

Perbandingan Model CNN *Transfer Learning* untuk Deteksi Tumor Otak Berbasis Citra MRI

Noviyanto^{1*}, Sintia Darma Pamuja²

¹ Program Studi Teknologi Informasi, Fakultas Kesehatan dan Teknologi, Universitas Muhammadiyah Klaten, Klaten

² Program Studi Teknologi Informasi, Fakultas Kesehatan dan Teknologi, Universitas Muhammadiyah Klaten, Klaten

Email: ¹noviyanto@umkla.ac.id, ²sintia@umkla.ac.id

ABSTRACT — Brain tumors are serious neurological diseases that require early and accurate detection to support clinical decision-making. This study compares the performance of four transfer learning-based Convolutional Neural Network (CNN) models, namely DenseNet121, InceptionV3, MobileNet, and Xception, for brain tumor classification using MRI images. The novelty of this research lies in the use of a larger and more diverse MRI dataset with a four-class tumor classification scheme, enabling a more realistic evaluation of model performance under multi-class clinical scenarios. The dataset was preprocessed through image resizing, normalization, and data augmentation to enhance data variability. All models were trained for 20 epochs using ImageNet pre-trained weights under identical training configurations to ensure a fair comparison. Model performance was evaluated on the testing set using accuracy, precision, recall, and F1-score metrics to assess generalization capability. Experimental results show that all models achieved accuracy above 90%, with MobileNet demonstrating the best performance, achieving an accuracy of 94,74%, precision, recall, and F1-score values of 0,95, 0,95, and 0,94, respectively. These findings indicate that combining a multi-class and more diverse dataset with a lightweight and computationally efficient CNN architecture can deliver superior performance in MRI-based brain tumor classification, highlighting its potential for real-world clinical decision support systems.

KEYWORDS — Brain Tumor, MRI, CNN, Transfer Learning, Deep Learning, MobileNet.

INTISARI — Tumor otak merupakan penyakit serius yang memerlukan deteksi dini dan akurat untuk mendukung pengambilan keputusan klinis. Penelitian ini melakukan perbandingan kinerja empat model Convolutional Neural Network (CNN) berbasis transfer learning, yaitu DenseNet121, InceptionV3, MobileNet, dan Xception, dalam klasifikasi tumor otak menggunakan citra MRI. Kebaruan penelitian ini terletak pada penggunaan dataset MRI dengan jumlah data yang lebih besar serta skema klasifikasi multikelas yang lebih variatif, yaitu empat kelas tumor otak, sehingga evaluasi model menjadi lebih representatif terhadap kondisi klinis nyata. Dataset dilakukan *pre-processing* melalui resizing, normalisasi, dan augmentasi data untuk meningkatkan keragaman data latih. Seluruh model dilatih selama 20 epoch menggunakan bobot pralatih ImageNet dengan konfigurasi pelatihan yang seragam guna memastikan perbandingan yang adil. Evaluasi kinerja dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score pada data uji untuk menilai kemampuan generalisasi model. Hasil eksperimen menunjukkan bahwa seluruh model mencapai akurasi di atas 90%, dengan MobileNet menunjukkan performa terbaik dengan akurasi 94,74%, precision, recall, dan F1-score masing-masing sebesar 0,95, 0,95, dan 0,94. Temuan ini menunjukkan bahwa kombinasi dataset multikelas yang lebih variatif dan arsitektur CNN yang ringan dan efisien mampu menghasilkan kinerja unggul dalam klasifikasi tumor otak berbasis citra MRI, serta berpotensi diterapkan pada sistem pendukung diagnosis klinis.

KATA KUNCI — Tumor Otak, MRI, CNN, Transfer Learning, Deep Learning, MobileNet.

I. PENDAHULUAN

Tumor otak merupakan kondisi medis serius yang ditandai oleh pertumbuhan sel abnormal pada jaringan otak dan dapat mengancam jiwa apabila tidak terdeteksi secara dini [1]. Diagnosis awal yang akurat sangat krusial dalam menentukan strategi terapi yang tepat serta meningkatkan peluang keberhasilan perawatan dan kualitas hidup pasien. Kesalahan atau keterlambatan diagnosis dapat berdampak signifikan terhadap progresivitas penyakit dan prognosis pasien, sehingga diperlukan metode deteksi yang andal dan konsisten. Citra Magnetic Resonance Imaging (MRI) telah menjadi modalitas utama dalam deteksi tumor otak karena kemampuannya menyajikan informasi struktur jaringan otak secara detail dan

non-invasif. Namun, proses interpretasi citra MRI hingga saat ini masih sangat bergantung pada analisis visual oleh radiolog, yang bersifat subjektif, memerlukan keahlian tinggi, serta membutuhkan waktu yang relatif lama terutama ketika jumlah data pemeriksaan meningkat. Kondisi ini mendorong perlunya sistem otomatis berbasis komputasi untuk membantu meningkatkan efisiensi, konsistensi, dan akurasi diagnosis klinis [2].

Perkembangan pesat deep learning dalam dekade terakhir telah membuka peluang besar dalam pengolahan citra medis [3],[4] khususnya melalui Convolutional Neural Networks (CNN) yang mampu mengekstraksi fitur visual kompleks secara otomatis tanpa memerlukan rekayasa fitur manual [5] [6]. CNN

telah banyak diaplikasikan dalam berbagai tugas analisis citra MRI, termasuk klasifikasi dan deteksi tumor otak, dengan hasil yang menjanjikan dan performa yang melampaui metode konvensional [2]. Implementasi CNN dalam konteks klinis berpotensi berperan sebagai sistem pendukung keputusan yang membantu radiolog dalam mengidentifikasi tumor secara lebih cepat dan konsisten [7], terutama pada fasilitas kesehatan dengan keterbatasan sumber manusia.

Meskipun demikian, pelatihan model CNN secara from scratch pada domain medis sering menghadapi kendala berupa keterbatasan jumlah dataset berlabel serta risiko overfitting. Untuk mengatasi permasalahan tersebut, pendekatan transfer learning menjadi solusi yang banyak diadopsi [8], dengan memanfaatkan model CNN yang telah dilatih pada dataset berskala besar seperti *ImageNet* dan kemudian dilakukan fine-tuning untuk tugas spesifik. Pendekatan ini terbukti mampu meningkatkan kemampuan generalisasi model, mempercepat proses pelatihan, serta mengurangi kebutuhan data dalam jumlah besar [9]. Dari sudut pandang klinis, transfer learning memungkinkan pengembangan sistem deteksi tumor otak yang lebih efisien dan mudah diadaptasi pada berbagai lingkungan rumah sakit.

Sejumlah penelitian sebelumnya telah membandingkan berbagai arsitektur Convolutional Neural Network (CNN) pra-latih untuk klasifikasi tumor otak, seperti VGG19, ResNet50, InceptionV3, dan DenseNet121. Hasil studi tersebut menunjukkan bahwa setiap arsitektur memiliki karakteristik kinerja yang berbeda, baik dari sisi tingkat akurasi maupun kompleksitas model yang digunakan [10]. Selain itu, penelitian lain yang membandingkan tiga model CNN, yaitu VGG16, ResNet50, dan Xception, melaporkan bahwa meskipun model mampu mencapai akurasi pelatihan yang sangat tinggi hingga 99%, kinerja pada data pengujian mengalami penurunan signifikan menjadi sekitar 85%. Kondisi ini mengindikasikan adanya masalah overfitting, di mana model kurang mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya [11].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja empat model CNN berbasis transfer learning yaitu DenseNet121, InceptionV3, MobileNet, dan Xception dalam mendeteksi tumor otak menggunakan citra MRI. Hasil penelitian ini diharapkan dapat memberikan rekomendasi model yang paling optimal untuk dikembangkan sebagai sistem pendukung diagnosis klinis, serta menjadi referensi bagi pengembangan solusi kecerdasan buatan yang aplikatif dan berkelanjutan di bidang kesehatan.

II. TINJAUAN PUSTAKA

A. Deep Learning dan CNN dalam Pengolahan Citra Medis

Convolutional Neural Networks (CNN) merupakan salah satu arsitektur pembelajaran mesin yang paling efektif dalam pengolahan citra. CNN menggabungkan lapisan konvolusi, pemetaan non-linear, dan pooling untuk mengekstraksi fitur citra secara hierarkis. Pendekatan ini telah digunakan secara ekstensif dalam tugas klasifikasi citra medis termasuk tumor otak, di mana CNN dapat secara otomatis mengekstraksi fitur representatif dari citra MRI untuk membedakan antara kondisi tumor dan non-tumor [12], [13].

B. Transfer Learning pada Deteksi Tumor Otak

Transfer learning adalah pendekatan yang memanfaatkan model yang telah dilatih sebelumnya pada dataset besar seperti *ImageNet* dan kemudian diadaptasi (*fine-tuned*) untuk tugas tertentu. Dalam kasus klasifikasi tumor otak, transfer learning memungkinkan model memanfaatkan pengetahuan fitur umum yang telah dipelajari dari jutaan gambar dan meminimalkan kebutuhan akan dataset yang sangat besar dalam domain medis. Pendekatan ini telah terbukti meningkatkan performa serta mempercepat proses pelatihan dalam banyak studi [9].

C. Studi Perbandingan Model CNN

Beberapa model CNN telah dibandingkan dalam konteks klasifikasi MRI tumor otak. Misalnya, studi yang mengevaluasi kinerja *VGG19*, *ResNet50*, *InceptionV3*, dan *DenseNet121* menunjukkan bahwa setiap model memiliki karakteristik performa yang berbeda dalam hal akurasi, presisi, dan *F1-score*. Hasil penelitian ini memberikan gambaran bahwa model residu seperti *ResNet50* cenderung memiliki performa unggul dalam deteksi tumor otak pada dataset tertentu, namun model lain seperti *DenseNet121* dan *InceptionV3* juga memberikan kontribusi kompetitif [10].

Penelitian lanjutan menyarankan perlunya evaluasi komparatif lebih luas terhadap model CNN modern yang efisien secara komputasi dan dapat diaplikasikan pada sistem real-time serta perangkat dengan sumber daya terbatas [14].

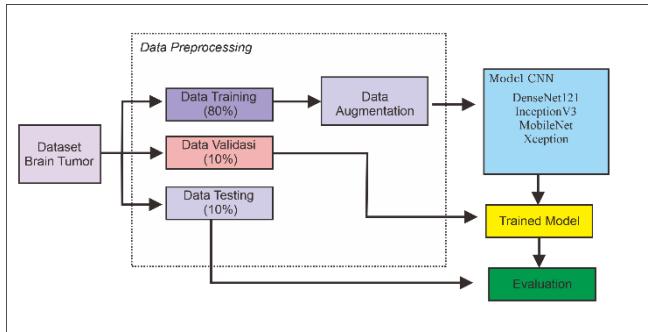
Sejumlah penelitian sebelumnya telah membandingkan model CNN pra-latih dalam klasifikasi tumor otak berbasis citra MRI menggunakan metrik accuracy, precision, recall, dan *F1-score*. Beberapa studi mengkaji model seperti *VGG19*, *ResNet50*, *InceptionV3*, dan *DenseNet121*, yang menunjukkan bahwa setiap arsitektur memiliki karakteristik performa berbeda tergantung pada struktur jaringan dan dataset yang digunakan [13]. Selain itu, terdapat penelitian yang membandingkan *VGG16*, *ResNet50* dan *Xception* dengan jumlah dataset yang relatif terbatas sehingga hasil evaluasi belum sepenuhnya merepresentasikan kemampuan generalisasi model pada variasi data MRI yang lebih luas [11]. Penelitian selanjutnya menekankan pentingnya penggunaan dataset dengan jumlah yang lebih besar dan beragam guna meningkatkan reliabilitas evaluasi serta kemampuan generalisasi model [15].

D. Kebutuhan Penelitian Saat Ini

Meskipun pendekatan transfer learning telah banyak diterapkan dalam klasifikasi tumor otak, perbandingan terhadap beberapa arsitektur CNN modern dengan dataset berukuran besar masih terbatas. Oleh karena itu, penelitian ini melakukan evaluasi terhadap empat model CNN berbasis transfer learning, yaitu DenseNet121, InceptionV3, MobileNet, dan Xception, menggunakan dataset yang lebih besar dan beragam sebanyak 7.022 citra MRI. Evaluasi dilakukan secara konsisten menggunakan metrik accuracy, precision, recall, dan *F1-score* untuk memperoleh gambaran kinerja model yang lebih representatif dan relevan bagi pengembangan sistem deteksi tumor otak berbasis AI dalam konteks aplikasi klinis. [12].

III. METODOLOGI

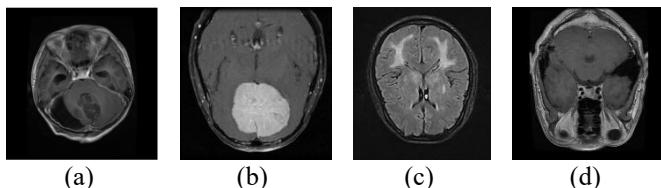
Penelitian ini menggunakan pendekatan eksperimental kuantitatif dengan membandingkan beberapa model *Convolutional Neural Network* (CNN) berbasis transfer learning untuk mendeteksi tumor otak menggunakan citra MRI.



Gambar 1. Alur Penelitian

A. DATASET

Dalam penelitian ini, dataset yang digunakan merupakan kumpulan gambar penyakit tumor otak berupa citra *Magnetic Resonance Imaging* (MRI) otak, yang diperoleh dari dataset publik (*Brain Tumor MRI Dataset*). Dataset ini dapat diakses melalui tautan berikut: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset/data> [16]. Totalnya dataset terdiri dari 7022 gambar yang diklasifikasikan ke dalam empat kelas, yaitu Glioma, meningioma, notumor, dan pituitary. Semua gambar disimpan dalam format JPG, sesuai yang terlihat pada Gambar 2.



Gambar 2. Jenis Penyakit Tumor Otak, (a) glioma, (b) meningioma, (c) notumor, (d) pituitary.

Tiga komponen dataset yang digunakan dalam penelitian ini adalah 10% untuk validasi, 10% untuk pengujian, dan 80% untuk pelatihan yang dibagi random.

B. PRE-PROCESSING DATA

Tahapan *pre-processing* dilakukan untuk meningkatkan kualitas citra dan menyesuaikan format input dengan arsitektur CNN. Langkah-langkah *pre-processing* meliputi:

1) Resizing

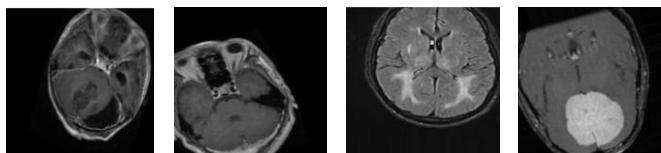
Seluruh citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan ukuran input model CNN.

2) Normalisasi

Nilai intensitas piksel dinormalisasi ke rentang $[0,1]$ guna mempercepat proses konvergensi selama pelatihan.

3) Data Augmentation

Untuk mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model, dilakukan augmentasi data berupa rotasi, *width shift range*, *height shift range*, *flip horizontal*, *zoom*, dan *shear transformation*.



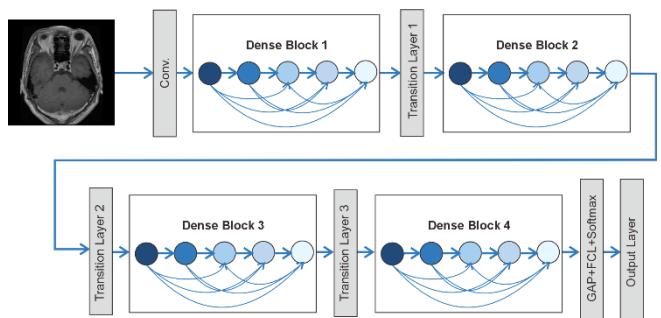
Gambar 3. Hasil augmentasi dari citra penyakit tumor otak

C. Model Transfer Learning

Penelitian ini menggunakan empat arsitektur CNN berbasis *transfer learning* yang telah dilatih sebelumnya menggunakan dataset *ImageNet*, yaitu:

1) DenseNet121

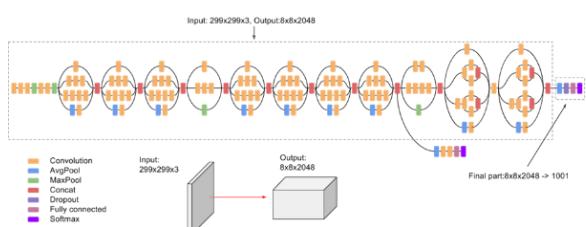
DenseNet121 adalah varian arsitektur *Densely Connected Convolutional Networks* yang menghubungkan setiap layer dengan semua layer sebelumnya melalui koneksi dens (*dense connections*). Pendekatan ini memperkuat aliran gradien selama pelatihan, mengurangi redundansi fitur, serta meningkatkan efisiensi parameter dan kemampuan generalisasi [17]. Dalam konteks deteksi tumor otak, *DenseNet121* telah digunakan sebagai model transfer learning yang efektif dalam klasifikasi MRI dengan akurasi tinggi, karena kemampuannya dalam mengekstraksi fitur penting dari gambar medis yang kompleks. Studi terbaru menggunakan *DenseNet121* bersama model lain (termasuk *InceptionV3*, *MobileNetV2*, dan *Xception*) menunjukkan bahwa model ini termasuk dalam arsitektur deep learning yang optimal untuk klasifikasi tumor otak dengan kinerja yang kompetitif, terutama dalam menangani dataset besar MRI otak guna mengoptimalkan akurasi dan efisiensi komputasi.



Gambar 4. Ilustrasi Arsitektur DenseNet121

2) InceptionV3

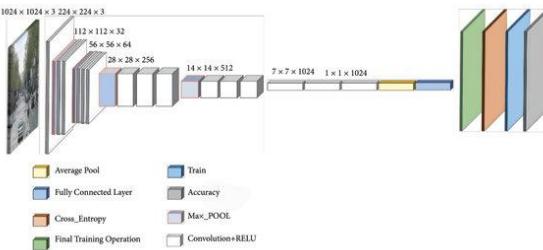
InceptionV3 merupakan salah satu arsitektur CNN yang banyak digunakan dalam klasifikasi citra berkat Inception modules yang mampu memproses fitur pada berbagai skala secara paralel. Arsitektur ini memungkinkan model untuk mengekstraksi fitur yang lebih kaya dan kompleks tanpa meningkatkan jumlah parameter secara signifikan. Model ini telah banyak digunakan dalam aplikasi medis, khususnya dalam tugas klasifikasi MRI tumor, dan menjadi salah satu model utama yang dibandingkan dalam literatur terbaru untuk mengevaluasi performa transfer learning pada dataset MRI otak, sekaligus menunjukkan kemampuan generalisasi yang baik pada data citra medis [18].



Gambar 5. Ilustrasi Arsitektur InceptionV3

3) MobileNet

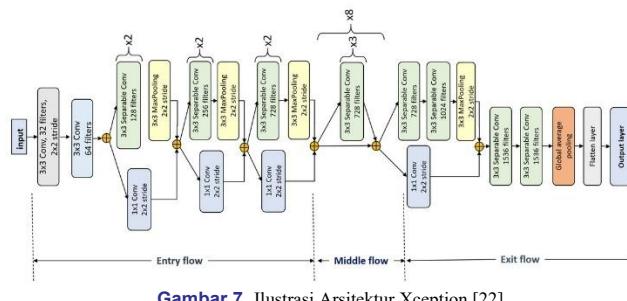
MobileNet adalah arsitektur CNN yang dirancang khusus untuk efisiensi komputasi dengan menggunakan *depthwise separable convolutions* sebagai pengganti konvolusi standar. Pendekatan ini mengurangi jumlah parameter dan kebutuhan komputasi tanpa mengorbankan kemampuan representasi fitur. Dalam penelitian klasifikasi tumor otak berbasis MRI, MobileNet (termasuk edisi seperti MobileNetV2) telah menunjukkan hasil yang kuat yang bersaing dengan arsitektur yang lebih kompleks, dengan akurasi tinggi dan efisiensi yang baik, sehingga cocok untuk implementasi pada perangkat dengan sumber daya terbatas [19].



Gambar 6. Ilustrasi Arsitektur MobileNet [20]

4) Xception

Xception merupakan arsitektur CNN yang merupakan pengembangan dari arsitektur Inception dengan menerapkan *depthwise separable convolution* secara penuh pada seluruh jaringan. Hal ini memungkinkan pemisahan yang lebih efisien antara korelasi kanal dan spasial dalam pemrosesan citra. Xception telah terbukti sangat efektif dalam tugas klasifikasi citra medis termasuk MRI tumor otak. Penelitian terbaru menunjukkan bahwa Xception sering menempati posisi teratas dalam kinerja klasifikasi tumor otak bila dibandingkan dengan beberapa model pra-latih lainnya, menjadikannya salah satu pilihan populer dalam *transfer learning* untuk aplikasi medis [21].



Gambar 7. Ilustrasi Arsitektur Xception [22]

Bobot awal (*pre-trained weights*) dari ImageNet digunakan sebagai dasar pembelajaran untuk mempercepat proses pelatihan dan meningkatkan akurasi model.

D. Arsitektur Klasifikasi dan Fine-Tuning

Pada setiap model, lapisan klasifikasi bawaan digantikan dengan lapisan kustom yang terdiri dari Global Average Pooling untuk merangkum fitur spasial, Dropout sebagai mekanisme regularisasi guna mengurangi overfitting, serta Flatten untuk

mengubah fitur menjadi representasi vektor. Lapisan keluaran menggunakan fungsi aktivasi Softmax yang disesuaikan dengan jumlah kelas pada proses klasifikasi.

Selain itu, proses fine-tuning dilakukan dengan membekukan (freeze) seluruh lapisan awal hingga lapisan menengah dari backbone CNN, yang berperan sebagai feature extractor dan telah mempelajari fitur-fitur dasar seperti tepi, tekstur, dan pola umum. Beberapa lapisan konvolusional terakhir (top layers) dibuka kembali (unfreeze) untuk dilatih ulang agar model dapat menyesuaikan fitur tingkat tinggi dengan karakteristik spesifik dataset yang digunakan. Pendekatan ini bertujuan untuk menjaga stabilitas pembelajaran sekaligus meningkatkan kemampuan diskriminasi model terhadap kelas target.

E. Konfigurasi Pelatihan

Proses pelatihan model dilakukan menggunakan *optimizer Adam* dengan nilai learning rate sebesar 0.0009. Seluruh model dilatih selama 20 epoch, sementara fungsi kerugian (loss function) yang digunakan adalah *Categorical Cross-Entropy*, yang sesuai untuk tugas klasifikasi multi-kelas. Konfigurasi pelatihan ini diterapkan secara konsisten pada seluruh model untuk memastikan proses pembelajaran yang stabil dan perbandingan kinerja yang adil.

F. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan menggunakan data pengujian (*testing set*) untuk menilai kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Kinerja model diukur menggunakan beberapa metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*, yang diperoleh berdasarkan nilai *confusion matrix* yang terdiri dari *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN).

Accuracy digunakan untuk mengukur tingkat ketepatan model secara keseluruhan dalam mengklasifikasikan data dan dihitung sebagai perbandingan antara jumlah prediksi yang benar terhadap total seluruh data, yang dirumuskan sebagai:

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN}$$

Precision menggambarkan tingkat ketepatan model dalam memprediksi kelas positif, yaitu seberapa banyak prediksi positif yang benar dibandingkan dengan seluruh prediksi positif yang dihasilkan model. Nilai precision dihitung menggunakan rumus .

$$\text{Precision} = \frac{TP}{TP + FP}$$

Recall menunjukkan kemampuan model dalam mendeteksi seluruh data positif yang sebenarnya, atau seberapa besar proporsi data positif yang berhasil diklasifikasikan dengan benar. Nilai recall dirumuskan sebagai.

$$\text{Recall} = \frac{TP}{TP + FN}$$

Sementara itu, **F1-Score** merupakan nilai rata-rata harmonik dari precision dan recall yang digunakan untuk memberikan

keseimbangan antara kedua metrik tersebut, terutama pada kondisi data yang tidak seimbang. F1-Score dihitung dengan persamaan.

$$Recall = \frac{TP}{TP + FN}$$

Semua eksperimen dilakukan menggunakan TensorFlow di Google Colaboratory sebagai platform cloud computing yang memiliki RAM 25 GB dan GPU NVIDIA Tesla T4

IV. HASIL DAN PEMBAHASAN

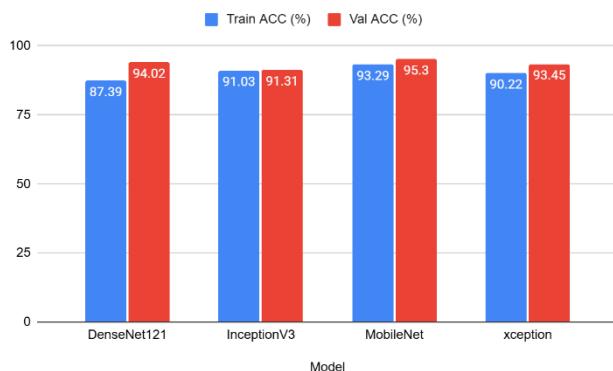
A. Hasil Pengujian Model

Penelitian ini mengevaluasi kinerja empat model *Convolutional Neural Network* (CNN) berbasis *transfer learning*, yaitu DenseNet121, InceptionV3, MobileNet, dan Xception, dalam tugas deteksi tumor otak menggunakan citra MRI. Seluruh model dilatih selama 20 epoch dengan konfigurasi pelatihan yang sama untuk menjamin perbandingan yang adil (*fair comparison*).

Hasil Pelatihan dan Validasi

Berdasarkan grafik hasil pelatihan, terlihat bahwa seluruh model mampu mencapai nilai akurasi *training* dan validasi yang tinggi. DenseNet121 menunjukkan akurasi *training* sebesar 87,39% dan akurasi validasi 94,02%, sedangkan InceptionV3 memperoleh akurasi *training* 91,03% dan validasi 91,31%. Model MobileNet mencatatkan performa tertinggi pada tahap ini dengan akurasi *training* 93,29% dan validasi 95,30%, sementara Xception mencapai akurasi *training* 90,22% dan validasi 93,45%.

Hasil tersebut menunjukkan bahwa seluruh model mampu melakukan pembelajaran dengan baik tanpa indikasi *overfitting* yang signifikan, ditandai dengan selisih yang relatif kecil antara akurasi *training* dan validasi.



Gambar 8. Hasil akurasi data pelatihan dan data validasi dari Model CNN

Hasil Pengujian Menggunakan Data Uji

Evaluasi akhir dilakukan menggunakan data pengujian (*testing set*) untuk menilai kemampuan generalisasi model. Hasil pengujian ditunjukkan pada Tabel 1, yang memuat nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score*.

Tabel 1. Hasil Pengujian Model CNN Transfer Learning

| No | Model | Accuracy (%) | Precision (%) | Recall (%) | F1 Score (%) |
|----|-------------|--------------|---------------|------------|--------------|
| 1 | DenseNet121 | 92.61 | 93.00 | 93.00 | 93.00 |
| 2 | InceptionV3 | 90.77 | 91.00 | 90.00 | 90.00 |
| 3 | MobileNet | 94.74 | 95.00 | 95.00 | 94.00 |
| 4 | Xception | 93.18 | 93.00 | 93.00 | 93.00 |

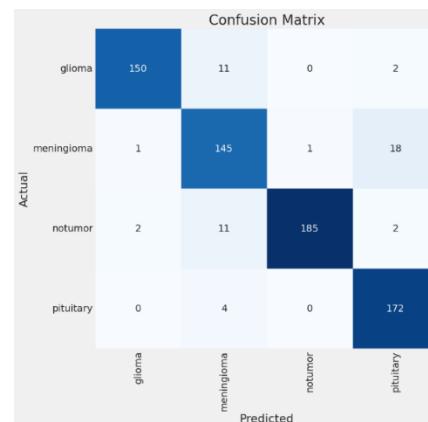
Berdasarkan hasil pengujian, *MobileNet* menunjukkan kinerja terbaik dengan akurasi tertinggi sebesar 94,74%, serta nilai precision, recall, dan F1-score masing-masing mencapai 95%, 95%, dan 94%. Model *Xception* dan *DenseNet121* juga menunjukkan performa yang stabil dengan nilai akurasi di atas 92%, sementara *InceptionV3* memiliki performa paling rendah dibandingkan model lainnya, meskipun tetap berada pada kategori akurasi tinggi.

Secara keseluruhan, hasil ini menunjukkan bahwa seluruh model CNN berbasis transfer learning mampu memberikan performa yang baik dan konsisten dalam mendeteksi tumor otak dari citra MRI. Nilai akurasi yang tinggi pada data pelatihan, validasi, dan pengujian mengindikasikan bahwa pendekatan transfer learning efektif digunakan meskipun dataset yang tersedia relatif terbatas.

B. Analisis Perbandingan Model

1) DenseNet121

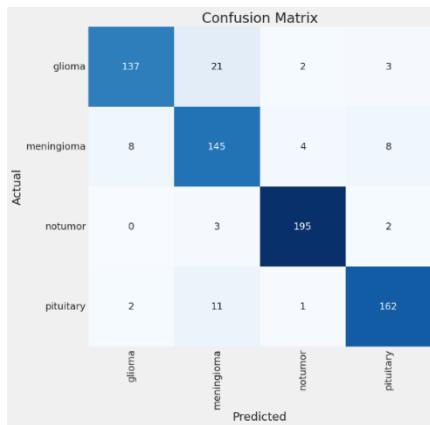
Model *DenseNet121* mencapai akurasi sebesar 92.61% dengan nilai precision 0.93, recall 0.93, dan F1-score 0.93. Kinerja ini menunjukkan bahwa koneksi dens antar layer pada *DenseNet* mampu mempertahankan aliran informasi fitur secara efektif. Namun, performanya masih sedikit di bawah *Xception*, yang menunjukkan bahwa arsitektur yang lebih ringan dapat memberikan generalisasi yang lebih baik pada dataset ini.



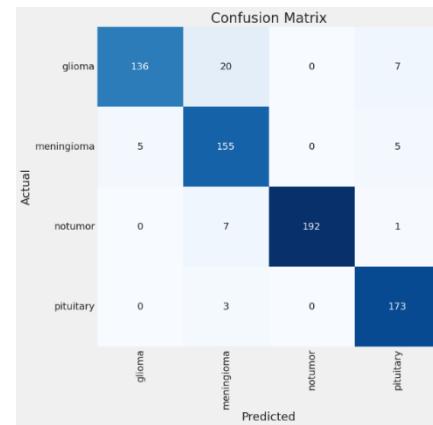
Gambar 9. Confusion matrix model DenseNet121

2) InceptionV3

Model *InceptionV3* memperoleh akurasi sebesar 90.77%, yang merupakan nilai terendah di antara model yang diuji. Meskipun demikian, nilai *precision*, *recall*, dan *F1-score* masing-masing 91, 90 & 90 menunjukkan bahwa model ini cukup stabil dalam mengklasifikasikan kelas tumor dan non-tumor. Kompleksitas arsitektur *InceptionV3* yang relatif tinggi diduga memerlukan jumlah data yang lebih besar untuk mencapai performa optimal.



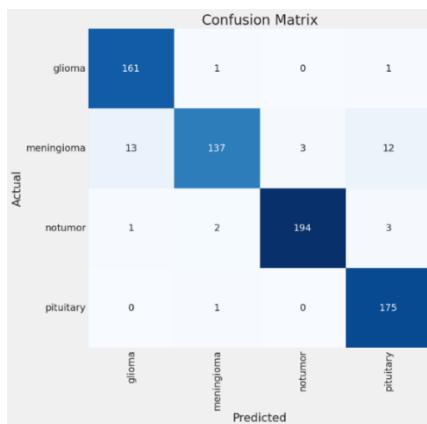
Gambar 10. Confusion matrix model InceptionV3



Gambar 12. Confusion matrix model Xception

3) MobileNet

Model **MobileNet** menunjukkan kinerja terbaik dengan akurasi tertinggi sebesar **94,74%**, serta nilai precision, recall, dan F1-score masing-masing **95, 95 dan 94**. Hasil ini menunjukkan bahwa arsitektur MobileNet yang menggunakan *depthwise separable convolution* mampu mengekstraksi fitur penting secara efisien dan mengurangi risiko *overfitting*. Selain itu, efisiensi komputasi *MobileNet* menjadikannya sangat potensial untuk diimplementasikan pada sistem deteksi tumor otak berbasis real-time atau perangkat dengan sumber daya terbatas.



Gambar 11. Confusion matrix model MobileNet

4) Xception

Model **Xception** mencapai akurasi **93,18%** dengan *precision*, *recall*, dan *F1-score* dengan nilai yang sama yaitu **93**. Performa ini relatif sebanding dengan *DenseNet121* dan lebih baik dibandingkan *InceptionV3*. Penggunaan *depthwise separable convolution* secara penuh pada *Xception* membantu meningkatkan efisiensi pembelajaran fitur, meskipun keunggulannya belum melampaui *MobileNet* pada dataset yang digunakan.

V. KESIMPULAN

Penelitian ini membuktikan bahwa pendekatan transfer learning menggunakan model CNN DenseNet121, InceptionV3, MobileNet, dan Xception efektif dalam deteksi tumor otak berbasis citra MRI dengan seluruh model mencapai akurasi di atas 90%, di mana MobileNet menunjukkan kinerja terbaik dengan akurasi 94,74% serta nilai precision, recall, dan F1-score tertinggi disertai efisiensi komputasi yang baik. Meskipun demikian, penelitian ini masih memiliki keterbatasan pada ukuran dan keragaman dataset, penggunaan satu jenis modalitas MRI, serta belum diterapkannya model pada lingkungan klinis nyata dan analisis interpretabilitas.

Secara praktis, hasil penelitian ini menunjukkan bahwa MobileNet berpotensi kuat untuk dikembangkan sebagai sistem pendukung deteksi tumor otak yang efisien dan berpeluang diimplementasikan di lingkungan medis.

REFERENSI

- [1] A. Hekmat, Z. Zuping, O. Bilal, and S. U. R. Khan, “Differential evolution-driven optimized ensemble network for brain tumor detection,” *International Journal of Machine Learning and Cybernetics*, vol. 16, no. 9, pp. 6447–6472, 2025, doi: 10.1007/s13042-025-02629-6.
- [2] D. Candra, G. Wibisono, M. Ayu, and M. Afrad, “LEDGER: Journal Informatic and Information Technology Transfer Learning model Convolutional Neural Network menggunakan VGG-16 untuk Klasifikasi Tumor Otak pada Citra Hasil MRI,” 2024.
- [3] A. Chaddad, Y. Hu, Y. Wu, B. Wen, and R. Kateb, “Generalizable and explainable deep learning for medical image computing: An overview,” *Curr. Opin. Biomed. Eng.*, vol. 33, p. 100567, 2025, doi: <https://doi.org/10.1016/j.cobme.2024.100567>.
- [4] J. Chen *et al.*, “A survey on deep learning in medical image registration: New technologies, uncertainty, evaluation metrics, and beyond,” *Med. Image Anal.*, vol. 100, p. 103385, 2025, doi: <https://doi.org/10.1016/j.media.2024.103385>.
- [5] I. D. Mienye, T. G. Swart, G. Obaido, M. Jordan, and P. Ilono, “Deep Convolutional Neural Networks in Medical Image Analysis: A Review,” Mar. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/info16030195.
- [6] C. Chen, N. A. Mat Isa, and X. Liu, “A review of convolutional neural network based methods for medical image classification,” *Comput. Biol. Med.*, vol. 185, p. 109507, 2025, doi: <https://doi.org/10.1016/j.combiomed.2024.109507>.
- [7] Y. Wu, S. Fong, and L. Liu, “Shadow learner system: implementation of CNN with explainable AI model for bone radiology image classification,” *Sofia comput.*, vol. 29, no. 7, pp. 3571–3588, 2025, doi: 10.1007/s00500-025-10644-6.
- [8] A. K. Sharma, A. Nandal, A. Dhaka, A. Alhudhaif, K. Polat, and A. Sharma, “Diagnosis of cervical cancer using CNN deep learning

- model with transfer learning approaches,” *Biomed. Signal Process. Control*, vol. 105, p. 107639, 2025, doi: <https://doi.org/10.1016/j.bspc.2025.107639>.
- [9] P. Dhanalakshmi, S. Pavani, N. Fathima, R. Usha, M. Mahesh, and M. Likitha, “A Hybrid Transfer Learning Model for Predicting Chronic Kidney Disease Using DenseNet121 and InceptionV3,” in *2025 International Conference on Knowledge Engineering and Communication Systems (ICKECS)*, IEEE, Apr. 2025, pp. 1–6. doi: 10.1109/ICKECS65700.2025.11036010.
- [10] R. Disci, F. Gurcan, and A. Soylu, “Advanced Brain Tumor Classification in MR Images Using Transfer Learning and Pre-Trained Deep CNN Models,” *Cancers (Basel)*, vol. 17, no. 1, 2025, doi: 10.3390/cancers17010121.
- [11] K. N. Qodri, “Indonesian Journal Of Information Technology Analisis Perbandingan Klasifikasi Tumor Otak Menggunakan Deep Learning,” *INDONESIAN JOURNAL OF INFORMATION TECHNOLOGY*, vol. 2, no. 1, pp. 3047–5511, 2024, doi: 10.25077/Attribution-NonCommercial.
- [12] D. Hareesh, Sk. Riyaz, Y. S. Reddy, and B. J. N, “Brain Tumor Detection Using Deep Learning Techniques,” in *2025 2nd International Conference on Research Methodologies in Knowledge Management, Artificial Intelligence and Telecommunication Engineering (RMKMATE)*, IEEE, May 2025, pp. 1–6. doi: 10.1109/RMkmate64874.2025.11042498.
- [13] K. D. Kadam, S. Ahirrao, and K. Kotecha, “Efficient Approach towards Detection and Identification of Copy Move and Image Splicing Forgeries Using Mask R-CNN with MobileNet V1,” *Comput. Intell. Neurosci.*, vol. 2022, pp. 1–21, Jan. 2022, doi: 10.1155/2022/6845326.
- [14] D. Listianing Tyas, F. Rocky Rumambi, A. Patanduk, and R. Christopel Johanes Mailangkay, “Klasifikasi Jenis Tumor Otak Melalui Citra MRI dengan Menggunakan Convolutional Neural Network,” *Informatik : Jurnal Ilmu Komputer*, vol. 21, no. 1, pp. 26–34, Apr. 2025, doi: 10.52958/iftk.v21i1.11095.
- [15] R. Rudiansyah and A. Husein, “Klasifikasi Tumor Otak pada gambar Magnetic Resonance Images (MRI) dengan Pendekatan Pembelajaran Mendalam,” *Data Sciences Indonesia (DSI)*, vol. 4, no. 1, pp. 62–68, Jul. 2024, doi: 10.47709/dsi.v4i1.4265.
- [16] M. F. F. Mardianto, E. Pusporani, F. N. Salsabila, A. N. Nitasaki, and N. Lu’lu’a, “Optimizing Brain Tumor MRI Classification with Transfer Learning: A Performance Comparison of Pre-Trained CNN Models,” *Jurnal Nasional Pendidikan Teknik Informatika (JANPATI)*, vol. 14, no. 1, pp. 13–26, Mar. 2025, doi: 10.23887/janpati.v14i1.87377.
- [17] Noviyanto, A. Sunyoto, and D. Ariyatmanto, “Innovative Solutions for Bean Leaf Disease Detection Using Deep Learning,” in *2024 IEEE International Conference on Artificial Intelligence and Mechatronics Systems (AIMS)*, IEEE, Feb. 2024, pp. 1–5. doi: 10.1109/AMIS61812.2024.10512726.
- [18] N. Pratama, M. Liebenlito, and Y. Irene, “Perbandingan Model Klasifikasi Transfer Learning Convolutional Neural Network Tumor Otak menggunakan Citra Magnetic Resonance Imaging,” *Jurnal Sehat Indonesia (JUSINDO)*, vol. 6, no. 01, pp. 308–318, Jan. 2024, doi: 10.59141/jsi.v6i01.81.
- [19] M. Rasheed *et al.*, “Improved brain tumor classification through DenseNet121 based transfer learning,” *Discover Oncology*, vol. 16, no. 1, p. 1645, Aug. 2025, doi: 10.1007/s12672-025-03501-3.
- [20] M. M. A. Shibly, T. A. Tisha, T. A. Tani, and S. Ripon, “Convolutional neural network-based ensemble methods to recognize Bangla handwritten character,” *PeerJ Comput. Sci.*, vol. 7, p. e565, Jun. 2021, doi: 10.7717/peerj.cs.565.
- [21] J. S. Sulistyawan, K. S. Nugroho, M. Isnand, and B. Pardamean, “Comparative Analysis of CNN Models for Multiclass Detection on Colon Disease,” in *2024 9th International Conference on Information Technology and Digital Applications (ICITDA)*, IEEE, Nov. 2024, pp. 01–06. doi: 10.1109/ICITDA64560.2024.10809661.
- [22] R. Vignesh and D. Hepsiba, “Chronic Kidney Disease Prediction using DL: A Comparative Study of CNN VGG16 and MOBILENET,” in *2025 Eleventh International Conference on Bio Signals, Images, and Instrumentation (ICBSII)*, IEEE, Mar. 2025, pp. 1–6. doi: 10.1109/ICBSII65145.2025.11013191.