

# PENERAPAN TRANSFER LEARNING UNTUK KLASIFIKASI CITRA TUMOR OTAK PADA DATA TERBATAS

Sechan Maydi Putra<sup>1</sup>, Asyfha Anan Diarisya<sup>2</sup>, Hanif Setya Nugroho<sup>3</sup>, Ferdy Arditya<sup>4</sup>,  
Nunung Hidayatun<sup>5</sup>, Muhammad Muharom<sup>6</sup>

Fakultas Teknik Informatika, Universitas Bina Sarana Informatika, Bekasi

Jl. Cut Mutia No.88, Sepanjang Jaya, Kec. Rawalumbu, Kota Bks, Jawa Barat

e-mail: sechanmaydiputra12@gmail.com<sup>1</sup>, asyfha0701@gmail.com<sup>2</sup>,

hanifsetyanugroho@gmail.com<sup>3</sup>, ferdiarditya75@gmail.com<sup>4</sup>, nunung.ntn@bsi.ac.id<sup>5</sup>,

Muhammad.muu@bsi.ac.id<sup>6</sup>

## Abstrak

Penelitian ini bertujuan mengatasi tantangan klasifikasi citra tumor otak berbasis kecerdasan buatan yang terhambat oleh keterbatasan data berlabel. Pendekatan yang diajukan adalah Penerapan Transfer Learning menggunakan arsitektur MobileNetV2. Model dilatih dengan strategi dua fase, yaitu pembekuan bobot dasar diikuti oleh fine-tuning lapisan konvolusi teratas, serta didukung oleh teknik Augmentasi Data. Evaluasi dilakukan pada 1.311 citra uji independen. Hasil penelitian menunjukkan model mencapai Akurasi Keseluruhan 94,02 persen dan Macro Average F1-Score 94,50 persen. Kinerja ini membuktikan keberhasilan Transfer Learning dalam mitigasi overfitting dan pencapaian generalisasi yang sangat baik. Model juga menunjukkan efisiensi komputasi yang tinggi, terbukti dengan waktu inferensi yang hanya sekitar 25 milidetik per citra. Dengan bobot yang ringan (14,2 megabyte), model ini diintegrasikan ke dalam prototipe visualisasi berbasis web. Temuan ini menegaskan kelayakan model untuk dikembangkan sebagai sistem diagnosis bantu klinis yang akurat dan responsif.

**Kata kunci:** data terbatas, klasifikasi citra, mobilenetv2, transfer learning, tumor otak

## Abstract

*This study aimed to overcome the challenge of brain tumor image classification using Artificial Intelligence hindered by data scarcity. The proposed approach was the Application of Transfer Learning utilizing the MobileNetV2 architecture on an augmented four-class image dataset. The model was trained through a two-phase strategy: freezing the base weights followed by fine-tuning the top convolutional layers. Evaluation was conducted on 1,311 independent test images. The results demonstrated that the model achieved an Overall Accuracy of 94.02 percent and a Macro Average F1-Score of 94.50 percent. This performance validated the success of Transfer Learning in mitigating overfitting and achieving excellent generalization. Furthermore, the model exhibited high computational efficiency, evidenced by an inference time of only approximately 25 milliseconds per image. With its lightweight size (14.2 megabytes), the model was integrated into a web-based visualization prototype, demonstrating its strong potential for further development as an accurate and responsive clinical decision support system.*

**Keywords:** limited data, image classification, mobilenetv2, transfer learning, brain tumor

## 1. PENDAHULUAN

Tumor otak adalah penyakit saraf yang berbahaya, yang sangat mempengaruhi kualitas hidup pasien [1]. Salah satu metode yang umum digunakan untuk mendiagnosis tumor otak secara non-invasif adalah *Magnetic Resonance Imaging* (MRI), yang berperan penting dalam proses diagnosis dan pengobatan medis. MRI menggunakan resonansi magnetik untuk menangkap sinyal elektromagnetik dari otak, sehingga dapat membangun kembali informasi otak dan memberikan gambar anatomi yang akurat [2]. Namun, pemahaman terhadap hasil citra tersebut sangat bergantung pada keterampilan dokter spesialis, yang seringkali menyebabkan variasi dalam diagnosis dan kemungkinan terjadinya kesalahan [3]. Oleh karena itu, sistem berbasis kecerdasan buatan yang dapat membantu dalam menafsirkan citra menjadi sangat diperlukan untuk meningkatkan akurasi dan efektivitas diagnosis [4].

Perkembangan terbaru dalam sektor kecerdasan buatan (AI) dan *Deep Learning* memberikan solusi yang mungkin untuk tantangan ini [1]. *Convolutional Neural Networks* (CNN) telah menunjukkan hasil yang sebanding atau bahkan lebih unggul dibandingkan dengan dokter spesialis radiologi pada beberapa tugas analisis gambar medis, dengan tingkat akurasi mencapai 92-97% dalam mendeteksi kelainan pada otak [5]. Meskipun model CNN memiliki akurasi yang sangat baik, masih ada beberapa kekurangan, seperti perlunya dataset yang besar untuk pelatihan, kompleksitas komputasi yang tinggi, dan risiko *overfitting* jika tidak diterapkan teknik regulasi yang sesuai [6]. Adapun, akses terhadap dataset medis yang besar dan berkualitas masih terbatas serta infrastruktur komputasi yang kurang memadai di banyak fasilitas kesehatan di Indonesia juga menjadi kendala. Selain itu, diperlukan validasi klinis yang menyeluruh sebelum teknologi ini dapat diterapkan secara luas dalam dunia medis [7].

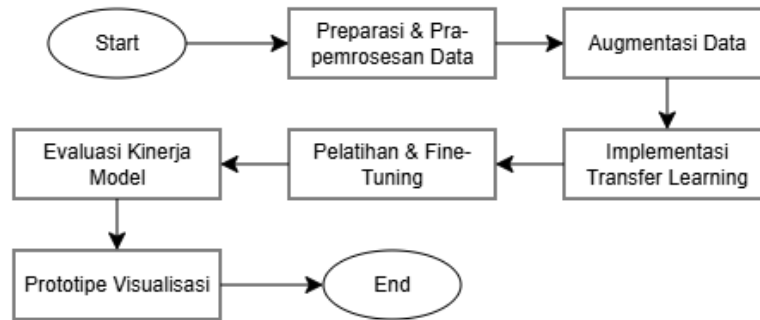
Pendekatan seperti *transfer learning* memungkinkan penerapan model pembelajaran mendalam yang telah dilatih sebelumnya ke kumpulan data medis yang lebih kecil [8]. Penelitian ini memanfaatkan model MobileNetV2 untuk menerapkan *transfer learning* (TL) karena efisiensi komputasinya yang baik dan kecepatan inferensi yang tinggi. Hasil model ini kemudian diintegrasikan ke dalam prototipe visualisasi berbasis web sebagai alat demonstrasi *proof of concept* yang cepat dan mudah diakses [9]. Strategi ini meningkatkan skalabilitas teknologi analitik. Dengan memanfaatkan model pra-terlatih, organisasi dapat mengurangi waktu dan sumber daya keuangan yang diperlukan untuk pelatihan model [10]. Tujuan dari penelitian ini adalah untuk menganalisis kinerja strategi pembelajaran *transfer learning* berbasis kecerdasan buatan (AI) yang menggunakan arsitektur *Convolutional Neural Network* (CNN) yang diakui dengan baik dalam pencitraan medis. Melalui *transfer learning*, model AI dapat mengadaptasi fitur yang dipelajari dari kumpulan data non-medis besar untuk meningkatkan akurasi dalam klasifikasi atau segmentasi gambar tumor otak [11].

Pengembangan model klasifikasi citra medis berfokus pada efisiensi arsitektur serta optimasi performa pada dataset terbatas melalui pendekatan transfer learning. Sebagaimana penelitian sebelumnya oleh Nafisa, dkk [12] implementasi MobileNetV2 pada klasifikasi tumor otak mampu menghasilkan akurasi sebesar 86,458%, dengan catatan bahwa identifikasi tumor Pituitary mencapai hasil optimal sementara untuk Glioma dan Meningioma model kesulitan mengidentifikasi, yang menjadi dasar bagi pengembangan model yang lebih kompleks atau penambahan dataset pada penelitian selanjutnya. Di sisi lain, Gulzar [13] memperkuat justifikasi penggunaan arsitektur ringan melalui model transfer learning MobileNetV2 yang meraih akurasi 99% serta menunjukkan efisiensi komputasi yang lebih unggul dibandingkan model VGG16 dan ResNet. Penelitian lain dilakukan oleh Gu dan Li [2] memperkenalkan metode TSMDL yang menggabungkan *supervised multi-layer dictionary learning* dengan transfer learning untuk mengatasi tantangan spesifik terkait keterbatasan data berlabel pada citra MRI untuk stabilitas identifikasi fitur yang lebih baik daripada CNN tradisional. Secara kolektif, berbagai temuan ini menegaskan bahwa penggunaan MobileNetV2 yang didukung oleh strategi transfer learning yang tepat merupakan paradigma yang sangat relevan dalam mewujudkan sistem diagnosis bantuan klinis yang akurat, efisien, dan aplikatif.

Dengan berpegang pada tujuan tersebut, metodologi penelitian ini akan meliputi analisis perbandingan untuk mengevaluasi kinerja model *transfer learning* (*fine-tuning*) dibandingkan dengan model yang dilatih dari tahap awal (*from scratch*). Diharapkan penelitian ini akan memperlihatkan peningkatan yang nyata dalam metrik kinerja seperti akurasi dan efisiensi komputasi. Kontribusi utama dari penelitian ini adalah untuk memberikan bukti nyata mengenai efektivitas *Transfer Learning* menggunakan arsitektur MobileNetV2 dalam mengatasi masalah kekurangan data untuk klasifikasi tumor otak. Sebagai tambahan dari implementasi ini, model yang dihasilkan bisa menjadi landasan untuk pengembangan antarmuka pengguna (UI) berbasis web yang fungsional guna mendukung diagnosis medis. Prototipe sistem berbasis web yang dikembangkan ini hanya berfungsi sebagai antarmuka visualisasi hasil dan bukan merupakan penelitian mendalam tentang pengembangan rekayasa perangkat lunak *front-end* atau *back-end*.

## 2. METODE PENELITIAN

Metode penelitian ini menggunakan pendekatan kuantitatif-experimental dengan penekanan pada pengembangan dan evaluasi model *Deep Transfer Learning* (DTL). Tahapan penelitian ini disusun untuk secara efisiensi mengatasi tantangan keterbatasan data pada citra medis melalui penggunaan arsitektur MobileNetV2 yang telah dilatih sebelumnya (*pre-trained*). Keseluruhan metodologi terbagi menjadi tiga tahapan utama: Persiapan Data dan Augmentasi, Implementasi dan *Fine-Tuning* Model DLT, serta Evaluasi Kinerja dan Demonstrasi Prototipe. Seluruh proses komputasi dan implementasi model *Machine Learning* dilakukan menggunakan lingkungan pemrograman Python dengan menggunakan *framework TensorFlow/keras*.



Gambar 1 Diagram Alur Penelitian

### 2.1. Preparasi & Pra-pemrosesan data

Tahap awal metodologi penelitian ini berfokus pada Preparasi dan Pra-pemrosesan Data untuk menjamin kualitas input bagi model *Deep Learning*. Data berupa citra *Magnetic Resonance Imaging* (MRI) tumor otak dikumpulkan dari sumber yang teridentifikasi. Setiap citra kemudian diseragamkan ukurannya melalui proses *resizing* menjadi 224x224 piksel dan dinormalisasi (diskala) ke rentang nilai [0, 1]. Penyesuaian dimensi dan normalisasi ini merupakan langkah esensial untuk memenuhi persyaratan input dari arsitektur MobileNetV2 serta mengoptimalkan efisiensi komputasi selama pelatihan. Selanjutnya, keseluruhan dataset dibagi secara *non-overlapping* menjadi set pelatihan, set validasi, dan set uji untuk memastikan objektivitas evaluasi kinerja model.

### 2.2. Augmentasi Data

Untuk menghadapi tantangan utama keterbatasan data berlabel di bidang pencitraan medis, teknik Augmentasi Data diterapkan secara menyeluruh pada training set. Tujuan utama dari strategi ini adalah untuk secara sintesis meningkatkan variasi serta ukuran data pelatihan, agar model dapat mempelajari fitur yang lebih kuat dan menghindari terjadinya *overfitting*. Augmentasi yang dilakukan mencakup: rotasi gambar maksimum 10 derajat, pergeseran lebar dan tinggi sebesar 10%, zoom in/out sebesar 10%, dan pembalikan horizontal. Secara khusus, pembalikan horizontal menirukan kemunculan tumor di hemisfer kiri atau kanan, sedangkan pergeseran dan pembesaran menangani perbedaan dalam penempatan objek pada bingkai MRI. Penerapan teknik augmentasi ini memastikan bahwa model tidak terikat pada posisi atau arah tertentu, yang secara langsung mendukung kemampuan generalisasi model yang lebih baik.

### 2.3. Implementasi Transfer Learning

Langkah implementasi krusial berikutnya adalah adopsi *Transfer Learning* (TL) menggunakan arsitektur MobileNetV2. Pemilihan MobileNetV2 didasarkan pada keunggulannya dalam efisiensi komputasi tinggi dan kecepatan inferensi yang superior berkat penggunaan *depthwise separable convolution*, menjadikannya pilihan ideal untuk aplikasi Web UI yang *real-time*. Model dimuat dengan bobot yang telah dilatih pada ImageNet, kemudian Lapisan *Fully Connected* (FC) klasifikasi asli dihilangkan. Lapisan FC baru ditambahkan untuk mengakomodasi jumlah kelas tumor yang diteliti. Pada inisiasi, lapisan konvolusi MobileNetV2 dibekukan (*frozen*) untuk mempertahankan ekstraksi fitur *low-level* yang universal, memitigasi risiko kerusakan bobot pra-trlatih.

### 2.4. Pelatihan & Fine-Tuning

Proses adaptasi model dilaksanakan melalui Pelatihan dan *Fine-Tuning* dua fase untuk memaksimalkan kinerja dan efisiensi. Awalnya, Fase I berfokus pada pelatihan lapisan klasifikasi yang baru ditambahkan, sementara bobot pra-trlatih MobileNetV2 dibekukan (*frozen*). Setelah Lapisan Klasifikasi mencapai konvergensi awal, Fase II dimulai dengan menerapkan strategi *Fine-Tuning*. Beberapa blok lapisan konvolusi teratas MobileNetV2 dibuka bekumannya (*unfrozen*) lapisan ini dipilih karena sensitivitasnya yang lebih tinggi terhadap fitur *high-level* citra medis. Pelatihan dilanjutkan dengan tingkat pembelajaran (*Learning Rate*) yang sangat rendah. Penyesuaian halus ini bertujuan mengadaptasi representasi fitur MobileNetV2 agar secara spesifik mengenali pola morfologi tumor otak, sehingga akurasi dan efisiensi model dapat dimaksimalkan pada domain medis target.

### 2.5. Evaluasi Kinerja Model

Setelah proses *Fine-Tuning* selesai, dilakukan Evaluasi Kinerja Model secara komprehensif menggunakan set data uji yang bersifat independen dan belum pernah dilihat oleh model selama pelatihan. Kinerja klasifikasi diukur menggunakan serangkaian metrik standar, meliputi Akurasi, Presisi, Recall, dan F1-Score. Untuk menganalisis kesalahan prediksi secara terperinci per-kelas, dibuatlah Matriks Kebingungan (*Confusion Matrix*). Selanjutnya, hasil kinerja MobileNetV2 dibandingkan secara kuantitatif dan komputasional dengan model *baseline* (misalnya, CNN yang dilatih *from scratch*). Perbandingan ini

bertujuan untuk memvalidasi keberhasilan *Transfer Learning* dalam mengatasi keterbatasan data serta mengkonfirmasi efisiensi komputasi dari arsitektur MobileNetV2.

### 2.6. Prototipe Visualisasi

Sebagai langkah akhir, fungsionalitas model yang tervalidasi didemonstrasikan melalui pengembangan Prototipe Visualisasi berbasis web sederhana. Model MobileNetV2 yang telah di-*fine-tune* diintegrasikan ke dalam antarmuka ini untuk tujuan *proof of concept*. Efisiensi arsitektur MobileNetV2 menjamin inferensi yang sangat cepat, memungkinkan sistem memberikan hasil prediksi dalam waktu *near real-time*. Prototipe ini berfungsi untuk menunjukkan kapabilitas aplikatif model, di mana pengguna dapat mengunggah citra dan memvisualisasikan output klasifikasi (meliputi label tumor yang diprediksi dan tingkat probabilitas terkait).

## 3. HASIL DAN PEMBAHASAN

Tahap ini menyajikan serta menganalisis hasil eksperimen yang dilakukan dengan menerapkan strategi *Transfer Learning* menggunakan arsitektur MobileNetV2 pada dataset gambar MRI tumor otak. Metodologi yang telah dijelaskan dalam Bab II—yang mencakup Augmentasi Data untuk mengatasi keterbatasan data, serta pelatihan dua tahap (pembekuan dan *fine-tuning* pada 30 lapisan teratas MobileNetV2)—bertujuan untuk meraih kinerja klasifikasi yang tinggi sambil tetap menjaga efisiensi di bidang komputasi. Evaluasi model dilakukan secara menyeluruh pada 1.311 citra pengujian yang bersifat independen. Analisis kinerja berkaitan dengan verifikasi keberhasilan *Transfer Learning*, peninjauan metrik pada setiap kelas (Akurasi, Recall, F1-Score), analisis pola kesalahan menggunakan Matriks Kebingungan, serta evaluasi Kurva Pelatihan terkait Akurasi dan Kerugian Model, serta efisiensi model untuk penggunaan secara *real-time*.

### 3.1. Hasil Kinerja Klasifikasi dan Validasi Transfer Learning

Tahapan evaluasi ini memanfaatkan Test set yang terpisah, yang terdiri dari 1.311 gambar uji. Hasil dari pengujian mengungkapkan bahwa model Transfer Learning MobileNetV2 menunjukkan performa yang baik dan efisien, yang dirangkum dalam Tabel 1.

Tabel 1. Ringkasan Matriks Kinerja Model MobileNetV2

Matriks	Nilai	Keterangan
Akurasi Keseluruhan	94,02%	Diukur pada 1.311 sampel uji,
F-1 Score Rata-rata (Macro Avg)	94,50%	Menunjukkan keseimbangan yang baik antara precision dan recall.
Total Parameter Model	2,59 juta	Ukuran model yang ringan.
Waktu Inferensi	~25ms/citra	Sangat cepat, mendukung deployment real-time.

#### 3.1.1. Validasi Transfer Learning dan Generalisasi

Pencapaian akurasi keseluruhan (*Test Set*) sebesar 94,02% secara empiris membuktikan efektifitas *Transfer Learning* (TL) dalam menangani masalah keterbatasan data. Validasi tersebut didasarkan pada generalisasi yang baik, terlihat dari perbedaan (gap) yang kecil antara akurasi pelatihan akhir (96,78%) dan akurasi pengujian (94,02%). Jurang kecil ini menunjukkan keberhasilan dalam mengatasi *overfitting*. Tingginya tingkat akurasi pada set tes yang independen menunjukkan bahwa model dapat menerapkan pengetahuan yang diperoleh dari ImageNet serta proses penyesuaian untuk tugas klasifikasi tumor otak yang khusus.

#### 3.1.2. Efisiensi Komputasi (MobileNetV2)

Selain akurasi, model ini menunjukkan efisiensi komputasi yang baik berkat pemilihan arsitektur MobileNetV2 yang ringkas.

- 1) Model Ringan: Model ini memiliki total 2,59 juta parameter dan ukuran file model akhir adalah sekitar 14,2 MB. Sebaliknya, MobileNetV2 jauh lebih ringan dibandingkan dengan ResNet50 yang memiliki total 25 juta parameter.
- 2) Inferensi Cepat: Kinerja ini menghasilkan waktu inferensi rata-rata yang sangat singkat, yaitu sekitar 25 milidetik untuk setiap citra. Kecepatan ini sangat krusial untuk mendukung pelaksanaan dan penempatan sistem diagnosis bantuan klinis secara real-time.

Kinerja yang seimbang, yang ditunjukkan oleh F1-Score Rata-rata 94,50%, mengindikasikan bahwa model tidak condong pada kelas tertentu dan berhasil menjaga keseimbangan antara Precision dan Recall.

**3.2. Analisis Kinerja Per-Kelas**

Analisis kinerja model pada setiap kelas menunjukkan keseimbangan yang tinggi, yang merupakan indikator penting dalam domain medis:

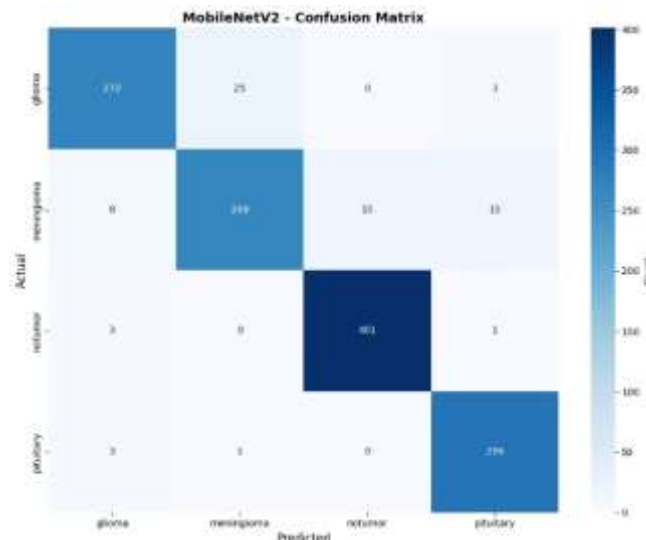
**Tabel 2 Kinerja MobileNetV2 Berdasarkan Kelas Uji**

Kelas Tumor	Akurasi Per-Kelas	Precision	Recall	F1-Score
Glioma	95,00%	93%	95%	94%
Meningioma	91,83%	96%	92%	94%
No Tumor	97,04%	98%	97%	97%
Pituitary	94,00%	91%	94%	93%

Analisis kinerja model MobileNetV2 menggunakan matriks per-kelas menunjukkan keseimbangan dan kesiapan untuk digunakan secara klinis dengan baik. Kelas No Tumor menunjukkan kinerja paling baik, yang merupakan hal penting dalam proses penyaringan, dengan Akurasi Per-Kelas sebesar 97,04% dan nilai Recall mencapai 97%. Tingginya tingkat recall ini secara signifikan mengurangi risiko *False Negative*, yaitu kasus yang sehat salah diidentifikasi sebagai tumor. Sementara itu, model tersebut tetap mempertahankan kemampuan yang tinggi dalam mendeteksi kasus positif (Recall) untuk ketiga jenis tumor: Glioma mencapai Recall sebesar 95%, dan Pituitary mencapai Recall sebesar 94%. Kemampuan untuk mendeteksi Glioma dengan akurat sangat krusial mengingat karakteristiknya yang berbahaya. Sebaliknya, Meningioma menunjukkan tingkat ketepatan tertinggi (96%) di antara semua jenis tumor, menegaskan bahwa ketika model memprediksi Meningioma, tingkat keandalannya sangat tinggi. Secara keseluruhan, kinerja yang seimbang ini—dengan setiap kelas tumor menunjukkan F1-Score antara 93% dan 94%—menunjukkan bahwa model MobileNetV2 tidak hanya tepat secara umum tetapi juga andal dalam situasi diagnostik diferensial.

**3.3. Analisis Matriks Bingung**

Matriks Kebingungan untuk model MobileNetV2 telah diuji pada 1. 311 citra independen dan memberikan informasi penting tentang pola kesalahan tertentu yang dilakukan oleh model tersebut. Analisis diarahkan pada nilai diagonal (*True Positive*) dan sel *off-diagonal* (kesalahan dalam klasifikasi).



**Gambar 1. Matriks Bingung**

**3.3.1. Kinerja Prediksi Benar (True Positive)**

Angka-angka yang terdapat pada diagonal matriks menunjukkan jumlah prediksi yang akurat (*True Positives*):

- 1) Tanpa Tumor: Sebanyak 401 kasus telah berhasil diklasifikasikan dengan tepat, menunjukkan Akurasi Per-Kelas sebesar 97. 04% dan menunjukkan keandalan model dalam skrining awal.
- 2) Pituitari: Sebanyak 296 kasus telah berhasil dikategorikan dengan tepat.
- 3) Glioma: 272 kasus telah berhasil diklasifikasikan dengan tepat.
- 4) Meningioma: 268 kasus telah berhasil dikategorikan dengan tepat.

### 3.3.2. Analisis Pola Kesalahan (Off-Diagonal Errors)

Sel off-diagonal mengidentifikasi kelas mana yang paling sering membuat model bingung. Penganalisan pola kesalahan ini sangatlah penting untuk mengetahui batasan model serta dampak klinis yang ditimbulkannya.

#### Perbedaan antara Glioma dan Meningioma (Tumor dibandingkan dengan Tumor)

- 1) Jumlah Kesalahan: Kesalahan yang paling signifikan muncul antara kelas Glioma dan Meningioma, dengan total 33 kasus kesalahan klasifikasi. Sebanyak 25 kasus merupakan Glioma yang saat ini diperkirakan sebagai Meningioma. Delapan kasus merupakan Meningioma yang saat ini diperkirakan sebagai Glioma.
- 2) Interpretasi: Pola kesalahan ini menunjukkan bahwa karakteristik visual dalam gambar MRI (seperti bentuk dan tekstur) antara kedua jenis tumor tersebut memiliki kesamaan yang nyata.
- 3) Implikasi Klinis: Dampak klinisnya dinilai sedang karena model ini minimal berhasil mengidentifikasi keduanya sebagai keadaan tumor.

#### Kesalahan Klasifikasi Kelas Tanpa Tumor (Salah Negatif)

- 1) Jumlah Kesalahan: Kelas No Tumor menunjukkan tingkat False Negative yang sangat rendah. Dari 405 citra 'No Tumor', hanya 4 kasus yang salah diidentifikasi sebagai tumor (3 kasus diklasifikasikan sebagai Glioma, dan 1 kasus sebagai Pituitary).
- 2) Interpretasi: Nilai False Negative yang rendah ini merupakan bukti mengenai keandalan model dalam konteks penyaringan. Hal ini menunjukkan bahwa model ini memiliki tingkat kehati-hatian yang tinggi (konservatisme) dalam mendiagnosis kasus positif.
- 3) Kepentingan False Positive: Di sisi lain, kesalahan pengklasifikasian dari kategori tumor menjadi Tidak Ada Tumor (False Negatives klinis) juga sangat minim, yang merupakan aspek paling berisiko, menegaskan tingginya Recall model.


#### Kesalahan Pituitari dan Meningioma

- 1) Jumlah Kesalahan: Terdapat total 16 kasus (15 kasus sebenarnya meningioma ternyata memprediksi pituitari, dan 1 kasus sebenarnya pituitary ternyata memprediksi meningioma).
- 2) Interpretasi: Kesalahan ini mungkin terjadi karena lokasi tumor yang saling berdekatan atau ukuran tumor yang kecil, yang memerlukan perhatian lebih lanjut terhadap ciri-ciri batas wilayah tumor.

Secara keseluruhan, Matriks Kebingungan menunjukkan bahwa model MobileNetV2 memiliki kemampuan yang baik dalam membedakan antara kasus sehat (No Tumor) dan kasus yang mengandung tumor, serta dalam mengenali area khusus (seperti perbedaan antara Glioma dan Meningioma) yang membutuhkan penjelajahan aspek yang lebih mendalam di waktu yang akan datang.

### 3.4. Analisis Kurva Pelatihan Model Accuracy dan Model Loss

Analisis kinerja model pelatihan yang bersifat iteratif diuji secara visual melalui kurva riwayat pelatihan, yang ditampilkan dalam Gambar 3.2. Visualisasi ini memiliki peranan yang sangat penting untuk mengevaluasi cara model berkonvergensi dan memastikan bahwa strategi penyempurnaan berjalan sukses serta metode pencegahan *overfitting* berfungsi dengan baik.



Gambar 2.. Accuracy dan Loss MobileNetV2

Gambar ini terdiri dari dua grafik, yang menggambarkan kinerja model selama proses pelatihan (garis biru) dan validasi (garis oranye) pada setiap epoch. Kedua grafik ini membuktikan keunggulan dari metode *Transfer Learning* dan teknik penyempurnaan yang telah diterapkan.

#### Kurva Kiri: Model Accuracy

Sumbu X (Horizontal): Mempresentasikan Epoch (jumlah iterasi pelatihan penuh pada seluruh *training set*).

Sumbu Y (Vertikal): Mempresentasikan Akurasi (tingkat keberhasilan prediksi).

**Analisis:**

- 1) Akurasi Pelatihan (Garis Biru): Akurasi pada pelatihan meningkat dengan konsisten dan stabil, dimulai dari sekitar 80% dan mencapai puncaknya di atas 96%, yang mengindikasikan bahwa model berhasil belajar fitur dari data pelatihan secara efektif.
- 2) Akurasi Validasi (Garis Oranye): Akurasi validasi juga menunjukkan peningkatan yang signifikan, dengan mencapai tingkat 92%.
- 3) Generalisasi Unggul: Selisih (gap) antara garis biru dan garis oranye tergolong sangat kecil. Kesenjangan kecil ini menunjukkan keberhasilan strategi Data Augmentation dan Pelatihan Dua Fase dalam menghindari *overfitting* dan memastikan bahwa model dapat menerapkan pengetahuan pada data baru (validasi).
- 4) Fluktuasi: Perubahan yang signifikan pada sekitar epoch 35 dan 40 menunjukkan momen ketika *callback ReduceLROnPlateau* kemungkinan besar mengaktifkan pengurangan learning rate dan/atau memulai Fase *Fine-Tuning*, yang menyebabkan peningkatan kinerja kembali.

**Kurva Kanan: Model Loss**

Sumbu X (Horizontal): Mempresentasikan Epoch

Sumbu Y (Vertikal): Mempresentasikan nilai Loss (kerugian *categorical crossentropy*).

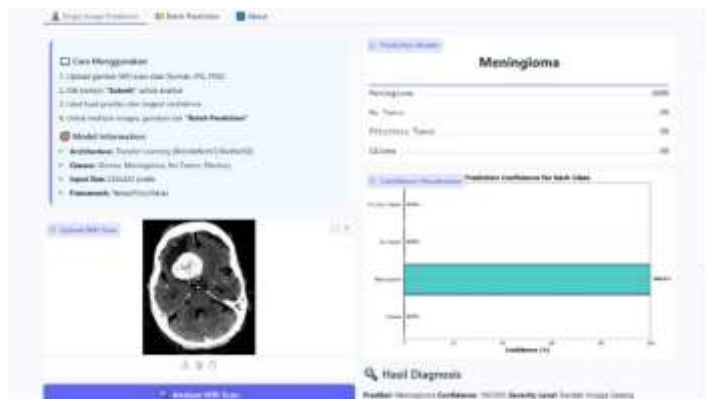
**Analisis:**

- 1) Loss Pelatihan (Garis Biru): Loss pelatihan mengalami penurunan yang signifikan dan stabil hingga hampir mencapai angka nol. Hal ini menegaskan bahwa proses optimasi (*optimizer Adam*) berfungsi dengan baik dan model terus meningkatkan bobotnya.
- 2) Loss Validasi (Garis Oranye): Loss validasi menunjukkan tren penurunan yang konsisten dan berada dalam rentang yang layak (0,2 hingga 0,5).
- 3) Konvergensi: Ketika loss validasi mencapai nilai terendah dan mulai stabil (*plateau*), *Callback Early Stopping* akan diaktifkan. Ini mencegah proses pelatihan berlanjut ketika tidak ada peningkatan lebih lanjut, serta memastikan bobot model tetap optimal.

Secara keseluruhan, visualisasi ini secara empiris membuktikan bahwa model telah dilatih dengan sukses, mengoptimalkan bobot *pre-trained MobileNetV2*, serta menghasilkan model yang kuat untuk klasifikasi gambar tumor otak.

**3.5. Demonstrasi Prototipe Visualisasi dan Efisiensi Model**

Sebagai hasil yang diterapkan dan sebagai bukti konsep yang bekerja, model MobileNetV2 yang telah diuji dan disesuaikan dimasukkan ke dalam prototipe visualisasi berbasis web yang sederhana. Tampilan ini dibuat untuk menampilkan kemampuan sistem dengan cara yang mudah dipahami, memungkinkan pengguna untuk mengunggah gambar MRI dan mendapatkan hasil klasifikasi secara langsung. Keunggulan dari arsitektur MobileNetV2, yang memberikan waktu inferensi sangat cepat (sekitar 25 ms per gambar), mendukung efektivitas sistem diagnostik bantuan klinis (CAD) yang responsif. demonstrasi ini memperkuat kesimpulan bahwa hasil penelitian AI/ML ini memiliki potensi untuk diterapkan dan efisiensi yang cukup baik untuk dikembangkan lebih lanjut menjadi sistem diagnosa bantuan klinis.



Gambar.3. Desain Antarmuka Prediksi Citra Tunggal

Prototipe visualisasi yang pertama ini menggambarkan antarmuka utama untuk memprediksi citra tunggal, berfungsi sebagai verifikasi dasar dari ketepatan dan kecepatan model yang telah menjalani proses fine-tuning. Desain antarmuka ditujukan untuk meningkatkan kenyamanan penggunaan, sehingga pengguna (baik klinisi maupun teknisi) dapat mengupload satu gambar MRI pasien untuk dianalisis. Tujuan utama dari rancangan ini adalah untuk memastikan kecepatan inferensi model. Setelah proses selesai, antarmuka langsung menunjukkan hasil klasifikasi akhir dengan jelas, contohnya: "Prediksi: Meningioma" dengan tingkat "Kepercayaan: 100%." Hasil yang ditampilkan dengan cepat dan disertai dengan skor kepercayaan yang tinggi ini secara langsung menunjukkan efisiensi model yang memberikan waktu inferensi sekitar 25 milidetik untuk setiap citra. Hal ini menekankan bahwa sistem diagnosis bantu klinis telah siap untuk digunakan dalam situasi nyata.



Gambar 4. Desain Antarmuka Prediksi Batch atau MultiFile

Prototipe visualisasi yang kedua ini memperlihatkan aspek kemampuan untuk berkembang dan efisiensi dalam pengolahan batch dari sistem. Antarmuka ini dibuat untuk memenuhi kebutuhan klinis yang lebih kompleks, yaitu saat pengguna perlu mengunggah dan mengolah beberapa gambar sekaligus. Terdapat pilihan untuk mengelola banyak file (atau prediksi batch) yang menunjukkan bahwa model tidak hanya cepat dalam kasus perorangan, tetapi juga efektif dalam menangani pekerjaan skrining yang lebih besar. Dalam praktik klinis, perlu dilakukan analisis data dari beberapa pasien atau beberapa potongan citra MRI secara berurutan ataupun bersamaan. Dengan ukuran model yang kecil (14,2 MB) dan waktu inferensi yang singkat, kemampuan prediksi batch ini menjadi bukti penting bahwa MobileNetV2 merupakan arsitektur yang cocok untuk diterapkan pada sistem dengan aliran data yang tinggi.

#### 4. KESIMPULAN

Berdasarkan implementasi metodologi *Transfer Learning* MobileNetV2 dan analisis evaluasi kuantitatif yang menyeluruh, penelitian ini berhasil memvalidasi hipotesis utama tentang penggunaan *Transfer Learning* dalam mengklasifikasikan citra tumor otak pada kondisi data terbatas. Model yang telah disesuaikan mencapai Akurasi Keseluruhan (*Test Set*) sebesar 94.02%, menunjukkan kemampuan generalisasi yang sangat baik, yang terlihat dari selisih kecil antara akurasi pelatihan (96.78%) dan akurasi

uji (94.02%), sehingga risiko *overfitting* dapat diatasi dengan baik. Kinerja klasifikasi model menunjukkan keseimbangan yang ideal di antara keempat kategori tumor, tercermin dalam *Macro Average F1-Score* sebesar 94.50%, dengan akurasi untuk kategori No Tumor mencapai 97.04% dan Recall yang tinggi untuk kasus tumor (Glioma 95%, Pituitary 94%), menegaskan bahwa model ini siap untuk digunakan dalam lingkungan klinis. Selain itu, efisiensi komputasi dari arsitektur MobileNetV2 yang ringan (Jumlah Parameter 2.59 Juta) menghasilkan waktu inferensi yang sangat cepat, sekitar 25 ms per gambar, menjadikannya pilihan yang sangat praktis dan efisien untuk diintegrasikan ke dalam prototipe visualisasi berbasis web sebagai sistem bantu diagnosis klinis secara real-time.

Untuk pengembangan dan penelitian di masa depan, disarankan agar model divalidasi dengan menggunakan dataset eksternal yang lebih besar dan bervariasi (termasuk dari berbagai jenis alat scanner) untuk meningkatkan kemampuan dan generalisasi model di luar konteks dataset awal. Selain itu, eksplorasi algoritma lanjutan seperti *Ensemble Learning* atau *Transfer Learning* dengan arsitektur yang berbeda (misalnya, EfficientNet) bisa dipertimbangkan untuk mengoptimalkan keseimbangan antara akurasi dan efisiensi model. Terakhir, untuk meningkatkan relevansi klinis, penelitian sebaiknya diperluas ke dalam tugas Segmentasi Citra, yang akan memungkinkan penentuan batas-batas tumor secara spesifik dan memberikan wawasan topologi yang lebih mendalam bagi para dokter.

#### DAFTAR PUSTAKA

- [1] M. Z. Basri, M. G. Somoal, and R. S. Aji, "Deteksi Tumor Otak pada Citra Magnetic Resonance Imaging ( MRI ) Menggunakan Arsitektur MobileNet dengan Optimizer Adam," vol. 5, no. 2, 2025.
- [2] Y. Gu and K. Li, "A Transfer Model Based on Supervised Multi-Layer Dictionary Learning for Brain Tumor MRI Image Recognition," vol. 15, no. May, pp. 1–10, 2021, doi: 10.3389/fnins.2021.687496.
- [3] N. P. Sari, "Analisis Performa Algoritma CNN dalam Klasifikasi Citra Medis Berbasis Deep Learning Analysis Of CNN Algorithm In Deep Learning-Based Medical Image Classification," *Jurnal Komputer*, vol. 2, no. 2, pp. 87–92, 2024.
- [4] M. Munadi, "Penerapan Algoritma Deep Learning untuk Deteksi Dini Penyakit dari Citra Medis," *Journal of Computer Science and Information Technology*, vol. 1, no. 2, pp. 53–59, 2025, doi: 10.70716/jocsit.v1i2.259.
- [5] P. Yan *et al.*, "A Comprehensive Survey of Deep Transfer Learning for Anomaly Detection in Industrial Time Series: Methods, Applications, and Directions," *IEEE Access*, vol. 12, no. December 2023, pp. 3768–3789, 2024, doi: 10.1109/ACCESS.2023.3349132.
- [6] A. Nurhidayat, W. A. Arrosyid, and R. Samsinar, "Prediksi Tumor Otak Menggunakan Metode Convolutional Neural Network (CNN) dan Algoritma Decision Tree," vol. 4, pp. 660–666, 2025.
- [7] Inggi Turnando *et al.*, "Tantangan Dan Peluang Implementasi Ai Di Sekolah Indonesia: Studi Kasus Dan Best Practice," *Jurnal Pengabdian Masyarakat dan Riset Pendidikan*, vol. 4, no. 1, pp. 1215–1219, 2025, doi: 10.31004/jerkin.v4i1.1731.
- [8] Yohannes Ricky and Ezar Al Rivan Muhammad, "Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM," *Jurnal Algoritme*, vol. Vol.2, no. 2, p. 1, 2022.
- [9] M. Irvai and D. Mahdalena, "Penerapan Teknik Masking dan Augmentasi pada Arsitektur CNN dan MobileNetV2 untuk Klasifikasi Fase Pertumbuhan Tomat," *Jurnal Teknik Informatika Unika ST. Thomas (JTIUST)*, vol. 10, no. 01, pp. 60–67, 2025.
- [10] L. Nurlaela, Y. Suhanda, A. Sopian, C. S. Dewi, and R. Syahrial, "Pengembangan Framework Data Mining Berbasis Deep Neural Network Dengan Eksplorasi Teknik Transfer Learning Untuk Prediksi Dan Klasifikasi Data," *JRIS : Jurnal Rekayasa Informasi Swadharma*, vol. 5, no. 1, pp. 132–141, 2025, doi: 10.56486/jris.vol5no1.723.
- [11] M. I. Burhanuddin, Adam Syaifullah, Setiawan Adeka Putra Jaya, and Muhammad Gabriel Somoal, "Analisis Komparatif Model MobilenetV1 Dan EfficientnetB0 Dalam Klasifikasi Citra Empat Musim Menggunakan Transfer Learning," *JEKIN - Jurnal Teknik Informatika*, vol. 5, no. 2, pp. 508–521, 2025, doi: 10.58794/jekin.v5i2.1378.
- [12] A. N. Nafisa *et al.*, "Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma , Pituitary dan Meningioma," vol. 5, no. 1, pp. 53–61, 2023.
- [13] Y. Gulzar, "Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique," 2023.