

ANALISIS SENSITIVITAS SPASIAL PADA KLASIFIKASI TUMOR OTAK MULTI-KELAS MENGGUNAKAN FINE-TUNING MOBILENETV2 BERBASIS CITRA MRI

Robi Firmansyah¹, Bambang Irawan², Ahmad Faqih³, Raditya Danar Dana⁴.

Program Studi Teknik Informatika¹²³
Program Studi Manajemen Informatika⁴

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
robifirmansyah096@gmail.com

(*) Corresponding Author : robifirmansyah096@gmail.com
Published : 20 Juli 2026

Abstract—Advances in digital image processing technology have made significant contributions in the medical field, particularly in the field of disease detection based on Magnetic Resonance Imaging (MRI). One of the main challenges in automatic brain tumor detection is the suboptimal quality of MRI images and the imbalance of data distribution between classes (data imbalance), which can reduce the performance of feature extraction in deep learning models. This study proposes a new classification approach using the MobileNetV2 Transfer Learning architecture with standardized image contrast enhancement using Contrast Limited Adaptive Histogram Equalization (CLAHE). To address the problem of data imbalance efficiently without increasing the physical dataset size, an algorithm-level technique called Cost-Sensitive Learning (Class Weights) is applied. The focus of the experiment in this study is shifted to analyze the effect of data augmentation on model stability by comparing two main scenarios, namely the Baseline model (Without Augmentation) and the Final model (With Spatial Augmentation) involving rotation, width/height shift, and zoom. Testing was conducted on a multi-class MRI image dataset covering four categories: glioma tumor, meningioma tumor, pituitary tumor, and no tumor, with a final evaluation using an independent Test Set of 1,311 images. The results showed that the Baseline model (Without Augmentation) integrating MobileNetV2, CLAHE, and Class Weights successfully achieved peak performance with an overall accuracy of 97% on the Test Set, and produced a very high and balanced F1-score value in each class (No Tumor: 1.00, Pituitary: 0.98, Glioma: 0.95, Meningioma: 0.94). On the other hand, the Augmented model experienced early stopping at the 13th epoch with the highest validation accuracy of only 95.98% at the 8th epoch. This indicates that overly aggressive spatial manipulation has the potential to blur the subtle pathological anatomical boundaries of the tumor (tumor margins), thus triggering early saturation in the validation data. This study concludes that the combination of MobileNetV2 transfer learning, CLAHE standardization, and balanced class weights is the most optimal, stable, and efficient approach for MRI-based brain tumor classification without the need for additional spatial augmentation

Keywords: Brain MRI Images, Brain Tumors, CLAHE, MobileNetV2, Class Weights, Data Augmentation, Image Classification.

Abstrak—Kemajuan teknologi pengolahan citra digital telah memberikan kontribusi signifikan dalam bidang medis, khususnya dalam upaya deteksi penyakit berbasis citra Magnetic Resonance Imaging (MRI). Salah satu tantangan utama dalam deteksi otomatis tumor otak adalah kualitas citra MRI yang kurang optimal serta adanya ketidakseimbangan distribusi data antar-kelas (data imbalance), yang dapat menurunkan kinerja ekstraksi fitur pada model deep learning. Penelitian ini mengusulkan pendekatan klasifikasi baru menggunakan arsitektur Transfer Learning MobileNetV2 dengan standarisasi peningkatan kontras citra menggunakan Contrast Limited Adaptive Histogram Equalization (CLAHE). Guna mengatasi masalah ketidakseimbangan data secara efisien tanpa menambah ukuran dataset fisik, diterapkan teknik algorithm-level berupa Cost-Sensitive Learning (Class Weights). Fokus eksperimen dalam penelitian ini digeser untuk menganalisis pengaruh augmentasi data terhadap stabilitas model dengan membandingkan dua skenario utama, yaitu model Baseline (Tanpa Augmentasi) dan model Final (Dengan Augmentasi Spasial) yang melibatkan rotasi, width/height shift, dan zoom. Pengujian dilakukan pada dataset citra MRI multi-kelas yang mencakup empat kategori: glioma tumor, meningioma tumor,

pituitary tumor, dan no tumor, dengan evaluasi akhir menggunakan Test Set independen sebanyak 1.311 citra. Hasil penelitian menunjukkan bahwa model Baseline (Tanpa Augmentasi) yang mengintegrasikan MobileNetV2, CLAHE, dan Class Weights berhasil mencapai performa puncak dengan akurasi keseluruhan mencapai 97% pada Test Set, serta menghasilkan nilai F1-score yang sangat tinggi dan seimbang di setiap kelas (No Tumor: 1.00, Pituitary: 0.98, Glioma: 0.95, Meningioma: 0.94). Di sisi lain, model Dengan Augmentasi mengalami early stopping dini pada epoch ke-13 dengan akurasi validasi tertinggi hanya sebesar 95,98% pada epoch ke-8. Hal ini mengindikasikan bahwa manipulasi spasial yang terlalu agresif berpotensi mengaburkan batas anatomi patologis tumor yang halus (tumor margins), sehingga memicu saturasi dini pada data validasi. Penelitian ini menyimpulkan bahwa kombinasi Transfer Learning MobileNetV2, standardisasi CLAHE, dan bobot kelas seimbang merupakan pendekatan yang paling optimal, stabil, dan efisien untuk klasifikasi tumor otak berbasis citra MRI tanpa memerlukan augmentasi spasial tambahan.

Kata Kunci: Citra MRI Otak, Tumor Otak, CLAHE, MobileNetV2, Class Weights, Augmentasi Data, Klasifikasi Citra.

INTRODUCTION

Inovasi dalam *machine learning*, *computer vision*, dan *deep learning*, khususnya melalui pendekatan *Transfer Learning*, telah mendorong lahirnya solusi cerdas untuk permasalahan medis yang kompleks, salah satunya adalah deteksi dini penyakit melalui analisis citra medis. Dalam konteks layanan kesehatan modern, teknologi informatika berperan vital dalam membantu diagnosis penyakit berbasis citra, seperti *Magnetic Resonance Imaging (MRI)*, yang memiliki peran krusial dalam deteksi kelainan otak termasuk tumor. Integrasi arsitektur pembelajaran mendalam pra-latih (*pre-trained deep learning architecture*) telah terbukti secara signifikan meningkatkan akurasi dan efisiensi dalam klasifikasi citra medis, yang pada akhirnya mempercepat proses diagnosis dengan tingkat presisi yang lebih tinggi (Naseer Deen et al., 2021).

Meskipun teknologi *deep learning* berbasis *Convolutional Neural Network (CNN)* telah menunjukkan performa menjanjikan, efektivitas model sangat bergantung pada kualitas input citra serta karakteristik distribusi data yang digunakan. Dalam praktiknya, citra *MRI* otak sering kali mengalami permasalahan kualitas seperti kontras yang rendah, distribusi pencahayaan tidak merata, dan batas anatomi patologis tumor yang halus. Kondisi tersebut dapat mengaburkan informasi tekstur yang dibutuhkan oleh lapisan konvolusi, sehingga menyulitkan proses ekstraksi fitur secara optimal oleh model (Afshar et al., 2021). Selain kendala visual, tantangan signifikan lain yang sering dijumpai dalam dataset medis adalah ketidakseimbangan jumlah sampel antar-kelas (*data imbalance*). Kondisi data yang tidak seimbang ini berisiko tinggi memicu bias klasifikasi, di mana model cenderung superior


mengenali kelas mayoritas namun gagal mendeteksi kelas minoritas secara klinis (Saxena et al., 2021). Oleh karena itu, penggabungan teknik pemrosesan awal citra yang tepat dan strategi penanganan ketidakseimbangan data menjadi tahapan krusial yang belum sepenuhnya dioptimalkan secara simultan dalam studi klasifikasi tumor otak.

Sebagai solusi untuk mengatasi kendala tersebut, penelitian ini menerapkan teknik peningkatan citra *Contrast Limited Adaptive Histogram Equalization (CLAHE)* sebagai standardisasi pemrosesan awal untuk mengoptimalkan kontras lokal dan mempertegas struktur tekstur tumor tanpa memperbesar *noise*. Citra yang telah ditingkatkan kualitasnya kemudian diintegrasikan dengan arsitektur *Transfer Learning MobileNetV2* yang dikenal efisien dan tangguh dalam mengenali fitur visual kompleks. Guna mengatasi masalah ketidakseimbangan data pada tingkat algoritma, penelitian ini menerapkan metode *Cost-Sensitive Learning* melalui pengaturan bobot kelas (*Class Weights*). Lebih lanjut, fokus eksperimen dalam penelitian ini diarahkan untuk menganalisis pengaruh penerapan augmentasi data spasial secara kritis, dengan membandingkan performa model *Baseline* (Tanpa Augmentasi) dan model *Final* (Dengan Augmentasi). Melalui pendekatan komprehensif ini, diharapkan dapat ditemukan sebuah *pipeline* klasifikasi tumor otak multi-kelas yang tidak hanya menghasilkan akurasi tinggi, melainkan juga stabil dan efisien dalam mengenali seluruh karakteristik tumor secara adil.

MATERIALS AND METHODS

Penelitian ini merupakan penelitian kuantitatif eksperimental, yang bertujuan untuk menguji efektivitas berbagai teknik peningkatan citra terhadap performa model klasifikasi tumor otak

berbasis *CNN*. Pendekatan kuantitatif eksperimental memungkinkan peneliti untuk mengontrol variabel secara sistematis, melakukan manipulasi terhadap perlakuan (treatment), dan mengamati pengaruhnya terhadap variabel terikat [2]. Dalam konteks ini, teknik peningkatan citra menjadi variabel bebas yang diterapkan pada data *MRI* otak, sedangkan performa model *CNN* menjadi variabel terikat yang diukur melalui sejumlah *metrik* evaluasi. Penelitian eksperimental dinilai sangat tepat digunakan dalam bidang pengolahan citra dan pembelajaran mesin karena memungkinkan uji coba sistematis terhadap metode dan model dengan data aktual (Creswell & Creswell., 2022). Desain penelitian terbagi menjadi 4 (Empat) tahapan, yakni 1) Tahapan Studi Pendahuluan, 2) Tahapan Literature Review, 3) Tahapan Pendekatan Eksperimen, 4) Tahapan Kesimpulan dan Rekomendasi.



Gambar 1. Alur Penelitian

Berdasarkan Gambar 1 yang disajikan, penelitian ini dirancang secara sistematis melalui serangkaian tahapan terintegrasi tanpa pemisahan poin untuk memastikan validitas metodologi dan ketercapaian tujuan eksperimen secara runtut.

Alur logika penelitian diawali dari tahapan studi pendahuluan yang difokuskan pada identifikasi masalah teknis berupa rendahnya kualitas kontras lokal citra *MRI* otak serta tantangan ketidakseimbangan distribusi jumlah data antar-kelas tumor yang berisiko memicu

bias klasifikasi pada model. Berdasarkan urgensi masalah klinis tersebut, peneliti merumuskan pertanyaan penelitian dan menetapkan tujuan secara kuantitatif untuk mengevaluasi efektivitas teknik peningkatan kontras *CLAHE* yang diintegrasikan dengan metode pembobotan kelas (*Class Weights*), sekaligus membandingkan skenario model *Baseline* tanpa augmentasi melawan skenario *Final* dengan augmentasi menggunakan arsitektur *Transfer Learning MobileNetV2*.

Setelah permasalahan dirumuskan, penelitian dilanjutkan ke tahapan tinjauan pustaka untuk membangun landasan konseptual yang kuat melalui penelaahan literatur mutakhir. Peneliti mengkaji studi klasifikasi penyakit berbasis model *MobileNetV2* guna memahami mekanisme konvolusi efisien seperti *Depthwise Separable Convolution* dan pemanfaatan bobot pra-latih ImageNet pada citra medis, serta menganalisis karakteristik matematis metode *CLAHE* dan pendekatan *Cost-Sensitive Learning*. Tinjauan mendalam ini melandasi hipotesis ilmiah bahwa pengondisian sinyal visual melalui *CLAHE* dan penyesuaian bobot *loss* tingkat algoritma jauh lebih stabil dalam mempertahankan fitur asli jaringan tumor dibandingkan dengan manipulasi bentuk spasial secara agresif.

Memasuki tahapan ketiga yaitu pendekatan eksperimen, seluruh rancangan kuantitatif diimplementasikan secara nyata ke dalam kode pemrograman yang diawali dengan pemuatan dataset citra *MRI* multi-kelas yang mencakup kategori *glioma_tumor*, *meningioma_tumor*, *pituitary_tumor*, dan *no_tumor*. Guna menghindari bias pencampuran data (*data leakage*), dilakukan prosedur *3-Way Splitting* untuk memisahkan data menjadi *Training Set*, *Validation Set*, dan *Testing Set* independen sebelum menyentuh komponen generator. Selanjutnya, setiap citra *MRI* masuk ke dalam proses standarisasi pemrosesan awal dengan dikonversi dari *RGB* ke ruang warna *LAB*, di mana proses peningkatan kontras lokal *CLAHE* diaplikasikan secara spesifik hanya pada saluran *L (Lightness)* menggunakan parameter *clip limit 2.0* dan *tile grid size (8,8)* untuk menonjolkan fitur tekstur mikro tumor tanpa memperbesar *noise*, sebelum akhirnya dikembalikan ke ruang warna *RGB*. Setelah citra distandardisasi, pustaka *Scikit-Learn* digunakan untuk menghitung bobot penyeimbang (*Class Weights*) pada data *training* guna memberikan penalti *loss* yang lebih tinggi apabila model salah mengklasifikasikan kelas tumor minoritas.

Proses kemudian diarahkan pada pembagian dua jalur generator data komparatif, yaitu Skenario 1 berupa generator tanpa augmentasi sebagai

baseline dan Skenario 2 berupa generator dengan augmentasi spasial yang melibatkan rotasi 15 derajat, *width/height shift* 0.1, dan *zoom* 0.1. Pelatihan model kemudian mengintegrasikan *backbone MobileNetV2* dengan menerapkan metode penyetelan halus (*fine-tuning*) melalui pembukaan 20 lapisan terakhir agar dapat dilatih kembali menyesuaikan citra *MRI*. Di atas *backbone* tersebut, ditambahkan lapisan kustom berupa *Global Average Pooling 2D*, *Dense Layer* dengan 128 neuron didukung aktivasi *ReLU*, serta lapisan output *Softmax* 4 neuron, di mana seluruh proses pelatihan dikontrol ketat oleh fungsi *callbacks Early Stopping* dan *ReduceLROnPlateau*. Fase pendekatan eksperimen ini ditutup dengan pengujian objektif terhadap kedua model menggunakan *Test Set* independen sebanyak 1.311 citra, lalu mengekstraksi hasil prediksinya ke dalam bentuk *Confusion Matrix* untuk mengukur nilai metrik klasifikasi berupa akurasi keseluruhan, presisi, *recall*, dan *F1-score* secara makro.

Rangkaian desain penelitian ini diakhiri oleh tahapan kesimpulan dan rekomendasi yang melakukan analisis komparatif *head-to-head* terhadap performa akhir kedua skenario model. Peneliti merangkum bukti empiris hasil pengujian yang menunjukkan bahwa model *Baseline* tanpa augmentasi berhasil mencapai performa puncak dengan akurasi tertinggi sebesar 97% serta memiliki distribusi nilai *F1-score* yang sangat seimbang di seluruh kelas tumor. Berdasarkan analisis visual kurva pembelajaran dan pemicuan *Early Stopping* dini pada model beraugmentasi, peneliti menyusun argumentasi ilmiah mengenai batasan toleransi manipulasi spasial pada citra medis *MRI*, yang kemudian ditutup dengan penarikan kesimpulan formal serta pemberian rekomendasi konfigurasi *pipeline* terbaik untuk diimplementasikan pada sistem berbantuan diagnosis otomatis di masa depan.

RESULTS AND DISCUSSION

Setelah seluruh 7.023 data citra *MRI* dipersiapkan melalui tahap pra-pemrosesan dasar *CLAHE* dalam ruang warna *LAB*, penelitian memasuki tahap implementasi inti: pengembangan arsitektur dan pelatihan model. Bagian ini menjabarkan secara rinci proses perancangan model berbasis jaringan saraf tiruan mendalam yang digunakan sebagai instrumen klasifikasi untuk menguji hipotesis penelitian.

Sesuai dengan metodologi yang telah disesuaikan, arsitektur model ini dibangun menggunakan *framework Keras* dan *TensorFlow* dengan memanfaatkan metode *Transfer Learning* berbasis *MobileNetV2*. Struktur ini terdiri dari blok arsitektur dasar (*backbone base model*) yang memuat filter konvolusi pra-latih *ImageNet*, serta blok klasifikasi kustom (*custom classification head*) yang terdiri dari *Global Average Pooling 2D*, lapisan *Dense* 128 neuron dengan aktivasi *ReLU*, regularisasi *Dropout* 0.5, dan lapisan output *Dense* dengan 4 neuron beraktivasi *Softmax* untuk memprediksi empat kelas tumor.

Selanjutnya, sub-bab ini akan memaparkan proses pelatihan model pada dua skenario data (Skenario *Baseline* dan Skenario *Final Augmented*), yang diatur menggunakan parameter optimisasi spesifik, meliputi *Optimizer Adam* dengan laju pembelajaran awal $1e-4$, *Batch Size* 32, batas maksimum 50 *Epochs*, serta kendali dinamis dari fungsi *callbacks Early Stopping* dan *ReduceLROnPlateau*. Hal ini selaras dengan hasil yang dilakukan pada tahap penelitian dan pembuatan model dijabarkan pada Tabel 1

Tabel 1 Parameter Arsitektur MobilNetV2

Blok / Lapisan	Komponen Layer	Spesifikasi Parameter	Fungsi / Keterangan
Input	<i>Input Layer</i>	Shape: 224x224 piksel)	Menerima array matriks tiga saluran warna <i>RGB</i> hasil pemrosesan awal.
Arsitektur Dasar	<i>MobileNetV2 Backbone</i>	<i>Pre-trained ImageNet Weights</i>	Mengekstrak hierarki fitur visual medis; 20 lapisan terdapat dibuka kuncinya (<i>unfrozen</i>) untuk <i>fine-tuning</i> .
Reduksi Spasial	<i>GlobalAverage Pooling2D</i>	-	Mereduksi dimensi spasial peta fitur menjadi vektor 1D tanpa

			merusak informasi esensial.	input_shape=(224, 224, 3), yang selaras dengan data citra tiga saluran warna RGB ukuran 224x224 piksel hasil pra-pemrosesan dasar. Sesuai dengan batasan penelitian yang mutakhir, kondisi weights='imagenet' memastikan model mengekstrak bobot fitur tingkat rendah (<i>low-level features</i>) yang telah matang dari dataset ImageNet skala besar.
Top Layer	<i>Dense Layer</i>	128 Neuron, Aktivasi ReLU	Lapisan terhubung penuh (<i>fully connected</i>) untuk mempelajari pola karakteristik tumor global.	Arsitektur dasar ini dimodifikasi secara kritis menggunakan metode <i>fine-tuning</i> , di mana perintah <i>base_model.trainable = True</i> dikombinasikan dengan pembekuan lapisan konvolusi awal lewat fungsi perulangan <i>for layer in base_model.layers[:-20]: layer.trainable = False</i> . Perintah ini memastikan bahwa hanya 20 lapisan konvolusi terdalam pada <i>MobileNetV2</i> yang dibuka kuncinya agar dapat diperbarui bobot parameternya menyesuaikan visualisasi citra patologi <i>MRI</i> otak. Blok klasifikasi kustom di atasnya kemudian dibangun secara runtut menggunakan lapisan <i>Global Average Pooling 2D</i> , diikuti <i>Dense</i> (128 neuron, <i>ReLU</i>), <i>Dropout</i> (0.5), dan lapisan output <i>Dense</i> (4 neuron, <i>Softmax</i>). Model ini kemudian dikompilasi menggunakan fungsi pengoptimal Adam dengan laju pembelajaran awal 1e-4, fungsi kerugian <i>categorical_crossentropy</i> , serta metrik evaluasi utama berupa <i>accuracy</i> .
Regulasi	<i>Dropout</i>	Rate: 0.5	Menolak bobot berlebih secara acak untuk mencegah fenomena <i>overfitting</i> selama latihan.	
Output	<i>Dense Layer</i>	4 Neuron, Aktivasi <i>Softmax</i>	Memprediksi nilai probabilitas 4 kelas target (<i>glioma_tumor, meningioma_tumor, pituitary_tumor, no_tumor</i>).	Penggunaan fungsi tunggal ini sangat krusial, karena fungsi <i>build_model()</i> dipanggil secara identik untuk membangun jaringan pada Skenario 1 (<i>Baseline</i>) maupun Skenario 2 (<i>Final Augmented</i>). Hal ini menjamin arsitektur model tetap konstan secara absolut, sehingga hasil pengujian murni merefleksikan dampak dari perlakuan manipulasi spasial data generator yang diuji. Setelah model berhasil dibuat, langkah selanjutnya adalah menetapkan parameter persiapan implementasi jalannya proses pelatihan yang dirincikan pada Tabel 2



Gambar 2. pengembangan Arsitektur Model

Implementasi arsitektur model yang digunakan sebagai instrumen klasifikasi utama didefinisikan dalam sebuah fungsi bernama *build_model()*. Fungsi ini dirancang untuk menerima parameter dimensi masukan

Tabel 2 Persiapan Implementasi Arsitektur Model

Parameter	Konfigurasi	Keterangan
Framework	Keras / TensorFlow	Platform utama untuk pengembangan dan kompilasi arsitektur model.

Optimizer	Adam (Learning Rate = 1e-4)	Algoritma optimisasi adaptif untuk pembaruan bobot secara halus dan stabil.
Loss Function	<i>Categorical Crossentropy</i>	Fungsi kerugian untuk mengukur kesalahan prediksi pada kasus multi-kelas.
Metrik Evaluasi	<i>Accuracy</i>	Indikator kuantitatif utama untuk memantau performa latihan global.
Batch Size	32	Ukuran sub-sampel data yang dialirkan ke GPU per iterasi.
Epochs	50	Batas maksimum iterasi siklus pelatihan penuh model.
Mode Pelatihan	<i>Fine-Tuning</i> (Unfreeze Last 20 Layers)	Memanfaatkan <i>Transfer Learning</i> dengan melatih ulang 20 lapisan terdalam model base.



Gambar 3 pengujian terhadap pengembangan arsitektur model

Setelah arsitektur model berbasis *Transfer Learning MobileNetV2* berhasil dibangun dan dikompilasi melalui fungsi `build_model()`, model tersebut berada dalam kondisi siap untuk memasuki fase pelatihan. Guna memastikan proses pelatihan dan pemantauan performa berjalan secara konsisten, objektif, dan adil pada kedua skenario pengujian (Skenario *Baseline* dan Skenario *Final Augmented*), eksekusi data dikontrol secara terpusat menggunakan perintah `model.fit`.

Proses ini menerima parameter input berupa model yang telah dikompilasi, objek data generator untuk draf data latihan dan validasi, serta kamus bobot kelas `class_weight=cw_dict` tingkat algoritma untuk menangani masalah ketidakseimbangan data (*data imbalance*). Di dalam fase ini, jalannya pelatihan diatur secara ketat sesuai metodologi penelitian, di mana batas maksimum iterasi ditetapkan selama 50 *epochs* dengan ukuran *batch* sebesar 32 citra.

Untuk menjaga stabilitas konvergensi dan mencegah terjadinya *over-fitting* pada citra medis, dua fungsi pemantau otomatis (*callbacks*) diintegrasikan secara aktif dalam proses pelatihan ini. Pertama, fungsi `EarlyStopping` dikonfigurasi untuk memonitor nilai kerugian validasi (`monitor='val_loss'`) dengan nilai ambang batas `patience=5`. Fungsi ini akan menghentikan siklus pelatihan secara otomatis jika grafik *validation loss* tidak menunjukkan tren penurunan dalam lima *epochs* berturut-turut, sekaligus mengembalikan parameter bobot model ke kondisi terbaik yang pernah dicapai (`restore_best_weights=True`). Kedua, fungsi `ReduceLROnPlateau` ditambahkan untuk menyesuaikan laju pembelajaran secara dinamis, di mana nilai *learning rate* akan dipotong secara agresif sebesar 80 persen atau disusutkan dengan faktor 0.2 (`factor=0.2`) apabila nilai *validation loss* mengalami stagnasi tanpa perbaikan selama 3 *epochs* berturut-turut (`patience=3`).

Segera setelah proses pelatihan (`model.fit`) selesai dieksekusi, total waktu komputasi akan dicatat dan draf bobot model terbaik disimpan secara otomatis ke dalam direktori kerja. Pustaka `matplotlib` kemudian dipanggil untuk menghasilkan visualisasi kurva pembelajaran (*learning curves*) dalam bentuk plot matriks berukuran 1×2 . Visualisasi grafis ini menampilkan pergerakan kurva akurasi (latihan vs validasi) pada sub-plot pertama, serta kurva *loss* (latihan vs validasi) pada sub-plot kedua di setiap perubahan *epoch*. Penggunaan parameter pengontrol yang terstandarisasi ini menjamin bahwa model pada Skenario *Baseline* maupun Skenario *Final Augmented* dilatih dengan kondisi yang identik, sehingga perbandingan hasil evaluasi akhir murni merefleksikan pengaruh sensitivitas spasial dari kedua skenario data generator tersebut.

CONCLUSION

Berdasarkan analisis hasil penelitian, draf pengujian, dan pembahasan mendalam yang telah dipaparkan secara runtut pada Bab IV, penelitian ini sampai pada beberapa kesimpulan utama yang secara langsung dan valid menjawab ketiga rumusan masalah yang telah diajukan sebelumnya:

Penerapan teknik perluasan dataset melalui manipulasi spasial fisik (augmentasi geometri dinamis) pada objek data generator tidak terbukti menghasilkan kualitas input citra *MRI* otak yang lebih baik untuk deteksi otomatis. Kualitas input paling optimal, yang diukur dari nilai kesalahan fungsional kerugian pengujian (*Test Loss*) terendah sebesar 0.1142, justru dihasilkan secara murni oleh Skenario 1 (Baseline Tanpa Augmentasi) yang memfokuskan prapemrosesan pada standarisasi kontras lokal *CLAHE* dalam ruang warna LAB.

Arsitektur model *Transfer Learning MobileNetV2* yang dikonfigurasi melalui metode *fine-tuning* tidak mencapai nilai akurasi deteksi tumor otak tertinggi saat menggunakan bantuan data generator beraugmentasi spasial. Akurasi klasifikasi global tertinggi yang menyentuh angka 97,00% secara konsisten justru dicapai oleh Skenario 1 (Baseline Tanpa Augmentasi), yang sukses mengungguli performa Skenario 2 (*Final Model* beraugmentasi) yang hanya mencatatkan akurasi sebesar 95,42% pada pengujian objek data independen sebanyak 1.311 citra medis.

Penambahan manipulasi geometri fisik secara dinamis pada tingkat generator tidak terbukti mampu menghasilkan performa klasifikasi yang lebih stabil, andal, dan konsisten jika dibandingkan dengan metode standarisasi kontras murni tanpa augmentasi. Skenario *Baseline* terbukti paling stabil di seluruh lini metrik klasifikasi makro dengan nilai *Macro F1-Score* sebesar 0.97. Sebaliknya, penambahan teknik augmentasi spasial fisik (rotasi 15 derajat, pergeseran *shift* 0.1, dan perbesaran *zoom* 0.1) yang secara teoretis diprediksi mendongkrak ketahanan model, justru memicu instabilitas deteksi lokal yang drastis, ditunjukkan dengan anjloknya nilai presisi kelas *Meningioma Tumor* hingga menjadi 0.87 akibat terjadinya disorientasi ruang spasial piksel (*feature ambiguity*).

REFERENCE

- [1] I. Gundogan *et al.*, "A novel deep learning framework for brain tumor detection using magnetic resonance imaging," *Computers in Biology and Medicine*, vol. 146, no. 4, pp. 352–373, 2021, doi: 10.1016/j.artmed.2025.102795.
- [2] Sugiyono, *Metode Penelitian Kuantitatif, Kualitatif, dan R&D*. Bandung: Alfabeta, 2021.
- [3] J. W. Creswell and J. D. Creswell, *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches*, 6th ed. Thousand Oaks: SAGE Publications, 2022.