



KLASIFIKASI CITRA TUMOR OTAK MENGGUNAKAN TEKNIK TRANSFER LEARNING PADA ARSITEKTUR RESNET-50

Yusrina Ilmi Salsabila¹, Hery Mustofa²,
Masy Ari Ulinuha³

Program Studi Teknologi Informasi
Fakultas Sains dan Teknologi
Universitas Islam Negeri Walisongo Semarang

ilmisalsa04@gmail.com¹, herymustofa@walisongo.ac.id²,
ulinuha@walisongo.ac.id³

Received: May 3, 2025. **Revised:** May 29, 2025. **Accepted:** May 30, 2025. **Issue Period:** Vol.9 No.1 (2025), Pp. 128-139

Abstrak: Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi performa model *deep learning* Convolutional Neural Network (CNN) berbasis arsitektur ResNet-50 dalam klasifikasi citra Magnetic Resonance Imaging (MRI) tiga jenis tumor otak: glioma, meningioma, dan pituitary. Pendekatan *transfer learning* digunakan dengan dua skenario *fine-tuning*, yaitu pembekuan 30 layer pertama dan pembekuan 15 layer pertama. Dataset terdiri dari 3.064 citra MRI yang dibagi ke dalam data latih dan uji dengan rasio 80:20. Citra diproses melalui tahapan *resizing*, normalisasi, dan augmentasi untuk meningkatkan variasi data. Model dievaluasi menggunakan metrik akurasi, precision, recall, F1-score, *confusion matrix*, dan ROC-AUC. Hasil menunjukkan bahwa model dengan freeze 15 layer memberikan akurasi lebih tinggi sebesar 91,86% dibandingkan freeze 30 layer sebesar 90,88%. Namun, model dengan freeze 30 layer menunjukkan kestabilan dan generalisasi yang lebih baik terhadap data uji, terutama dalam mendeteksi meningioma. Temuan ini menunjukkan bahwa ResNet-50 efektif dalam klasifikasi tumor otak berbasis MRI, dan *fine-tuning* yang tepat berpengaruh terhadap performa akhir model.

Kata kunci: tumor otak, MRI, CNN, ResNet-50, transfer learning, klasifikasi citra

Abstract: This study aims to implement and evaluate the performance of a deep learning Convolutional Neural Network (CNN) model based on the ResNet-50 architecture for classifying Magnetic Resonance Imaging (MRI) brain tumor images into three types: glioma, meningioma, and pituitary. A transfer learning approach was applied using two fine-tuning scenarios: freezing the first 30 layers and freezing the first 15 layers. The dataset consisted of 3,064 MRI images, split into training and testing data at an 80:20 ratio. Images were processed through resizing, normalization, and augmentation to enhance data diversity. The model was evaluated using accuracy, precision, recall, F1-score, confusion matrix, and ROC-AUC metrics. Results showed that the 15-layer freeze model achieved a higher accuracy of 91.86% compared to the 30-layer freeze model at 90.88%. However, the 30-layer freeze model demonstrated better stability and generalization on the test data,



DOI: 10.52362/jisicom.v9i1.1925

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

particularly in detecting meningioma. These findings indicate that ResNet-50 is effective for MRI-based brain tumor classification, and proper fine-tuning significantly influences model performance.

Keywords: brain tumor, MRI, CNN, ResNet-50, transfer learning, image classification

I. PENDAHULUAN

Otak manusia merupakan organ paling kompleks dan vital dalam tubuh, yang berperan sebagai pusat kendali dari segala fungsi kehidupan. Terdiri dari sekitar 86 miliar *neuron* dan jaringan pendukung, otak bertanggung jawab atas aktivitas biologis seperti pengaturan denyut jantung, pernapasan, dan *homeostasis* tubuh, serta fungsi kognitif seperti berpikir, mengingat, berbicara, dan merasakan emosi [1]. Secara struktural, otak dibagi menjadi tiga bagian utama: otak besar (*cerebrum*), otak kecil (*cerebellum*), dan batang otak (*brainstem*). Otak besar mendominasi volume otak dan berperan dalam fungsi eksekutif seperti pengambilan keputusan dan logika. Otak kecil memainkan peran penting dalam koordinasi dan keseimbangan, sedangkan batang otak menangani fungsi dasar kehidupan seperti detak jantung dan tekanan darah [2].

Keseimbangan fungsi otak sangat rentan terhadap gangguan, salah satunya akibat kehadiran tumor. *Brain tumor* adalah massa jaringan abnormal yang dapat tumbuh di dalam atau di sekitar otak. Tumor ini bisa bersifat *benign* atau *malignant* dan dapat berasal dari jaringan otak itu sendiri maupun dari penyebaran sel kanker dari organ lain. Tumor otak mengganggu fungsi otak dengan menekan jaringan sekitarnya, menyebabkan pembengkakan, dan meningkatkan tekanan *intracranial*. Efeknya bisa menyebabkan kejang, gangguan penglihatan, hilangnya fungsi motorik, dan gangguan perilaku [3].

Jenis tumor otak yang paling umum meliputi *glioma*, *meningioma*, dan *pituitary adenoma*. *Glioma* berasal dari sel *glial* yang mendukung *neuron* dan sering kali bersifat ganas. *Meningioma* tumbuh dari *meninges* atau selaput pelindung otak dan sebagian besar bersifat jinak, tetapi karena pertumbuhannya yang lambat dan tekanannya terhadap jaringan otak, *meningioma* dapat menyebabkan kerusakan neurologis. Tumor *pituitary* muncul di kelenjar *pituitary* dan dapat mengganggu sistem hormonal tubuh secara luas [4]. Menurut Das et al.[5], meskipun prevalensi tumor otak tergolong rendah jika dibandingkan dengan jenis kanker lain, tingkat *morbidity* dan *mortality*-nya cukup tinggi karena lokasi dan kompleksitas struktur otak yang terdampak.

Deteksi dini terhadap tumor otak menjadi kunci utama untuk meningkatkan peluang pengobatan yang berhasil. Salah satu metode yang paling umum digunakan dalam deteksi tumor otak adalah pencitraan medis menggunakan teknologi *Magnetic Resonance Imaging (MRI)*[6]. *MRI* bekerja dengan menggunakan medan magnet dan gelombang radio untuk menghasilkan gambar detail dari struktur otak tanpa prosedur invasif. Teknologi ini sangat penting dalam mengidentifikasi ukuran, lokasi, dan jenis tumor [7]. Namun, interpretasi citra *MRI* secara manual oleh *radiologist* membutuhkan ketelitian tinggi, waktu yang tidak singkat, dan rentan terhadap subjektivitas.

Pendekatan berbasis teknologi *artificial intelligence (AI)* menawarkan solusi yang potensial. Salah satu cabang *AI* yang saat ini sangat berkembang adalah *deep learning*, khususnya melalui model *Convolutional Neural Network (CNN)*. *CNN* telah terbukti sangat efektif dalam mengenali pola-pola visual dan melakukan klasifikasi objek pada citra, termasuk dalam citra medis seperti *MRI* otak [8]. *CNN* mampu melakukan *feature extraction* dari gambar secara otomatis, mulai dari fitur sederhana seperti garis dan tepi hingga fitur kompleks seperti bentuk organ dan lesi.

Salah satu arsitektur *CNN* yang telah menunjukkan performa tinggi dalam berbagai tugas klasifikasi gambar adalah *Residual Network* atau *ResNet*. *ResNet* mengatasi permasalahan *vanishing gradient* dalam pelatihan jaringan dalam melalui penggunaan *skip connections* atau *residual blocks*, yang memungkinkan informasi melewati beberapa lapisan tanpa kehilangan kejelasan [9]. Varian *ResNet* terdiri dari beberapa konfigurasi, di antaranya *ResNet-18*, *ResNet-34*, *ResNet-50*, dan *ResNet-101*, yang masing-masing memiliki jumlah lapisan berbeda. *ResNet-50* menjadi pilihan populer dalam klasifikasi citra medis karena menawarkan keseimbangan antara kedalaman jaringan dan efisiensi komputasi [10].



ResNet-50 telah diterapkan dalam berbagai penelitian klasifikasi medis dengan hasil yang menjanjikan. Ali et al.[11] menunjukkan bahwa model *pretrained* seperti *EfficientNet* dan *ResNet* memberikan akurasi tinggi dalam klasifikasi kanker kulit berdasarkan citra *dermatoscopy*. Dalam konteks tumor otak, pendekatan yang sama telah diterapkan oleh Ardan & Indraswari[12] yang mengembangkan sistem segmentasi dan klasifikasi tingkat kegunaan tumor otak menggunakan jaringan 3D berbasis *deep learning*.

Pelatihan *CNN* dari awal (*training from scratch*) membutuhkan sumber daya komputasi besar dan waktu yang lama. Oleh karena itu, pendekatan *transfer learning* digunakan secara luas. *Transfer learning* memungkinkan penggunaan model yang telah dilatih sebelumnya pada dataset besar seperti *ImageNet*, untuk kemudian diadaptasi pada domain spesifik seperti klasifikasi tumor otak. Hal ini menghemat waktu pelatihan dan meningkatkan akurasi karena model sudah memiliki kemampuan dasar dalam mengenali struktur visual umum [13].

Beberapa penelitian mencatat bahwa klasifikasi tumor otak tidak selalu seimbang antar kelas. Tumor *meningioma*, misalnya, sering kali sulit dibedakan dari *glioma* karena bentuk dan teksturnya yang serupa. Selain itu, distribusi data dalam dataset *MRI* juga tidak merata, sehingga menyebabkan model cenderung bias terhadap kelas mayoritas [14]. Untuk itu, berbagai strategi telah dikembangkan, termasuk *data augmentation*, *data balancing*, dan *fine-tuning* lapisan tertentu dari model *pretrained* agar lebih sesuai dengan karakteristik citra medis.

Dengan mempertimbangkan kompleksitas dan tantangan tersebut, penelitian ini dirancang untuk mengimplementasikan dan mengevaluasi model klasifikasi tumor otak berbasis *CNN* dengan arsitektur *ResNet-50* melalui pendekatan *transfer learning*. Tujuan utama penelitian ini adalah untuk menguji seberapa efektif model ini dalam mengklasifikasikan tiga jenis tumor otak — *glioma*, *meningioma*, dan *pituitary* — berdasarkan citra *MRI* otak.

Dataset yang digunakan dalam penelitian ini terdiri dari ribuan citra *MRI* yang telah diberi label, dengan resolusi *512x512 pixels*. Proses pelatihan dan pengujian dilakukan dalam lingkungan *Jupyter Notebook* menggunakan *deep learning libraries* seperti *TensorFlow* dan *Keras*. Evaluasi dilakukan dengan mengukur metrik-metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score*, serta menggambarkan *ROC Curve* dan *Area Under Curve (AUC)* untuk mengukur performa klasifikasi.

Secara teoritis, penelitian ini diharapkan dapat memperkaya literatur akademik terkait pemanfaatan *CNN* dan *transfer learning* dalam klasifikasi citra medis, khususnya *MRI* otak. Secara praktis, hasil penelitian ini diharapkan dapat menjadi dasar bagi pengembangan sistem diagnosis berbasis *AI* yang lebih akurat, efisien, dan dapat diandalkan oleh tenaga medis dalam mendeteksi tumor otak secara lebih cepat dan objektif.

II. METODE DAN MATERI

2.1 Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen yang bertujuan untuk menguji efektivitas arsitektur Convolutional Neural Network (*CNN*) berbasis *ResNet-50* dalam klasifikasi citra tumor otak. Model dikembangkan menggunakan pendekatan *transfer learning* dengan memanfaatkan bobot awal dari pelatihan pada dataset *ImageNet*, sebagaimana disarankan oleh Sujatmiko et al.[15]. Fokus dari penelitian ini adalah klasifikasi tiga jenis tumor otak, yaitu *glioma*, *meningioma*, dan *pituitary*, secara otomatis dan akurat melalui evaluasi performa model pada data uji yang belum pernah dikenali sebelumnya.

2.2 Dataset

Dataset yang digunakan dalam penelitian ini merupakan data sekunder dari artikel ilmiah terkait yang telah dipublikasikan dalam studi oleh Cheng et al.[16]. *Dataset* tersebut terdiri dari 3064 citra *MRI* jenis T1-weighted contrast-enhanced dari 233 pasien yang berasal dari dua rumah sakit di China, yakni Nanfang Hospital dan General Hospital Tianjin Medical University. Resolusi tiap citra adalah *512x512* piksel dengan ukuran piksel *0,49x0,49 mm²* dan ketebalan irisan *6 mm*. Citra-citra tersebut telah melalui proses pelabelan manual oleh tiga orang radiolog berpengalaman dan terbagi ke dalam tiga kelas, yaitu *glioma* (1426 citra), *meningioma* (708 citra), dan *pituitary* (930 citra).




Tabel 1 Detail Kelas Citra

Kelas	Jumlah Data
Glioma	1426
Meningioma	708
Pituitary	930
Jumlah Keseluruhan	3064

Sebelum digunakan dalam pelatihan model, citra mengalami tahapan pre-processing. Ukuran citra diseragamkan menjadi 224x224 piksel untuk efisiensi komputasi. Selanjutnya, augmentasi citra dilakukan untuk meningkatkan keberagaman data dan menghindari overfitting, melalui teknik rescale, rotasi hingga 30 derajat, cropping, serta flipping horizontal dan vertikal. Teknik augmentasi tersebut sejalan dengan pendekatan yang digunakan oleh Nafisa et al.[17]. Setelah itu, dataset dibagi menjadi data pelatihan dan data pengujian dengan rasio 80:20.

2.3 Arsitektur Model

Model yang digunakan dalam penelitian ini adalah ResNet-50, sebuah arsitektur deep learning berbasis CNN yang memiliki keunggulan dalam menangani masalah vanishing gradient melalui penggunaan blok residual dan skip connection [18]. Model ResNet-50 terdiri dari beberapa blok konvolusi dalam struktur residual, yang memungkinkan penjumlahan output dari blok dengan input aslinya [19]. Lapisan akhir dari model dimodifikasi agar sesuai dengan klasifikasi tiga kelas tumor otak menggunakan fungsi aktivasi softmax. Visualisasi alur metodologi ditampilkan pada Gambar 1.


Gambar 1 Metodologi Penelitian

Penelitian ini menggunakan dua skenario fine-tuning untuk mengevaluasi pengaruh jumlah layer yang dibekukan terhadap performa klasifikasi. Skenario pertama membekukan 30 layer awal ResNet-50, sedangkan skenario kedua membekukan 15 layer awal. Pendekatan transfer learning ini juga diterapkan pada penelitian serupa oleh Wardhani & Nafiiyah[20].

2.4 Tools dan Implementasi

Proses implementasi model dilakukan menggunakan bahasa pemrograman Python versi 3.10 dan platform Jupyter Notebook. Library yang digunakan antara lain TensorFlow dan Keras untuk membangun serta

melatih model, NumPy untuk manipulasi data, serta Matplotlib untuk visualisasi. Model dikompilasi dengan fungsi loss categorical_crossentropy yang sesuai untuk klasifikasi multi-kelas, dan Adam digunakan sebagai optimizer karena kemampuannya dalam mempercepat proses konvergensi. Akurasi digunakan sebagai metrik utama evaluasi performa, sebagaimana umum digunakan dalam penelitian klasifikasi tumor otak [21].


2.5 Evaluasi Model

Evaluasi performa model dilakukan untuk mengetahui seberapa baik model dalam mengklasifikasikan jenis tumor otak. Pengukuran dilakukan menggunakan beberapa metrik: akurasi untuk menunjukkan proporsi prediksi yang benar terhadap total prediksi, precision untuk mengukur ketepatan prediksi kelas positif, recall untuk menilai sensitivitas model dalam menemukan seluruh sampel dari suatu kelas, dan F1-Score sebagai harmonisasi antara precision dan recall. Selain itu, confusion matrix digunakan untuk menunjukkan sebaran klasifikasi benar dan salah untuk tiap kelas. Evaluasi juga mencakup penggambaran kurva ROC dan penghitungan nilai AUC untuk menilai performa model secara keseluruhan dalam membedakan kelas, sebagaimana dijelaskan oleh Grandini et al.[22]. Hasil dari evaluasi ini digunakan untuk membandingkan performa antara dua skenario fine-tuning yang telah dilakukan.


III. PEMBAHASAN DAN HASIL

3.1 Hasil Klasifikasi dan Evaluasi Model

Proses klasifikasi diawali dengan tahapan pre-processing data yang terdiri atas resizing, normalisasi, dan augmentasi citra. Seluruh citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan arsitektur input dari ResNet-50, dan dinormalisasi dengan membagi nilai piksel dengan 255 sehingga berada dalam rentang [0,1]. Augmentasi dilakukan secara acak per batch dengan menerapkan rotasi (-20° hingga +20°), flipping horizontal dan vertikal, zoom (80%-120%), serta brightness adjustment untuk memperkaya keberagaman data dan mengurangi risiko overfitting, khususnya pada kelas yang jumlahnya tidak seimbang seperti meningioma.



Gambar 2 Hasil Resizing Citra



Gambar 3 Hasil Augmentasi Citra

Dataset dibagi menjadi data pelatihan sebesar 80% dan data pengujian sebesar 20% dengan teknik random shuffle untuk memastikan distribusi kelas yang seimbang. Rincian jumlah data pelatihan dan pengujian ditampilkan pada Tabel 2.


Tabel 2 Jumlah Splitting Data

Kelas	Training	Testing	Total
Glioma	1140	286	1426
Meningioma	566	142	708
Pituitary	744	186	930
Total	2450	614	3064


3.2 Analisis Performa Model

Model ResNet-50 yang digunakan merupakan arsitektur CNN yang telah dipra-latih pada dataset ImageNet dan diadaptasi menggunakan pendekatan transfer learning. Penelitian ini mengimplementasikan dua skenario fine-tuning, yaitu: (1) freeze 30 layer pertama, dan (2) freeze 15 layer pertama. Kedua pendekatan bertujuan mengevaluasi pengaruh jumlah layer yang dibekukan terhadap performa klasifikasi [23].

Pada skenario pertama (freeze 30 layer), hanya beberapa layer akhir dari model yang dilatih ulang. Sedangkan pada skenario kedua (freeze 15 layer), lebih banyak layer yang dioptimalkan ulang, sehingga memberikan model fleksibilitas yang lebih besar dalam menyesuaikan bobot terhadap fitur spesifik citra MRI tumor otak.



Gambar 4 Training dan Loss Freeze 30 Layer




Gambar 5 Training dan Loss Freeze 15 Layer


Pada skenario freeze 30 layer, model memperoleh akurasi pelatihan sebesar 95,50% dan akurasi validasi 90,18%. Nilai loss validasi sebesar 0,2543 menunjukkan bahwa model memiliki kemampuan generalisasi yang baik. Skenario freeze 15 layer menghasilkan akurasi pelatihan sebesar 95,64% dan akurasi validasi 88,55% dengan nilai loss sebesar 0,3204. Meskipun akurasi pelatihan lebih tinggi, fluktuasi pada loss validasi menandakan potensi overfitting.

3.3 Evaluasi Testing dan Metrik Klasifikasi

Evaluasi terhadap data testing menunjukkan bahwa pada skenario freeze 30 layer, model menghasilkan precision sebesar 88% untuk glioma, 98% untuk meningioma, dan 92% untuk pituitary. Recall tertinggi dicapai oleh kelas glioma sebesar 99%, menandakan tingkat deteksi yang sangat tinggi. Namun, recall meningioma hanya mencapai 73%, mengindikasikan tantangan dalam membedakan meningioma dari kelas lain.




Gambar 6 Confusion Matrix Freeze 30




Gambar 7 ROC Freeze 30

Pada skenario freeze 15 layer, nilai precision meningkat sedikit menjadi 89% untuk glioma, 99% untuk meningioma, dan 93% untuk pituitary. Namun recall meningioma justru menurun menjadi 68%, yang mempengaruhi F1-score keseluruhan [24]. Hal ini menunjukkan bahwa pelatihan terlalu banyak layer justru dapat memicu overfitting jika tidak diimbangi jumlah data yang cukup.



Gambar 8 Confusion Matrix Freeze 15

Matriks ini memperlihatkan kemampuan model dalam mengklasifikasikan citra MRI otak ke dalam tiga kategori tumor, yakni glioma, meningioma, dan pituitary. Terlihat bahwa untuk kelas glioma, model berhasil mengklasifikasikan seluruh 286 data uji dengan benar tanpa kesalahan klasifikasi. Sementara itu, untuk kelas meningioma, dari total 142 citra, sebanyak 96 citra diklasifikasikan dengan benar, namun masih terdapat 32 citra yang salah diklasifikasikan sebagai glioma dan 14 citra sebagai pituitary. Hal ini menunjukkan bahwa karakteristik visual meningioma masih kerap tumpang tindih dengan dua kelas lainnya, terutama glioma, yang secara tekstur memiliki kesamaan dalam pola bayangan dan intensitas citra. Temuan ini sejalan dengan hasil penelitian Marita et al. [25], yang menunjukkan bahwa identifikasi tumor pada citra otak kerap menghadapi tantangan dalam membedakan lesi berdasarkan gradasi warna dan tepi objek, terutama tanpa dukungan teknik segmentasi.



Gambar 9 ROC Freeze 15

Receiver Operating Characteristic (ROC) menunjukkan nilai *Area Under Curve (AUC)* sebesar 0.98, yang mengindikasikan bahwa model memiliki tingkat ketepatan yang sangat tinggi dalam proses klasifikasi. ROC curve yang mendekati sudut kiri atas dari grafik menandakan bahwa model memiliki *true positive rate* yang tinggi dan *false positive rate* yang rendah. Nilai AUC yang hampir sempurna ini menunjukkan bahwa meskipun masih terdapat tantangan dalam mengenali meningioma, secara umum model telah memiliki *discriminative power* yang sangat baik. Hasil ini menguatkan argumen dari Puspitasari et al. [26], yang

menyebutkan bahwa AUC tinggi merupakan indikator kuat dari stabilitas performa model deep learning dalam klasifikasi berbasis citra medis, terutama ketika bekerja pada data DICOM atau MRI yang kompleks.

Tabel 3 Matriks Evaluasi Freeze 30

	precision	recall	f1-score
Glioma	88%	99%	93%
Meningioma	98%	73%	83%
Pituitary	92%	93%	92%
Accuracy		95.50%	

Matriks yang dicantumkan meliputi precision, recall, dan f1-score untuk masing-masing kelas tumor. Nilai precision sebesar 88% untuk glioma menunjukkan bahwa model cukup tepat dalam memprediksi kelas tersebut. Namun, recall yang tinggi sebesar 99% mengindikasikan bahwa hampir semua data glioma berhasil dikenali oleh model. Untuk kelas meningioma, precision sangat tinggi yakni 98%, tetapi recall hanya 73%, mencerminkan bahwa meskipun model jarang salah dalam prediksi meningioma, banyak data meningioma yang gagal terdeteksi. Ketidakseimbangan ini menghasilkan f1-score sebesar 83%, mengindikasikan tantangan dalam mengenali meningioma secara akurat. Adapun kelas pituitary menunjukkan metrik yang seimbang dengan precision 92%, recall 93%, dan f1-score 92%.

Tabel 4 Matriks Evaluasi Freeze 15

	precision	recall	f1-score
Glioma	89%	100%	94%
Meningioma	99%	68%	80%
Pituitary	93%	98%	95%
Accuracy		95.64%	

Pada skenario pembekuan 15 layer pertama, model menunjukkan performa yang cukup baik dengan akurasi keseluruhan sebesar 95.64%. Hasil evaluasi per kelas menunjukkan bahwa kelas glioma memiliki precision sebesar 89% dan recall 100%, yang berarti model sangat mampu mengenali seluruh data glioma, meskipun masih terdapat sedikit kesalahan klasifikasi terhadap kelas lain. Pada kelas meningioma, precision sangat tinggi yaitu 99%, namun recall menurun menjadi 68%, yang mengindikasikan bahwa model hanya berhasil mengenali sebagian data meningioma. Hal ini menyebabkan f1-score meningioma turun menjadi 80%, dan menunjukkan bahwa model cenderung kesulitan dalam mendeteksi meningioma secara konsisten, meskipun akurasinya tampak tinggi. Sementara itu, kelas pituitary menunjukkan metrik yang sangat baik dan seimbang, dengan precision 93%, recall 98%, dan f1-score 95%.

Secara umum, model dalam skenario freeze 15 layer mencapai akurasi pelatihan tertinggi sebesar 95,64%, namun mengalami kendala pada recall kelas meningioma yang hanya mencapai 68%, menunjukkan bahwa sebagian data meningioma tidak berhasil dikenali dengan baik. Sementara itu, skenario freeze 30 layer meskipun memiliki akurasi pelatihan sedikit lebih rendah (95,50%), menunjukkan hasil yang lebih seimbang dan stabil, terutama dalam hal generalisasi terhadap data validasi. Performa ini juga didukung oleh penggunaan arsitektur CNN pretrained, yang secara teori mampu menangkap fitur visual dalam skala mikro dari struktur citra MRI. Menurut Mutiara dan Azizah [27], penggunaan metode pretrained seperti CNN atau HOG-SVM dalam klasifikasi tumor sangat membantu dalam mengenali fitur visual yang kompleks dari citra medis, sehingga dapat meningkatkan performa model dalam deteksi dini tumor otak secara otomatis dan efisien.

3.4 Visualisasi Hasil



DOI: 10.52362/jisicom.v9i1.1925

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

Visualisasi grafik akurasi dan loss dari proses pelatihan memperlihatkan tren konvergensi yang stabil. Confusion matrix menunjukkan distribusi prediksi model pada masing-masing kelas, dengan klasifikasi yang sangat akurat untuk glioma dan pituitary. ROC Curve dari kedua skenario menunjukkan AUC sebesar 0.98 yang mengindikasikan performa klasifikasi yang sangat baik dalam membedakan antar kelas tumor. Hasil ini juga diperkuat oleh penelitian Deshpande et al.[28] yang menyatakan bahwa nilai AUC di atas 0.9 menandakan model memiliki kemampuan klasifikasi yang sangat tinggi untuk data medis kompleks.

3.5 Tantangan dan Solusi Teknis

Salah satu tantangan utama dalam proses pelatihan adalah fluktuasi pada nilai loss validasi yang mengindikasikan potensi overfitting. Hal ini terjadi terutama pada skenario freeze 15 layer. Untuk mengatasi permasalahan tersebut, digunakan teknik callback ReduceLROnPlateau, yang secara otomatis menurunkan learning rate ketika performa validasi stagnan.

Di samping itu, ketidakseimbangan jumlah sampel per kelas menyebabkan model cenderung bias terhadap kelas mayoritas (glioma). Untuk itu, dilakukan augmentasi data secara agresif terhadap kelas minoritas, serta disarankan penggunaan pendekatan tambahan seperti class weighting atau oversampling di masa mendatang. Hal ini sejalan dengan saran dari Armansyah[29], yang menyatakan bahwa keberhasilan klasifikasi citra medis sangat bergantung pada representasi data yang merata dan pengaturan parameter pelatihan yang adaptif.

Secara keseluruhan, pendekatan fine-tuning dengan freeze 30 layer memberikan hasil yang lebih stabil dan seimbang, sedangkan freeze 15 layer berpotensi lebih akurat jika data lebih besar tersedia. Penelitian ini memberikan kontribusi penting dalam mengevaluasi strategi transfer learning pada klasifikasi citra MRI tumor otak dan memberikan dasar untuk eksplorasi metode segmentasi tambahan di masa depan.

Temuan ini selaras dengan penelitian sebelumnya oleh Miranda et al.[30] yang mengimplementasikan ResNet-50 dalam klasifikasi berbasis citra, serta Fakhri et al.[31] yang menunjukkan bahwa pengaruh jumlah layer yang dilatih ulang dapat berdampak signifikan terhadap performa akhir model klasifikasi tumor otak.

IV. KESIMPULAN

Penelitian ini dilaksanakan untuk mengevaluasi performa model deep learning ResNet50 dalam mengklasifikasikan citra MRI otak yang mengandung tumor. Tujuan utama dari penelitian ini adalah agar model mampu membedakan tiga tipe tumor otak, yaitu glioma, meningioma, dan pituitary. Untuk mencapai tujuan tersebut, digunakan dua pendekatan pelatihan berbeda, yakni dengan membekukan 30 layer awal dan 15 layer awal dari arsitektur model. Istilah “pembekuan” dalam hal ini berarti beberapa bagian dari jaringan tidak dilatih ulang, agar pengetahuan dasar dari pelatihan sebelumnya tetap dipertahankan.

Kedua skenario menunjukkan performa yang baik. Model dengan pembekuan 15 layer mencatat akurasi pelatihan tertinggi sebesar 95,64% dan menghasilkan precision serta f1-score yang tinggi pada kelas glioma dan pituitary. Namun, recall kelas meningioma masih rendah, yaitu hanya 68%, yang menunjukkan tantangan dalam mendeteksi kelas tersebut secara konsisten. Di sisi lain, model dengan pembekuan 30 layer menunjukkan performa yang lebih stabil dan seimbang, serta akurasi validasi yang lebih tinggi. Hal ini menunjukkan bahwa stabilitas model juga sangat dipengaruhi oleh jumlah layer yang dibekukan. Secara keseluruhan, penerapan transfer learning dengan ResNet50 terbukti efektif dan berpotensi besar untuk diterapkan dalam sistem diagnosis berbasis AI di bidang medis.

REFERENSI

- [1] N. Martin and D. Udjulawa, “Klasifikasi Kanker Kulit Pada Citra Dermatoskopi Menggunakan CNN,” *Jurnal Algoritme*, vol. 5, no. 1, pp. 35–46, 2024, doi: 10.35957/algoritme.xxxx.
- [2] T. Nabila and A. Salam, “Classification of Brain Tumors by Using a Hybrid CNN-SVM Model,” *Journal of Applied Informatics and Computing*, vol. 8, pp. 241–247, Aug. 2024, doi: 10.30871/jaic.v8i2.8277.
- [3] P. Theivendren, M. Pichaiavel, M. Gopal, and G. Anbumani, “An Overview of Brain Tumor,” in *Brain Tumors*, A. Agrawal, Ed., Rijeka: IntechOpen, 2022. doi: 10.5772/intechopen.100806.



DOI: 10.52362/jisicom.v9i1.1925

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).



- [4] V. Essianda, A. D. Indrasari, P. Widyastuti, T. Syahla, and R. Rohadi, "Brain Tumor : Molecular Biology, Pathophysiology, and Clinical Symptoms," *Jurnal Biologi Tropis*, vol. 23, no. 4, pp. 260–269, Sep. 2023, doi: 10.29303/jbt.v23i4.5585.
- [5] O. R. R. Aranya, S. Das, O. Aranya, and N. Labiba, *Brain Tumor Classification Using Convolutional Neural Network*. 2019. doi: 10.1109/ICASERT.2019.8934603.
- [6] A. S. Febrianti, T. A. Sardjono, and A. F. Babgei, "Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine," *Jurnal Teknik ITS*, vol. 9, no. 1, 2020, doi: 10.12962/j23373539.v9i1.51587.
- [7] A. W. Jatmiko, "Efek Pemakaian Kontras untuk Optimalisasi Citra pada Pemeriksaan Diagnostik Magnetic Resonance Imaging (MRI)," *Jurnal Biosains Pascasarjana*, vol. 23, no. 1, pp. 28–39, 2021, doi: 10.20473/jbp.v23i1.2021.28-39.
- [8] V. Benvenuto Gianzuriell *et al.*, "ANALISIS GAMBAR MRI OTAK UNTUK MENDETEKSI TUMOR OTAK MENGGUNAKAN ALGORITMA CNN," *Journal of Informatics and Advanced Computing (JIAC)*, vol. 4, no. 2, 2023.
- [9] D. Martomanggolo, "Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih," *Ultimatics : Jurnal Teknik Informatika*, vol. 13, no. 1, p. 51, 2021.
- [10] J. Alberto and D. Hermanto, "Klasifikasi Jenis Burung Menggunakan Metode CNN Dan Arsitektur ResNet-50," *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, vol. 10, pp. 34–46, Sep. 2023.
- [11] K. Ali, Z. A. Shaikh, A. A. Khan, and A. A. Laghari, "Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer," *Neuroscience Informatics*, vol. 2, no. 4, p. 100034, 2022, doi: <https://doi.org/10.1016/j.neuri.2021.100034>.
- [12] I. S. Ardan and R. Indraswari, "Sistem Berbasis Deep Learning untuk Segmentasi dan Klasifikasi Tingkat Keganasan Tumor Otak Menggunakan Citra MRI 3D," *ILKOMNIKA: Journal of Computer Science and Applied Informatics*, vol. 6, no. 2, pp. 1–10, Aug. 2024, doi: 10.28926/ilkomnika.v6i2.643.
- [13] M. I. Wahid, A. Lawi, D. A. Muh, and A. Siddik, "Perbandingan Kinerja Model Ensembled Transfer Learning Pada Klasifikasi Penyakit Daun Tomat," *Prosiding Seminar Nasional Teknik Elektro dan Informatika (SNTEI) 2022*, 2022.
- [14] P. Laksono, H. Harliana, and T. Prabowo, "Deteksi Tumor Otak Melalui Penerapan GLCM dan Naïve Bayes Classification," *Jurnal Ilmiah Intech : Information Technology Journal of UMUS*, vol. 5, no. 1, pp. 41–48, May 2023, doi: 10.46772/intech.v5i1.1286.
- [15] B. Sujatmiko, E. Yudaningtyas, and P. Raharjo, "CONVOLUTION NEURAL NETWORK DENGAN DESAIN JARINGAN RESNET SEBAGAI METODE KLASIFIKASI TUMOR KULIT," *Jurnal Simantec*, vol. 11, pp. 53–64, Dec. 2022, doi: 10.21107/simantec.v11i1.14083.
- [16] J. Cheng *et al.*, "Enhanced performance of brain tumor classification via tumor region augmentation and partition," *PLoS One*, vol. 10, no. 10, p. e0140381, 2015.
- [17] A. Nada Nafisa, E. Nia Devina Br Purba, F. Aulia Alfarisi Harahap, N. Adawiyah Putri, I. Komputer, and F. Matematika dan Ilmu Pengetahuan Alam, "Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma," *Jurnal Teknologi Informasi, Komputer dan Aplikasinya (JTika)*, vol. 5, no. 1, pp. 53–61, 2021, [Online]. Available: <http://jtika.if.unram.ac.id/index.php/JTika/>
- [18] A. Ridhovan and A. Suharso, "PENERAPAN METODE RESIDUAL NETWORK (RESNET) DALAM KLASIFIKASI PENYAKIT PADA DAUN GANDUM," *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 1, pp. 58–65, 2022.
- [19] D. Iskandar Mulyana, M. Ainur Rofik, and M. Ohan Zoharuddin Zakaria, "Klasifikasi Kendaraan pada Jalan Raya menggunakan Algoritma Convolutional Neural Network (CNN)," *Jurnal Pendidikan Tambusai*, vol. 6, no. 1, pp. 1668–1679, 2022.
- [20] R. Wardhani and N. Nafi'iyah, "Identifikasi Tumor Otak Citra MRI dengan Convolutional Neural Network," *Jurnal Informatika Jurnal Pengembangan IT*, vol. 8, pp. 213–219, Sep. 2023.
- [21] K. Amalia, R. Magdalena, and S. Saidah, "Klasifikasi Penyakit Tumor Otak Pada Citra Mri Menggunakan Metode CNN," 2022. [Online]. Available: www.kaggle.com





- [22] M. Grandini, E. Bagli, and G. Visani, *Metrics for Multi-Class Classification: an Overview*. 2020. doi: 10.48550/arXiv.2008.05756.
- [23] A. Raup, W. Ridwan, Y. Khoeriyah, S. Supiana, and Q. Zaqiah, "Deep Learning dan Penerapannya dalam Pembelajaran," *JIIP - Jurnal Ilmiah Ilmu Pendidikan*, vol. 5, pp. 3258–3267, Sep. 2022, doi: 10.54371/jiip.v5i9.805.
- [24] M. Ramadhan, T. Ananta, A. Zakkyfriza, I. H, and Y. Fauzan, "Perbandingan Jumlah Layer Pada Convolutional Neural Network Untuk Meningkatkan Akurasi Dalam Klasifikasi Gambar," *Merkurius : Jurnal Riset Sistem Informasi dan Teknik Informatika*, vol. 2, pp. 211–217, Jul. 2024, doi: 10.61132/merkurius.v2i5.301.
- [25] V. Marita and I. Sanubary, "Identifikasi Tumor Otak Menggunakan Jaringan Syaraf Tiruan Propagasi Balik pada Citra CT-Scan Otak," vol. V, no. 3, pp. 117–121, 2014.
- [26] N. Puspitasari, K. Nugroho, and K. Hadiono, "Usability of Brain Tumor Detection Using the DNN (Deep Neural Network) Method Based on Medical Image on DICOM," *CESS (Journal of Computer Engineering, System and Science)*, vol. 8, p. 619, Jul. 2023, doi: 10.24114/cess.v8i2.48727.
- [27] T. Adilah and Q. N. Azizah, "Klasifikasi Tumor Otak Menggunakan Ekstraksi Fitur HOG dan Support Vector Machine," 2022. [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/infortech45>
- [28] A. Deshpande, V. Estrela, and P. Patavardhan, "The DCT-CNN-ResNet50 architecture to classify brain tumors with super-resolution, convolutional neural network, and the ResNet50," *Neuroscience Informatics*, vol. 1, p. 100013, Oct. 2021, doi: 10.1016/j.neuri.2021.100013.
- [29] M. A. Armansyah, "Aplikasi Pengolahan Citra Mri Untuk Deteksi Area Kanker Otak Dengan Menggunakan Metode Robinson," 2022.
- [30] N. D. Miranda, L. Novamizanti, and S. Rizal, "CONVOLUTIONAL NEURAL NETWORK PADA KLASIFIKASI SIDIK JARI MENGGUNAKAN RESNET-50," *Jurnal Teknik Informatika (Jutif)*, vol. 1, no. 2, pp. 61–68, Dec. 2020, doi: 10.20884/1.jutif.2020.1.2.18.
- [31] H. Fakhri, S. Setiawardhana, I. Syarif, and R. Sigit, "Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network," *INOVTEK Polbeng - Seri Informatika*, vol. 9, Jun. 2024, doi: 10.35314/isi.v9i1.3908.

