis yang memiliki performa tinggi sekaligus efisien secara komputasi, sehingga dapat membantu tenaga medis dalam proses diagnosis yang lebih cepat, akurat, dan objektif.

2. METODOLOGI PENELITIAN

2.1 Kerangka Kerja Penelitian

Untuk memudahkan proses penelitian, dibutuhkan kerangka kerja yang menjelaskan setiap tahapan penelitian [16]. Kerangka kerja ini menjadi sebuah acuan utama dalam melaksanakan penelitian terkait dengan penerapan metode *Transfer Learning* berbasis *EfficientNet-B5* untuk klasifikasi tumor otak pada citra MRI. Adapun kerangka kerja penelitian yang dapat dilihat pada Gambar 1:



Gambar 1. Kerangka Kerja Penelitian

Berdasarkan pada Gambar 1 diatas berikut adalah penjelasan setiap tahap penelitian sebagai berikut:

1. Identifikasi Masalah

Tahapan ini berfokus pada mengidentifikasi suatu masalah utama dalam penelitian, yaitu mendiagnosis tumor otak tidak dapat dilakukan dengan waktu yang singkat karena dokter harus mengidentifikasi secara manual pada citra MRI yang membutuhkan ketelitian tinggi. Oleh karena itu, diperlukan sebuah sistem teknologi *Deep Learning* dengan metode *Convolutional Neural Network (CNN)* dalam analisis citra medis yang mampu membantu mempercepat dan meningkatkan akurasi identifikasi tumor otak. Penelitian ini berfokus pada empat jenis kondisi otak berdasarkan citra MRI, yaitu *glioma*, *meningioma*, *pituitary*, dan *non-tumor*.

2. Studi Literatur

Pada tahap ini dilakukan dengan menelaah berbagai referensi dari sumber jurnal atau penelitian terdahulu mengenai deteksi tumor otak pada citra MRI dengan pendekatan deep learning dan pemanfaatan transfer learning dalam klasifikasi citra medis. Studi ini bertujuan untuk memahami teori mengenai deteksi tumor otak, CNN, serta arsitektur *EfficientNet-B5* sebagai dasar pemilihan model yang digunakan dalam penelitian.

3. Pengumpulan Dataset

Pada tahap ini berfokus pada pengumpulan dataset. Penelitian ini menggunakan "Brain Tumor MRI Dataset" oleh Masoud Nickparvar dari platform Kaggle, yang memiliki 4 kategori, yaitu *glioma*, *meningioma*, *pituitary*, dan *no-tumor*. Dataset ini dipilih karena memiliki keragaman visual yang tinggi dan telah digunakan secara luas dalam penelitian serupa untuk klasifikasi tumor otak.

4. Preprocessing Data

Pada tahap ini, dilakukan preprocessing data untuk menyiapkan dan memastikan bahwa citra MRI dalam kondisi yang bersih, seragam dan siap digunakan pada proses pelatihan model. Proses dimulai dengan membuat *dataframe* yang memuat informasi lokasi file dan label kelas dari setiap citra, sehingga mempermudah proses pemetaan data, dilanjutkan dengan partisi dataset menjadi train test, validation, dan test-set. Setiap citra kemudian dinormalisasi menggunakan fungsi *preprocess_input* agar sesuai dengan standar *EfficientNet-B5*. Augmentasi data seperti *horizontal flip*, *rotation*, *width shift*, *height shift*, *zoom*, *brightness* diterapkan pada data latih untuk menambah keragaman citra dan mencegah *overfitting*. Selain itu, seluruh citra diubah ukurannya menjadi 456×456 piksel agar sesuai dengan kebutuhan arsitektur model. Tahapan ini memastikan bahwa data telah berada dalam format yang optimal untuk proses pelatihan.

5. Membangun Model

Tahap membangun model dilakukan dengan menerapkan pendekatan *transfer learning* menggunakan arsitektur *EfficientNet-B5* sebagai *feature extractor* utama. *EfficientNet-B5* dipilih karena kemampuannya dalam menyeimbangkan kedalaman, lebar, dan resolusi jaringan sehingga menghasilkan performa yang optimal pada tugas klasifikasi citra. Pada penelitian ini, lapisan top bawaan *EfficientNet-B5* dihilangkan dan diganti dengan lapisan klasifikasi baru yang disesuaikan dengan empat kelas tumor otak. Lapisan tambahan tersebut meliputi *Batch Normalization* untuk menstabilkan distribusi aktivasi, lapisan *Dense* berukuran 256 neuron dengan regularisasi L1 dan L2 untuk mengurangi *overfitting*, serta *Dropout* sebesar 0.45 guna menambah ketahanan model terhadap *noise*. Terakhir, ditambahkan lapisan *Dense* dengan aktivasi softmax sebagai *output* untuk menghasilkan probabilitas setiap kelas. Model kemudian dikompilasi menggunakan

optimizer Adamax, fungsi *loss categorical crossentropy*, dan metrik akurasi sehingga siap digunakan dalam proses pelatihan.

6. Pelatihan Model

Tahap pelatihan model dilakukan dengan menggunakan data latih yang telah melalui proses *preprocessing* dan augmentasi. Proses training dijalankan dengan memanfaatkan *data generator* yang secara otomatis memuat citra dalam bentuk *batch*, sehingga efisien untuk komputasi. Model dilatih menggunakan *optimizer Adamax* dengan *learning rate* 0.001 dan fungsi *loss categorical crossentropy*. Selama proses pelatihan, beberapa *callback* diterapkan untuk meningkatkan performa model, yaitu *Early Stopping* untuk menghentikan training ketika tidak terjadi peningkatan pada nilai validasi, *ReduceLROnPlateau* untuk menurunkan *learning rate* secara adaptif saat model mulai stagnan, serta *ModelCheckpoint* untuk menyimpan bobot terbaik berdasarkan akurasi validasi. Melalui mekanisme ini, model dapat belajar mengenali pola dari citra MRI secara bertahap sambil meminimalkan risiko *overfitting* dan memastikan performa terbaik pada data validasi.


7. Evaluasi Model

Tahap evaluasi model dilakukan untuk mengukur kinerja akhir model dalam mengklasifikasikan citra MRI tumor otak. Evaluasi dilakukan dengan menghitung beberapa metrik penting, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan ROC-AUC untuk setiap kelas. Selain itu, ditampilkan *confusion matrix* untuk melihat distribusi prediksi benar dan salah pada masing-masing kategori tumor. Metrik-metrik ini memungkinkan analisis menyeluruh terhadap kekuatan dan kelemahan model dalam mengenali setiap jenis tumor otak. Hasil evaluasi tersebut digunakan sebagai dasar untuk menentukan apakah model memiliki performa yang baik dan layak diterapkan pada kasus klasifikasi citra medis.

8. Analisis Hasil

Tahap analisis hasil dilakukan dengan menginterpretasikan metrik evaluasi yang diperoleh dari pengujian model, seperti *accuracy*, *precision*, *recall*, *F1-score*, ROC-AUC, serta *confusion matrix*. Melalui analisis ini dapat dilihat bagaimana kemampuan model dalam membedakan setiap kelas tumor otak, termasuk kelas yang paling mudah maupun paling sulit diprediksi. Nilai ROC-AUC membantu menilai performa model dalam skenario multi-kelas, sedangkan *confusion matrix* menunjukkan pola kesalahan yang terjadi selama prediksi. Hasil analisis ini juga digunakan untuk menilai efektivitas penggunaan arsitektur *EfficientNet-B5* sebagai pendekatan *transfer learning* dalam klasifikasi citra MRI. Secara keseluruhan, tahapan ini memberikan gambaran menyeluruh tentang kelebihan dan keterbatasan model sehingga dapat menjadi dasar dalam perumusan kesimpulan dan rekomendasi penelitian.

2.2 Alur Eksperimen Penelitian



Gambar 2 Alur Eksperimen Penelitian

Alur eksperimen penelitian pada Gambar 2 bertujuan untuk memberikan gambaran tentang tahapan dalam membangun dan mengevaluasi sistem klasifikasi tumor dari citra MRI [17]. *Dataset* yang digunakan adalah *Brain Tumor MRI Dataset* oleh Masoud Nickparvar dari platform Kaggle [18]. *Dataset* terdiri dari empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor* yang terdiri dalam 2 folder terpisah, yaitu *Training* dan *Testing*. Data yang diperoleh kemudian disusun dalam bentuk *dataframe* untuk memudahkan pengelolaan *filepaths* dan *labels* selama proses pelatihan. *Dataset* dibagi menjadi data latih, data validasi, dan data uji dengan proporsi mendekati 80:10:10 untuk memastikan proses pelatihan dan evaluasi berjalan optimal. Tahap berikutnya adalah

preprocessing yang meliputi pengubahan ukuran citra menjadi 456×456 piksel, konversi ke format RGB, serta normalisasi menggunakan fungsi *preprocess_input* sesuai standar model *pre-trained ImageNet*.

Untuk meningkatkan kemampuan generalisasi model, diterapkan teknik data augmentation pada data latih berupa rotasi, pergeseran, *horizontal flip*, *zoom*, dan penyesuaian kecerahan. Seluruh data kemudian dimuat dalam bentuk *batch* menggunakan *ImageDataGenerator* agar proses pelatihan lebih efisien secara komputasi. Model klasifikasi dibangun menggunakan pendekatan *transfer learning* dengan arsitektur *EfficientNet-B5* sebagai *feature extractor*. Lapisan klasifikasi bawaan dihilangkan dan diganti dengan beberapa lapisan tambahan seperti *Batch Normalization*, *Dense layer* dengan regularisasi, serta *Dropout* untuk mengurangi risiko *overfitting*. Model dikompilasi menggunakan *optimizer Adamax* dan fungsi *loss categorical_crossentropy*. Proses pelatihan dilakukan dengan mekanisme *EarlyStopping*, *ReduceLROnPlateau*, dan *ModelCheckpoint* untuk memperoleh bobot terbaik. Evaluasi akhir dilakukan pada data uji menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, serta analisis *confusion matrix* dan ROC-AUC multikelas untuk menilai performa model secara menyeluruh.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil implementasi sistem klasifikasi tumor otak berbasis citra *Magnetic Resonance Imaging* (MRI) menggunakan pendekatan *Convolutional Neural Network* (CNN) dengan metode *transfer learning* melalui arsitektur *EfficientNet-B5*.

3.1 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini adalah *Brain Tumor MRI Dataset* disusun oleh Masoud Nickparvar dari platform *Kaggle*. *Dataset* terdiri dari 7.023 citra MRI otak yang telah diberi label ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary tumor*, dan *no tumor*. Keempat kelas tersebut merepresentasikan kondisi klinis yang berbeda pada jaringan otak. *Dataset* awal terbagi ke dalam dua folde utama, yaitu *training* sebanyak 5.712 citra dan *testing* sebanyak 1.311 citra dapat dilihat pada Tabel 1.

Tabel 1 Jumlah Dataset Berdasarkan Folder

Folder	Jumlah Citra MRI
<i>Training</i>	5.712
<i>Testing</i>	1.311
Total	7.023

Untuk memudahkan pengelolaan data secara terstruktur, seluruh citra direpresentasikan ke dalam bentuk *DataFrame*. Setiap baris *DataFrame* berisi lokasi file citra (*filepaths*) dan label kelas tumor (*labels*). Setelah *DataFrame* terbentuk, tahap selanjutnya adalah melakukan pembagian dataset citra MRI otak ke dalam beberapa subset berbeda, sehingga model tidak hanya mampu belajar pola dari *data train*, tetapi juga memiliki kemampuan bekerja dengan baik pada data baru yang belum pernah dilihat sebelumnya (generalisasi). Untuk memastikan proses evaluasi yang lebih objektif, Penelitian ini membagi kembali data pada folder *testing* menjadi *data validation* dan *data testing* akhir menggunakan teknik *stratified sampling* dapat dilihat pada Tabel 2.

Tabel 2 Pembagian *Dataset Training*, *Validation*, dan *Testing*

Jenis Data	Jumlah Citra	Persentase (%)
<i>Training</i>	5.712	~80
<i>Validation</i>	655	~10
<i>Testing</i>	656	~10
Total	7.023	100

Pada Tabel 2, menunjukkan bahwa data validasi didapatkan sebanyak 655 citra MRI, sedangkan 656 citra digunakan sebagai data pengujian akhir (*testing*). Secara keseluruhan, pembagian dataset dalam penelitian ini dibagi menjadi tiga bagian utama, yaitu *data training*, *data validation*, dan *data testing* dengan rasio 80%:10%:10%, sebagaimana ditunjukkan pada Tabel 4.5. *Data training* digunakan untuk melatih model dalam mempelajari fitur dan pola karakteristik dari citra MRI otak. *Data validation* digunakan selama proses pelatihan untuk mengevaluasi kinerja model selama proses *training* serta mencegah terjadi *overfitting*, sedangkan *data testing* sebagai data uji akhir untuk mengevaluasi performa model.

3.2 Tahap *Preprocessing Data*

Tahapan *preprocessing* dilakukan untuk memastikan seluruh citra MRI berada dalam format yang seragam dan sesuai dengan kebutuhan arsitektur model yang digunakan. Pada penelitian ini, proses *processing* dilakukan menggunakan bahasa pemrograman *Python* dengan menggunakan beberapa *library*, seperti *TensorFlow/Keras* untuk pengolahan citra dan pembentukan generator data, *Numpy* untuk operasi numerik pada *array* citra, serta *Pandas* untuk pengelolaan metadata dataset. Tujuan utama dari *preprocessing* adalah untuk mempersiapkan citra MRI otak agar sesuai dengan kebutuhan input model *EfficientNet-B5*, sehingga model dapat mempelajari pola dan karakteristik tumor secara optimal. Seluruh citra diubah ukurannya menjadi 456 x 456 piksel untuk untuk menyeragamkan ukuran seluruh citra dalam *dataset* agar sesuai dengan ukuran input yang digunakan dalam penelitian ini. Selain proses *resizing*, tahap selanjutnya adalah mengonversi citra ke format RGB (*Red, Green, Blue*). Citra MRI pada dataset bersifat *grayscale* dikonversikan agar sesuai dengan persyaratan input *EfficientNet-B5* pada citra MRI dengan tiga kanal warna (R, G, B). Nilai intensitas pada citra *grayscale* direplikasi ke RGB tanpa menguahi informasi struktur dan karakteristik visual citra.


Proses selanjutnya adalah normalisasi citra yang bertujuan menyamakan skala nilai piksel pada seluruh citra sehingga berada dalam rentang tertentu, umumnya antara 0 dan 1 dan nilai piksel awal berada dalam rentang 0 – 255 dengan menggunakan fungsi *preprocess_input*. Untuk meningkatkan kemampuan generalisasi model, dilakukan proses augmentasi data pada subset *training*. Proses *preprocessing* dan augmentasi pada penelitian ini menggunakan kelas *ImageDataGenerator* dari *library TensorFlow Keras*. *ImageDataGenerator* berfungsi sebagai mekanisme pemrosesan citra secara *On-the-fly* yang dimana citra diproses secara langsung pada saat proses pelatihan model dilakukan tanpa mengubah atau menyimpan ulang citra asli ke dalam dataset. Teknik augmentasi yang digunakan meliputi *horizontal flip*, rotasi hingga ± 20 derajat, pregesaran horizontal dan vertikal sebesar 10%, *zoom range* sebesar 20% serta *brightness range*.

3.3 Arsitektur Model dan Konfigurasi Pelatihan


Model yang dibangun pada penelitian ini menggunakan metode *transfer learning* dengan arsitektur *EfficientNet-B5* sebagai *base model*. Model klasifikasi tumor otak pada citra MRI ini dibangun dengan mengombinasikan kemampuan *feature extractor* dari *EfficientNet-B5* sebagai model dasar dengan *custom classifier* yang dirancang secara khusus. Struktur ini memungkinkan sebuah model untuk memanfaatkan pengetahuan visual dari hasil pelatihan sebelumnya pada dataset yang berskala besar dan sekaligus menyesuaikan dengan karakteristik dari citra MRI otak. Arsitektur ini dipilih karena mengimplementasikan konsep *compound scaling*, yaitu penskalaan jaringan secara seimbang pada kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*) jaringan secara efisien. Penelitian ini menggunakan mekanisme *Global Average Pooling* (GAP) pada bagian akhir *base model* yang fungsinya untuk merangkum fitur hasil ekstraksi menjadi vector satu dimensi. Lapisan ini membantu dalam mengurangi kompleksitas sebuah model dan menekan risiko *overfitting* sebelum data diteruskan ke lapisan klasifikasi. Lapisan klasifikasi tambahan (*custom classifier*) ditambahkan setelah *base model*, terdiri dari *Batch Normalization*, *Dense layer* dengan 256 neuron dan aktivasi ReLU, mekanisme regularisasi L1 dan L2, serta *Dropout* sebesar 0,45. Lapisan output menggunakan fungsi aktivasi *softmax* dengan empat neuron sesuai jumlah kelas. Model dilatih menggunakan *optimizer Adamax* dengan *learning rate* awal 0,001 dan fungsi loss *categorical_crossentropy*. Proses pelatihan dibatasi hingga 20 epoch dengan penerapan callback *EarlyStopping*, *ReduceLROnPlateau*, dan *ModelCheckpoint* untuk mengoptimalkan performa sekaligus mencegah *overfitting*.

3.4 Hasil Pelatihan Model

Evaluasi ini dilakukan dengan menganalisis perkembangan nilai *accuracy* dan *loss* pada data *training* dan *validation*. Visualisasi hasil pelatihan model ditampilkan dalam bentuk grafik, yaitu grafik akurasi, dan grafik loss. Berikut adalah grafik akurasi *training* dan *validation* pada Gambar 3.

Gambar 3 Grafik Akurasi *Training* dan *Validation*

Berdasarkan pada Gambar 3, terlihat bahwa model menunjukkan performa yang signifikan sejak epoch awal. Pada epoch pertama, akurasi *training* berada pada kisaran 77% sedangkan akurasi *validation* sekitar 74%. Epoch ketiga hingga kelima, akurasi *training* meningkat dan berada di kisaran 93%–96% sedangkan akurasi *validation* mencapai nilai akurasi tinggi, yaitu sekitar 98%–99%. Terlihat adanya penurunan sementara pada akurasi *training* pada epoch ke-11, yang turun hingga sekitar 96%, namun akurasi *validation* tetap berada pada kisaran 98%–99%. Pada epoch terakhir, akurasi *training* meningkat kembali mencapai nilai akhir sekitar 99%, sedangkan akurasi *validation* sekitar 99%–100%.

Gambar 4 Grafik *Training* dan *Validation Loss*

Pada Gambar 4 menampilkan grafik *training loss* dan *validation loss* selama proses *training model* pada setiap epoch. Pada awal *training*, nilai *loss* mengalami penurunan yang signifikan, artinya model semakin mampu meminimalkan kesalahan prediksi dengan menyesuaikan bobot dan parameter selama proses *training*. Grafik tersebut menunjukkan bahwa model tidak mengalami *overfitting* secara signifikan selama proses pelatihan.

3.5 Evaluasi Performa Model

Proses evaluasi pada penelitian ini dilakukan menggunakan *data testing* dengan sampel data sebanyak 656 sampel dan proses tersebut tanpa augmentasi data untuk memastikan hasil prediksi yang dihasilkan dapat mencerminkan kemampuan generalisasi model dalam klasifikasi citra MRI tumor otak. Metode yang digunakan meliputi *Classification Report*, *Confusion Matrix*, serta kurva ROC-AUC multikelas.

3.5.1 Classification Report (Precision, Recall, F1-Score)


Tabel 3 Hasil *Classification Report*

Kelas	Precision	Recall	F1-Score	Support
Glioma	1.000	0.987	0.993	150
Meningioma	0.981	1.000	0.990	153
No Tumor	1.000	1.000	1.000	203

Pituitary	1.000	0.993	0.997	150
Accuracy	-	-	0.995	656
Macro Avg	0.995	0.995	0.995	656
Weighted Avg	0.996	0.995	0.995	656

Pada Tabel 2, menunjukkan bahwa model di evaluasi menggunakan *test set* terhadap 656 citra MRI otak. Pada kelas *glioma* menunjukkan bahwa nilai *precision* sebesar 1,000, *recall* sebesar 0,987 dan *F1-Score* sebesar 0,993 dari total 150 citra. Kelas *meningioma* menunjukkan nilai *precision* sebesar 0,981, *recall* sebesar 1,000 dan *F1-Score* sebesar 0,990 dari total 153 citra. Untuk kelas *notumor*, model mencapai nilai *precision*, *recall*, dan *F1-Score* sebesar 1,000 dari total 203 citra. Pada kelas *pituitary*, diperoleh nilai *precision* sebesar 1,000, *recall* sebesar 0,993, dan *F1-Score* sebesar 0,997 dengan 150 citra uji. Nilai *macro average* untuk *precision*, *recall*, dan *F1-Score* masing-masing sebesar 0,995, sedangkan *weighted average* menunjukkan nilai *precision* sebesar 0,996, *recall* sebesar 0,995, dan *F1-Score* sebesar 0,995. Hasil ini menunjukkan bahwa model memiliki kinerja klasifikasi yang sangat baik serta mampu melakukan generalisasi secara optimal, meskipun terdapat perbedaan jumlah data pada masing-masing kelas.

3.5.2 Confusion Matrix




Gambar 5 Confusion Matrix

Pada Gambar 5, menunjukkan bahwa model berhasil mengklasifikasikan citra otak dengan benar pada hampir seluruh kelas karena Sebagian besar prediksi berada pada diagonal utama matriks. Dapat dilihat pada kelas *glioma* sebanyak 148 citra dari 150 citra uji berhasil diklasifikasikan dengan benar sebagai tumor otak *glioma*, dan ada 2 citra yang salah diprediksi sebagai *meningioma*. Untuk kelas *meningioma*, seluruh citra sebanyak 153 citra uji berhasil diprediksi dengan benar tanpa ada kesalahan klasifikasi ke kelas tumor otak lain. Pada kelas *no tumor* juga berhasil klasifikasi dengan benar sebagai *no tumor* sebanyak 203 citra. Pada kelas *pituitary*, sebanyak 149 berhasil dikalsifikasikan dengan benar dari 150 citra, dan hanya 1 citra yang salah diprediksi sebagai *meningioma*. Secara keseluruhan, hasil *confusion matrix* menunjukkan bahwa model mampu mengklasifikasi antar kelas pada citra MRI otak.

3.5.3 Analisis ROC-AUC Multi Class

Tahap selanjutnya adalah analisis performa model melalui kurva *Receiver Operating Characteristic* (ROC) dan nilai *Area Under the Curve* (AUC) yang bertujuan untuk menilai kemampuan model dalam mengklasifikasikan kelas tumor otar berdasarkan nilai probabilitas prediksi yang dihasilkan. Kurva ROC menggambarkan hubungan antara *True Positiver Rate* (TPR) atau sensitivitas dan *False Positive Rate* (FPR) pada berbagai nilai ambang keputusan (*threshold*), sedangkan AUC nilai numerik yang merepresentasikan luas area dibawah kurva ROC. Berikut adalah hasil evaluasi performa model menggunakan ROC-AUC pada Gambar 6.



Gambar 6 Kurva ROC-AUC Multi Class

Hasil evaluasi pada Gambar 6, menunjukkan bahwa kurva ROC untuk seluruh kelas berada di atas garis diagonal, yang artinya model mampu mencapai tingkat sensitivitas yang tinggi pada FPR yang rendah. Nilai AUC yang didapatkan sangat tinggi sebesar 1,000 untuk kelas *glioma* dan *meningioma*, sedangkan kelas *notumor* dan *pituitary* juga sama memperoleh nilai AUC sebesar 1,000. Selain itu, nilai *macro-average* AUC juga mencapai 1,000 yang menunjukkan bahwa keseluruhan model memiliki performa klasifikasi yang sangat optimal dan konsisten pada seluruh kelas. Kurva ROC yang berada jauh di atas garis diagonal menunjukkan bahwa model bekerja jauh lebih baik dibandingkan klasifikasi acak. Secara keseluruhan, hasil evaluasi pada klasifikasi tumor otak berbasis *EfficientNet-B5* yang dikembangkan dalam penelitian ini bahwa model mampu memberikan performa yang sangat baik pada data uji.

4. KESIMPULAN

Penelitian ini berhasil menerapkan metode *transfer learning* menggunakan *EfficientNet-B5* sebagai model dasar dalam proses *feature extractor* pada klasifikasi tumor otak yang mampu mengekstraksi fitur dari gambar MRI otak dan berhasil menangkap representasi fitur visual yang kompleks dan relevan dalam membedakan empat kelas tumor otak, yaitu *glioma*, *meningioma*, *no tumor*, dan *pituitary*. Evaluasi kinerja model *EfficientNet-B5* dilakukan menggunakan data uji sebanyak 656 citra MRI otak yang tidak digunakan pada proses pelatihan. Hasil pengujian menunjukkan bahwa pada kelas glioma diperoleh nilai precision sebesar 1,000, recall sebesar 0,987, dan F1-Score sebesar 0,993 dari 150 citra uji, sedangkan pada kelas meningioma model mencapai nilai precision sebesar 0,981, recall sebesar 1,000, dan F1-Score sebesar 0,990 dari 153 citra. Untuk kelas no tumor, model menunjukkan performa sangat optimal dengan nilai precision, recall, dan F1-Score masing-masing sebesar 1,000 pada 203 citra uji, sementara pada kelas pituitary diperoleh nilai precision sebesar 1,000, recall sebesar 0,993, dan F1-Score sebesar 0,997 dari 150 citra uji. Secara keseluruhan, model menghasilkan nilai akurasi sebesar 0,995 atau 99,5 persen, dengan nilai macro average untuk precision, recall, dan F1-Score masing-masing sebesar 0,995 serta weighted average dengan nilai precision sebesar 0,996, recall sebesar 0,995, dan F1-Score sebesar 0,995, sehingga menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik dalam mengklasifikasikan citra MRI otak pada seluruh kelas tumor

REFERENCES

- [1] M. I. Surahman and F. Nurzaman, "Impelementasi Algoritma Convolutional Neural Network (CNN) Untuk Mendeteksi Penyakit Tumor Otak Berbasis Web," vol. 26, no. 1, pp. 94–100, 2025.
- [2] F. Bray *et al.*, "Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries," *CA. Cancer J. Clin.*, vol. 74, no. 3, pp. 229–263, 2024, doi: 10.3322/caac.21834.
- [3] J. Ferlay *et al.*, "Cancer statistics for the year 2020: An overview," *Int. J. Cancer*, vol. 149, no. 4, pp. 778–789, 2021, doi: 10.1002/ijc.33588.
- [4] M. Nafi, M. Hakim, A. B. Nugroho, and A. E. Minarno, "Prediksi Tumor Otak Menggunakan Metode Convolutional Neural Network," *Inform. Mulawarman J. Ilm. Ilmu Komput.*, vol. 17, no. 1, p. 48, 2023, doi: 10.30872/jim.v17i1.5246.
- [5] R. S. Passa, S. Nurmaini, and D. P. Rini, "DETEKSI TUMOR OTAK PADA MAGNETIC RESONANCE IMAGING MENGGUNAKAN YOLOv7," *J. Ilm. Matrik*, vol. 25, no. 2, pp. 116–121, 2023, doi:

- 10.33557/jurnalmatrik.v25i2.2404.
- [6] R. P. Sari, "Apa itu Convolutional Neural Networks? Pengertian & Cara Kerja," Indonesia Artificial Intelligence Hub. Accessed: Nov. 13, 2025. [Online]. Available: <https://aihub.id/pengetahuan-dasar/apa-itu-cnn>
 - [7] D. M. Wonohadidjojo, "Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih," *Ultim. J. Tek. Inform.*, vol. 13, no. 1, pp. 51–57, 2021, doi: 10.31937/ti.v13i1.2040.
 - [8] R. J. Hendri Butar-Butar and N. L. Marpaung, "Deep Learning untuk Identifikasi Daun Tanaman Obat Menggunakan Transfer Learning MobileNetV2," *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 142–148, 2023, doi: 10.30591/jpit.v8i2.5217.
 - [9] A. Hardirega, I. Jaelani, and M. Minarto, "Implementasi Convolutional Neural Network (Cnn) Klasifikasi Motif Batik Menggunakan Efficientnet-B1," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 5, pp. 10023–10028, 2024, doi: 10.36040/jati.v8i5.10901.
 - [10] W. Hastomo *et al.*, "Classification of Brain Image Tumor using EfficientNet B1-B2 Deep Learning," *Semesta Tek.*, vol. 27, no. 1, pp. 46–54, 2024, doi: 10.18196/st.v27i1.19691.
 - [11] P. Sharma and A. P. Shukla, "Transfer Learning Approach Using Efficientnet Architecture for Brain Tumor Classification in Mri Images," *Adv. Appl. Math. Sci.*, vol. 21, no. 12, pp. 7091–7106, 2022.
 - [12] B. Babu Vimala, S. Srinivasan, S. K. Mathivanan, Mahalakshmi, P. Jayagopal, and G. T. Dalu, "Detection and classification of brain tumor using hybrid deep learning models," *Sci. Rep.*, vol. 13, no. 1, pp. 1–17, 2023, doi: 10.1038/s41598-023-50505-6.
 - [13] H. K. Putri, B. H. Iswanto, and H. Suhendar, "Klasifikasi Kualitas Cangkang Telur Ayam Menggunakan Efficientnet Berbasis Citra Digital," *Pros. Semin. Nas. Fis.*, vol. XIII, pp. 93–101, 2024.
 - [14] H. R. J. Sinaga, "PENERAPAN MODEL ARSITEKTUR EFFICIENTNETB5 PADA KLASIFIKASI MULTI-KELAS PENYAKIT TANAMAN PADI," 2025.
 - [15] G. A. Sandag, E. Djamal, G. M. W. Tangka, and S. W. Taju, "MRI Image Analysis for Alzheimer's Disease Detection Using Transfer Learning: VGGNet vs. EfficientNet," *CogITO Smart J.*, vol. 10, no. 2, pp. 580–592, 2024, doi: 10.31154/cogito.v10i2.836.580-592.
 - [16] Pujianti, "Kerangka Penelitian dan Tata Cara Membuatnya," deepublish. Accessed: Feb. 21, 2026. [Online]. Available: <https://penerbitdeepublish.com/tutorial-menulis/menulis-karya-ilmiah/kerangka-penelitian/>
 - [17] C. P. Trisnanda, "Alur Penelitian dan Contoh," duniakampus.id. Accessed: Feb. 21, 2026. [Online]. Available: <https://www.duniakampus.id/riset-penelitian/mengenal-alur-penelitian/>
 - [18] M. Nickparvar, "Brain Tumor MRI Dataset," Kaggle. Accessed: Nov. 04, 2025. [Online]. Available: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>