

EVALUASI KOMPREHENSIF TEKNIK PREPROCESSING UNTUK KLASIFIKASI MRI TUMOR OTAK DENGAN MOBILENETV3-LARGE

Sayyid Miftah Farid¹, Ade Irma Purnamasari², Denni Pratama³, Mulyawan⁴.

Program Studi Teknik Informatika¹²
Program Studi Komputerisasi Akuntansi³
Program Studi Sistem Informasi⁴

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
sayyid223271@gmail.com

(*) Corresponding Author : sayyid223271@gmail.com
Published : 16 Juli 2026

Abstract—Classification of brain tumors from MRI images using Convolutional Neural Networks (CNN) requires optimal preprocessing to maximize model performance. This study evaluates five different preprocessing techniques (standard resize, Aspect Ratio Preservation with Padding, Center Crop, Adaptive Resize, and Multi-Scale Input) on the MobileNetV3-Large architecture for binary brain tumor classification. The dataset consists of 3,000 MRI images with a balanced distribution showing high resolution heterogeneity (291 unique combinations) and significant aspect ratio variation between classes (tumor 0.872 vs. non-tumor 0.988). Five independent experiments were conducted with identical model configurations using transfer learning and fine-tuning of the top 20 layers. The results show that Multi-Scale Input achieved the highest accuracy of 99.56% but with severe computational overhead (inference time 43.62 ms, model size 23.34 MB). Aspect Ratio Preservation + Padding achieved an accuracy of 98.89% with superior efficiency (inference time 16.60 ms, overhead +6.1%, model size 20.52 MB), a significant improvement of 4.89 points from the Standard Resize Baseline (94.00%). The confusion matrix analysis shows that Aspect Ratio + Padding achieves an optimal balance between sensitivity (99.11%) and specificity with a false positive rate of 1.33% and a false negative rate of 0.89%. This study confirms that Aspect Ratio Preservation is the optimal preprocessing strategy for lightweight CNNs in brain tumor MRI classification, providing the best balance between high diagnostic accuracy and computational efficiency for deployment on resource-constrained devices.

Keywords: Preprocessing, MRI, Brain Tumor, MobileNetV3-Large, Convolutional Neural Network

Abstrak—Klasifikasi tumor otak dari citra MRI menggunakan Convolutional Neural Network (CNN) memerlukan tahap *preprocessing* yang optimal untuk memaksimalkan performa model. Penelitian ini mengevaluasi lima teknik *preprocessing* berbeda (*standard resize*, *Aspect Ratio Preservation* dengan *Padding*, *Center Crop*, *Adaptive Resize*, dan *Multi-Scale Input*) pada arsitektur MobileNetV3-Large untuk klasifikasi biner tumor otak. Dataset terdiri dari 3.000 citra MRI dengan distribusi seimbang yang menunjukkan heterogenitas resolusi tinggi (291 kombinasi unik) dan variasi aspek rasio signifikan antar kelas (tumor 0,872 vs non-tumor 0,988). Lima eksperimen independen dilakukan dengan konfigurasi model identik menggunakan *transfer learning* dan fine-tuning 20 layer terbatas. Hasil menunjukkan *Multi-Scale Input* mencapai akurasi tertinggi 99,56% namun dengan overhead komputasi severe (waktu inferensi 43,62 ms, model size 23,34 MB). *Aspect Ratio Preservation + Padding* mencapai akurasi 98,89% dengan efisiensi superior (waktu inferensi 16,60 ms, overhead +6,1%, model size 20,52 MB), peningkatan signifikan 4,89 poin dari *Baseline Standard Resize* (94,00%). Analisis *confusion matrix* menunjukkan *Aspect Ratio + Padding* mencapai keseimbangan optimal antara sensitivitas (99,11%) dan spesifisitas dengan Nilai *false positive* 1,33% dan Nilai *false negative* 0,89%. Penelitian ini mengonfirmasi bahwa preservasi aspek rasio merupakan strategi *preprocessing* optimal untuk lightweight CNN pada klasifikasi MRI tumor otak, memberikan keseimbangan terbaik antara akurasi diagnostik tinggi dan efisiensi komputasi untuk *deployment* pada perangkat dengan keterbatasan sumber daya.

Kata Kunci: Preprocessing, MRI, Tumor Otak, MobileNetV3-Large, Convolutional Neural Network

INTRODUCTION

Perkembangan pesat *Artificial Intelligence* (AI) dan *deep learning* telah mendorong permintaan model komputasi efisien dalam berbagai domain, dari diagnostik industri hingga sistem evaluasi pendidikan. *Deep learning* sebagai subset *machine learning* yang meniru arsitektur jaringan saraf tiruan menjadi fondasi sistem berbasis AI yang mengelola dataset kompleks dengan akurasi tinggi [1]. Kompleksitas *Deep Neural Networks* (DNNs) menuntut optimalisasi arsitektur untuk meningkatkan performa dalam aplikasi pemrosesan data real-time [2]. Implementasi *parallel ensemble learning* menunjukkan efektivitas metodologi berbasis AI dalam mengotomatisasi proses sambil mengoptimalkan sumber daya [3]. Dalam konteks *ubiquitous computing* dan *Internet-of-Things* (IoT), kebutuhan model efisien meningkat untuk *deployment neural networks* pada platform *embedded* berdaya rendah yang memungkinkan analisis data dengan latensi minimal [4]. Evolusi teknologi *deep learning* menciptakan trajektori menjanjikan seiring meningkatnya tuntutan komputasi berbagai aplikasi, termasuk bidang medis yang membutuhkan klasifikasi citra dengan akurasi tinggi dan efisiensi optimal.

Convolutional Neural Networks ringan semakin dimanfaatkan dalam diagnostik medis, pengenalan visual, dan pemantauan lingkungan karena efisiensinya dalam memproses data dengan sumber daya terbatas. Namun, tantangan *preprocessing* berdampak signifikan terhadap konsistensi dan performa model. *Preprocessing* lanjutan seperti *resizing*, *normalization*, dan *filtering* sangat penting untuk meningkatkan kualitas citra dan memungkinkan CNN fokus pada fitur diskriminatif [5]. Dalam penilaian kardiorespirasi menggunakan sensor wearable, *preprocessing* menjadi vital untuk mengekstraksi fitur relevan yang mempengaruhi performa model [6]. Fase *preprocessing* harus selaras dengan keputusan arsitektural untuk memaksimalkan performa, sehingga ketidakselarasan menyebabkan degradasi performa [7]. Aplikasi multi-input seperti deteksi prekursor gempa bumi memerlukan berbagai langkah *preprocessing* sebelum data dimasukkan ke model CNN [8]. Teknik *filtering noise* yang *robust* dan augmentasi data sangat penting untuk mitigasi variasi antar dataset [9]. Adaptasi teknik *preprocessing* untuk lingkungan dengan keterbatasan energi seperti aplikasi TinyML memerlukan strategi inovatif yang terintegrasi

dengan lingkungan komputasi berdaya rendah [10]. Mengatasi tantangan ini melalui teknik *preprocessing* yang disesuaikan menjadi esensial untuk meningkatkan ketahanan dan akurasi model CNN dalam klasifikasi tumor otak pada citra MRI yang memiliki karakteristik *noise* dan variasi aspect ratio kompleks.

Eksplorasi teknik *preprocessing* untuk meningkatkan performa CNN ringan mengungkapkan kesenjangan signifikan dalam penelitian yang ada. Studi sebelumnya menekankan arsitektur CNN ringan seperti MobileNet dan ShuffleNet serta keunggulannya dalam mengurangi beban komputasi [11], namun mengabaikan analisis sistematis bagaimana metode *preprocessing* spesifik mempengaruhi performa model. Tian et al. (2024) menunjukkan efisiensi MobileNetV3 dalam klasifikasi sampah namun tidak mengeksplorasi bagaimana metode *preprocessing* berbeda mempengaruhi akurasi atau ketahanan. Defisiensi mencolok terlihat dalam penelitian yang membahas tantangan dataset berskala kecil, di mana Olimov et al. (2023) mencatat jaringan ringan mengalami *underfitting*, namun diskusi dampak teknik *preprocessing* dalam mengatasi tantangan ini masih minim. Meskipun penelitian mendemonstrasikan efektivitas *preprocessing* khusus seperti transformasi wavelet untuk deteksi kanker payudara [13], kesenjangan tetap ada mengenai integrasi teknik tersebut ke dalam model ringan untuk aplikasi citra medis lainnya. Limitasi serupa berlaku untuk studi Rahman et al. (2025) tentang data MRI untuk prediksi Alzheimer, di mana *pipeline preprocessing* yang canggih kurang dibahas dalam implementasinya dengan model ringan. Kesenjangan kritis terletak pada investigasi parameter *tuning* dan teknik optimasi *preprocessing* dalam hubungannya dengan pelatihan CNN ringan.

Perbandingan beberapa strategi *preprocessing* menjadi kritis untuk optimasi CNN karena *preprocessing* mempengaruhi performa model, generalisasi, dan efisiensi pelatihan. Penelitian ini bertujuan mengidentifikasi teknik *preprocessing* optimal yang memaksimalkan performa MobileNetV3-Large dalam klasifikasi tumor otak MRI dengan membandingkan lima pendekatan: *standard resize*, *Aspect Ratio Preservation* dengan *Padding*, *Center Crop*, *Adaptive Resize*, dan *Multi-Scale Input*. Zhang et al. (2024) menunjukkan ekstraksi fitur melalui *preprocessing* lanjutan menghasilkan peningkatan performa dalam pelatihan model. Signifikansi penelitian ini terletak pada kontribusinya mengisi kesenjangan pengetahuan tentang bagaimana berbagai teknik *preprocessing* mempengaruhi performa CNN ringan pada data MRI tumor otak yang memiliki karakteristik aspek ratio dan distribusi konten

beragam. Lilhore et al. (2024) mengilustrasikan bahwa *preprocessing* terencana dapat meningkatkan metrik seperti presisi, *Recall*, dan *F1-Score*. Penelitian ini diharapkan memberikan panduan praktis bagi praktisi dan peneliti dalam memilih teknik *preprocessing* yang sesuai untuk aplikasi klasifikasi tumor otak, serta berkontribusi pada pengembangan framework *preprocessing* yang dapat diadaptasi untuk berbagai jenis data pencitraan medis.

Untuk mengevaluasi dampak *preprocessing* terhadap performa CNNs, penelitian ini mengimplementasikan framework eksperimental terstruktur yang mengisolasi dan menilai efek berbagai teknik *preprocessing*. Metrik performa komprehensif yang digunakan mencakup akurasi, presisi, *Recall*, *F1-Score*, dan waktu inferensi untuk memperoleh pandangan holistik tentang performa CNN [17]. Penelitian ini menggunakan arsitektur MobileNetV3-Large sebagai model dasar dengan *fine-tuning* pada 20 layer teratas untuk adaptasi terhadap karakteristik spesifik dataset [18]. Lima teknik *preprocessing* diimplementasikan: *Standard Resize* sebagai *Baseline*, *Aspect Ratio Preservation* dengan *Padding* untuk menjaga integritas spasial, *Center Crop* untuk fokus pada bagian tengah yang ingin diteliti, *Adaptive Resize* sebagai pendekatan novel berbasis konten citra, dan *Multi-Scale Input* untuk ekstraksi fitur piramida pada berbagai resolusi. Desain eksperimental mencakup pembagian dataset menjadi 70% pelatihan, 15% validasi, dan 15% *testing* dengan stratifikasi untuk memastikan distribusi kelas seimbang [19]. *Framework* ini memungkinkan perbandingan jelas antara performa jaringan yang dilatih dengan dan tanpa teknik *preprocessing* spesifik [20].

Optimasi *preprocessing* memainkan peran kritis dalam meningkatkan penerapan lightweight CNNs di lingkungan dengan keterbatasan sumber daya dengan meningkatkan akurasi klasifikasi sambil mengurangi *overhead* komputasi, signifikan mengingat meningkatnya permintaan aplikasi AI di platform *mobile* dan *embedded* [21]. Hasil penelitian ini diharapkan memberikan wawasan tentang teknik *preprocessing* optimal yang meningkatkan performa MobileNetV3-Large dalam klasifikasi tumor otak MRI, dengan implikasi langsung pada sistem diagnostik medis berbasis AI. Teknik *preprocessing* seperti *adaptive filters* dan algoritma deteksi tepi membantu menyempurnakan data input, meningkatkan performa lightweight CNNs dalam konteks klasifikasi morfometri otak [9]. Memanfaatkan arsitektur lightweight seperti

MobileNet yang dirancang menyeimbangkan efisiensi dan akurasi menjadi kritis untuk penerapan di lingkungan sumber daya terbatas [22]. Temuan penelitian ini dapat digunakan praktisi medis dan pengembang sistem AI untuk memilih teknik *preprocessing* paling efektif, memungkinkan pengembangan sistem diagnostik yang dapat diimplementasikan pada perangkat *edge*. Metode penggunaan kembali komputasi yang mengeksplorasi lokalitas spasial menunjukkan bagaimana *preprocessing* dapat memfasilitasi efisiensi operasional, sangat bermanfaat untuk penerapan pada perangkat *edge* yang memerlukan respon latensi rendah [23]. Teknik seperti *quantization* dan *pruning* yang digunakan bersama metode *preprocessing* dapat meminimalkan beban kerja komputasi model *deep learning* sambil mempertahankan level performa yang dapat diterima [24].


MATERIALS AND METHODS

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan desain komparatif untuk mengevaluasi performa teknik *preprocessing* pada klasifikasi tumor otak menggunakan *Convolutional Neural Network* (CNN). Desain komparatif kuantitatif memungkinkan pengukuran sistematis berbagai aspek performa CNN dan memberikan bukti statistik untuk mengukur efektivitasnya [25].

Penelitian dirancang dengan lima eksperimen independen yang menerapkan teknik *preprocessing* berbeda pada dataset identik menggunakan arsitektur model yang sama (MobileNetV3-Large). Desain ini memastikan bahwa perbedaan performa yang terobservasi dapat diatribusikan secara langsung kepada teknik *preprocessing*, bukan variabel *confounding* lainnya.

Untuk memberikan pemahaman yang lebih komprehensif mengenai alur pelaksanaan penelitian, Gambar 1 menampilkan diagram metodologi yang secara sistematis menggambarkan rangkaian tahapan penelitian. Alur penelitian mengikuti empat fase sistematis. Fase 1 (Studi Pendahuluan) meliputi identifikasi *research problem*, *research objective*, dan *research question*. Fase 2 (*Literature Review*) mengkaji penelitian terdahulu menggunakan kata kunci "*Lightweight CNN*" dan "*Brain Tumor Detection*" dengan mengumpulkan 10 jurnal menggunakan 4 metode [26]. Fase 3 (Perancangan dan Pelaksanaan Eksperimen) dimulai dari dataset, dilanjutkan dengan *Exploratory Data Analysis* (EDA), *data splitting* (70% *training*, 15% *testing*, 15% *validation*), *image preprocessing* dengan lima teknik berbeda, pengembangan dan pelatihan model

MobileNetV3-Large, hingga evaluasi menggunakan metrik klasifikasi dan metrik efisiensi model. Fase 4 (Kesimpulan dan Rekomendasi) menyajikan kesimpulan serta saran berdasarkan hasil analisis yang diperoleh.



Gambar 1 Desain Penelitian

Gambar tersebut menunjukkan alur metodologi penelitian yang terdiri dari empat fase utama. Fase pertama adalah studi pendahuluan yang mencakup identifikasi masalah penelitian (research problem), penentuan tujuan penelitian (research objective), serta perumusan pertanyaan penelitian (research question) sebagai dasar arah penelitian. Selanjutnya, fase kedua adalah literature review, di mana peneliti melakukan kajian terhadap penelitian-penelitian sebelumnya menggunakan kata kunci seperti "Lightweight CNN" dan "Brain Tumor Detection", serta memilih sekitar 10 artikel ilmiah yang relevan untuk dianalisis menggunakan metode tertentu (misalnya metode Hasibuan, 2007), guna memperkuat landasan teoritis dan menemukan celah penelitian.

Fase ketiga merupakan tahap inti yaitu perancangan dan pelaksanaan eksperimen. Tahap ini dimulai dari pengumpulan dataset, dilanjutkan dengan eksplorasi data (Exploratory Data Analysis/EDA), konfigurasi, dan proses data loading. Data kemudian dibagi menjadi tiga bagian, yaitu data training (70%), data testing (15%), dan data validation (15%). Setelah itu dilakukan preprocessing citra dengan berbagai teknik seperti standard resize (baseline), aspect ratio preservation dengan padding, center crop, adaptive resize, dan multi-scale input. Model yang digunakan dalam penelitian ini adalah MobileNetV3-Large yang dikembangkan dan dilatih menggunakan data yang telah diproses. Evaluasi model dilakukan menggunakan metrik

klasifikasi seperti accuracy, precision, recall, F1-score, dan confusion matrix, serta metrik efisiensi model seperti jumlah parameter, ukuran model, dan waktu inferensi. Hasil evaluasi kemudian dianalisis pada tahap result analysis.

Terakhir, fase keempat adalah kesimpulan dan rekomendasi yang berisi ringkasan hasil penelitian serta saran untuk pengembangan penelitian selanjutnya. Keseluruhan alur ini menunjukkan pendekatan penelitian yang sistematis, dimulai dari perumusan masalah hingga evaluasi dan interpretasi hasil eksperimen.


RESULTS AND DISCUSSION

Proses pelatihan model dirancang dengan standar yang sangat konsisten di kelima eksperimen untuk memastikan perbandingan yang adil. Semua eksperimen mengadopsi protokol *transfer learning* dua fase. Fase pertama adalah ekstraksi fitur (feature extraction), di mana seluruh bobot model dasar (MobileNetV3-Large) dibekukan (frozen) untuk melatih kepala klasifikasi baru. Fase kedua adalah fine-tuning, di mana 20 lapisan teratas dari model dasar di-'unfreeze' (dibebaskan) untuk adaptasi fitur yang lebih mendalam terhadap citra MRI.


Perbedaan arsitektural utama terletak pada input dan head model, yang memengaruhi jumlah parameter total. Untuk Eksperimen 1 hingga 4, arsitektur model identik: satu input 128x128 piksel disambungkan ke kepala klasifikasi standar yang terdiri dari GlobalAveragePooling2D, Dropout(0.3), Dense(128) dengan regularisasi L2, Dropout(0.2), dan output layer Dense 2 unit (softmax). Arsitektur standar ini secara konsisten menghasilkan 3,12 Juta parameter.

Sebaliknya, Eksperimen 5 (*Multi-Scale Input*) menggunakan arsitektur multi-input dengan tiga skala (96x96, 128x128, 160x160). Penting untuk dicatat bahwa arsitektur ini menggunakan bobot yang dibagikan (shared weights) untuk base_model di ketiga input, sehingga model dasar tidak diduplikasi. Fitur dari setiap skala diekstraksi (GlobalAveragePooling2D) dan kemudian digabungkan menggunakan Concatenate. Fusi ini (input yang lebih besar ke lapisan Dense(128) pertama di head) sedikit meningkatkan jumlah parameter, menghasilkan total 3,37 Juta parameter.


Untuk memastikan reproduktibilitas dan keadilan perbandingan, semua eksperimen menggunakan random_state=42 untuk pembagian data. Selain itu, callback EarlyStopping digunakan secara seragam untuk memonitor val_loss, menghentikan pelatihan jika tidak ada perbaikan setelah 10 epoch, dan mengembalikan bobot model terbaik.

Eksperimen 1: Standard Resize (Baseline)**Gambar 2 Kurva Akurasi dan Presisi Eksperimen 1**

Pengubahan ukuran langsung *Baseline* menunjukkan pelatihan akurasi meningkat dari 90% ke 99% dengan konvergensi smooth. Akurasi validasi berfluktuasi signifikan di 91-96% dengan epoch terbaik di epoch 10 (96%). Pelatihan presisi naik konsisten dari 88% ke 99%, sedangkan validasi presisi fluktuatif di 90-96%. Gap pelatihan-validasi melebar seiring epoch, mengindikasikan onset *overfitting* meskipun performa validasi masih dapat diterima.


**Gambar 3 Kurva Recall dan Loss Eksperimen 1**

Pelatihan *Recall* meningkat dari 90% ke 99% secara stabil, validasi *Recall* berfluktuasi di 88-96%. Pelatihan loss turun konsisten dari 0,45 ke 0,05. Validasi loss kritis: turun hingga 0,35 di *epoch* 7, kemudian melonjak drastis ke 1,5 di *epoch* 12 dan berfluktuasi tinggi (0,5-1,5) hingga akhir. *Divergence* ekstrim pelatihan-validasi loss setelah *epoch* 10 mengonfirmasi *overfitting* yang parah (model menghafal pelatihan data tanpa generalisasi).


**Gambar 4 Confusion matrix Eksperimen 1**

Test set menghasilkan 203 TN, 22 FP, 5 FN, 220 TP (total 27 misklasifikasi). Akurasi 94,00%, presisi 90,98%, *Recall* 97,78%, *F1-Score* 94,25%. Nilai FP 9,78% jauh melebihi Nilai FN 2,22% (model bias ke deteksi berlebihan), sering misklasifikasi non-tumor sebagai tumor. *Recall* tinggi (97,78%) menunjukkan sensitivitas baik, namun presisi rendah (90,98%) mengindikasikan banyak *false alarm* yang berpotensi menyebabkan pemeriksaan lanjutan


tidak perlu dan *anxietas* pasien. Waktu inferensi $15,64 \pm 8,53$ ms (variabilitas tinggi akibat *preprocessing* citra heterogen). Waktu pelatihan 14,19 menit, model size 20,52 MB (3,12 juta parameter).

Eksperimen 2: Aspect Ratio Preservation + Padding**Gambar 5 Kurva Akurasi dan Presisi Eksperimen 2**

Preservasi aspek rasio dengan *zero-Padding* menghasilkan pelatihan akurasi meningkat cepat dari 91% ke 99-100% dan stabil hampir sempurna. Validasi akurasi dimulai dari 92%, berfluktuasi di 92-96%, dengan *epoch* terbaik di *epoch* 20 (96%). Pelatihan presisi konvergen sempurna di 99-100%, validasi presisi fluktuatif di 92-97%. Gap pelatihan-validasi terlihat namun performa validasi konsisten tinggi (>92%), menunjukkan generalisasi baik tanpa *overfitting* yang parah.

**Gambar 6 Kurva Recall dan Loss Eksperimen 2**

Pelatihan *Recall* mencapai 99-100% dengan stabilitas tinggi, validasi *Recall* berfluktuasi di 92-96% dengan *epoch* terbaik di *epoch* 20. Pelatihan loss turun sangat halus dari 0,45 ke mendekati 0,00. Validasi loss menunjukkan pola unik: dimulai dari 0,45, lonjakan dramatik ke 1,0+ di *epoch* 5 (kemungkinan penyesuaian tingkat pembelajaran atau *batch variance* ekstrim), kemudian turun bertahap dan stabil di 0,15-0,30 dengan *epoch* terbaik di *epoch* 30 (0,15). Konvergensi validasi loss setelah *epoch* 10 ke level rendah dengan lintasan menurun mengindikasikan tidak ada *overfitting*. Gap pelatihan-validasi loss masih masuk akal untuk model dengan generalisasi baik.

**Gambar 7 Confusion matrix Eksperimen 2**

Test set menghasilkan 222 TN, 3 FP, 2 FN, 223 TP (hanya 5 misklasifikasi). Akurasi 98,89%, presisi 98,67%, *Recall* 99,11%, *F1-Score* 98,89%. Nilai FP 1,33% sedikit lebih tinggi dari Nilai FN 0,89%, minor bias ke *over-detection* namun kedua Tingkat kesalahan sangat rendah. *Recall* 99,11% menunjukkan sensitivitas excellent dengan hanya 2 kasus tumor terlewat. Peningkatan 4,89 poin dari *Baseline* (94,00%→98,89%) mengonfirmasi preservasi aspek rasio krusial untuk mempertahankan fitur morfologis diagnostik. Waktu inferensi $16,60 \pm 2,63$ ms (overhead +6,1%, konsistensi *preprocessing* tinggi). Waktu pelatihan 36,30 menit ($2,6 \times$ *Baseline*), masuk akal untuk *gain* akurasi signifikan. Model size 20,52 MB (3,12 juta parameter).

CONCLUSION

Penelitian ini berhasil mengevaluasi lima teknik *preprocessing* (*standard resize*, *Aspect Ratio Preservation* dengan *Padding*, *Center Crop*, *Adaptive Resize*, dan *Multi-Scale Input*) pada arsitektur MobileNetV3-Large untuk klasifikasi biner MRI tumor otak. Analisis komprehensif terhadap dataset 3.000 citra, yang memiliki heterogenitas resolusi tinggi dan variasi aspek rasio signifikan antar kelas, menghasilkan tiga kesimpulan utama yang menjawab rumusan masalah:

Evaluasi Performa Klasifikasi: Teknik *Multi-Scale Input* mencapai performa akurasi tertinggi (99,56%). Namun, teknik *Aspect Ratio + Padding* mencapai akurasi yang sangat kompetitif (98,89%), dengan selisih marginal hanya 0,67 poin (setara 3 kesalahan dari 450 sampel uji). Performa ini menunjukkan peningkatan signifikan sebesar 4,89 poin dibandingkan *Baseline Standard Resize* (94,00%), mengonfirmasi bahwa preservasi geometris sangat efektif dalam meningkatkan performa model.

Analisis *Trade-off* Komputasi: Teknik *Aspect Ratio + Padding* terbukti paling efisien, dengan mempertahankan properti *lightweight* (model 20,52 MB, 3,12 juta parameter) dan overhead waktu inferensi minimal (16,60 ms, atau +6,1% dari *Baseline*). Sebaliknya, *Multi-Scale Input*, meskipun paling akurat, memiliki *trade-off* komputasi yang tidak proporsional, dengan waktu inferensi membengkak menjadi 43,62 ms (hampir 3x lipat *Baseline*) dan ukuran model 23,34 MB, yang melanggar prinsip efisiensi CNN ringan.

Penentuan Teknik Optimal: *Aspect Ratio Preservation + Padding* ditetapkan sebagai

teknik *preprocessing* optimal. Teknik ini memberikan keseimbangan terbaik antara akurasi diagnostik yang tinggi (98,89%), pola kesalahan yang seimbang (Nilai FP 1,33% dan Nilai FN 0,89%), dan efisiensi komputasi yang unggul (overhead +6,1%). Pendekatan yang sederhana namun berprinsip ini terbukti mengungguli strategi yang lebih kompleks dengan cara mempertahankan fitur morfologis tanpa distorsi, menjadikannya solusi praktis optimal untuk *deployment* sistem klasifikasi tumor otak pada perangkat dengan keterbatasan sumber daya.

REFERENCE

- [1] N. Ashar, G. Raut, V. Trivedi, S. Vishvakarma, and A. Kumar, "Quantmac: enhancing hardware performance in dnns with quantize enabled multiply-accumulate unit," *IEEE Access*, vol. 12, pp. 43600–43614, 2024, doi: 10.1109/access.2024.3379906.
- [2] P. Yan and G. Lu, "Design of an intelligent educational evaluation system using deep learning," *IEEE Access*, vol. 11, pp. 29790–29799, 2023, doi: 10.1109/access.2023.3260979.
- [3] M. Al-Andoli, S. Tan, K. Sim, M. Seera, and C. Lim, "A parallel ensemble learning model for fault detection and diagnosis of industrial machinery," *IEEE Access*, vol. 11, pp. 39866–39878, 2023, doi: 10.1109/access.2023.3267089.
- [4] E. Manor and S. Greenberg, "Custom hardware inference accelerator for tensorflow lite for microcontrollers," *IEEE Access*, vol. 10, pp. 73484–73493, 2022, doi: 10.1109/access.2022.3189776.
- [5] M. Musthafa, I. Manimozhi, T. Mahesh, and S. Guluwadi, "Optimizing double-layered convolutional neural networks for efficient lung cancer classification through hyperparameter optimization and advanced image pre-processing techniques," *BMC Med. Inform. Decis. Mak.*, vol. 24, no. 1, 2024, doi: 10.1186/s12911-024-02553-9.
- [6] H. Lu, X. Feng, and J. Zhang, "Early detection of cardiorespiratory complications and training monitoring using wearable ecg sensors and cnn," *BMC Med. Inform. Decis. Mak.*, vol. 24, no. 1, 2024, doi: 10.1186/s12911-024-02599-9.
- [7] I. Orășan, A. Bublea, and C. Căleanu, "Deep learning-based eye gaze estimation for automotive applications using knowledge distillation," *IEEE Access*, vol. 11, pp.

- 120741–120753, 2023, doi: 10.1109/access.2023.3325134.
- [8] H. Uyanik *et al.*, “A multi-input convolutional neural networks model for earthquake precursor detection based on ionospheric total electron content,” *Remote Sens. (Basel)*, vol. 15, no. 24, p. 5690, 2023, doi: 10.3390/rs15245690.
- [9] T. Devi and K. Saji, “A stacked custom convolution neural network for voxel-based human brain morphometry classification,” *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-17331-4.
- [10] G. Datta *et al.*, “A processing-in-pixel-in-memory paradigm for resource-constrained tinyml applications,” *Sci. Rep.*, vol. 12, no. 1, 2022, doi: 10.1038/s41598-022-17934-1.
- [11] X. Tian, L. Shi, Y. Luo, and X. Zhang, “Garbage classification algorithm based on improved mobilenetv3,” *IEEE Access*, vol. 12, pp. 44799–44807, 2024, doi: 10.1109/access.2024.3381533.
- [12] B. Olimov, B. Subramanian, R. Ugli, J. Kim, and J. Kim, “Consecutive multiscale feature learning-based image classification model,” *Sci. Rep.*, vol. 13, no. 1, 2023, doi: 10.1038/s41598-023-30480-8.
- [13] O. Oyelade and A. Ezugwu, “A novel wavelet decomposition and transformation convolutional neural network with data augmentation for breast cancer detection using digital mammogram,” *Sci. Rep.*, vol. 12, no. 1, 2022, doi: 10.1038/s41598-022-09905-3.
- [14] J. Rahman, M. Hanif, O. Rehman, U. Haider, S. Qaisar, and P. Plawiak, “Stages prediction of alzheimer’s disease with shallow 2d and 3d cnns from intelligently selected neuroimaging data,” *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-93560-x.
- [15] F. Zhang, F. Wang, W. Zhang, Q. Wang, Y. Liu, and Z. Jiang, “Rotu-net: an innovative u-net with local rotation for medical image segmentation,” *IEEE Access*, vol. 12, pp. 21114–21128, 2024, doi: 10.1109/access.2024.3363410.
- [16] U. Lilhore *et al.*, “Prevalence and risk factors analysis of postpartum depression at early stage using hybrid deep learning model,” *Sci. Rep.*, vol. 14, no. 1, 2024, doi: 10.1038/s41598-024-54927-8.
- [17] C. Tinauer *et al.*, “Interpretable brain disease classification and relevance-guided deep learning,” *Sci. Rep.*, vol. 12, no. 1, 2022, doi: 10.1038/s41598-022-24541-7.
- [18] J. Liu, T. Wang, A. Skidmore, Y. Sun, P. Jia, and K. Zhang, “Integrated 1d, 2d, and 3d cnns enable robust and efficient land cover classification from hyperspectral imagery,” *Remote Sens. (Basel)*, vol. 15, no. 19, p. 4797, 2023, doi: 10.3390/rs15194797.
- [19] J. Pandian, R. Thirunavukarasu, and E. Kotei, “A novel convolutional neural network model for automatic speaker identification from speech signals,” *IEEE Access*, vol. 12, pp. 51381–51394, 2024, doi: 10.1109/access.2024.3385858.
- [20] H. Guo and L. Ren, “A marine small-targets classification algorithm based on improved convolutional neural networks,” *Remote Sens. (Basel)*, vol. 15, no. 11, p. 2917, 2023, doi: 10.3390/rs15112917.
- [21] X. Xu, S. Huang, and H. Lai, “Lightweight semantic segmentation network leveraging class-aware contextual information,” *IEEE Access*, vol. 11, pp. 144722–144734, 2023, doi: 10.1109/access.2023.3345790.
- [22] F. Siraj, S. Ayon, M. Samad, J. Uddin, and K. Choi, “Few-shot lightweight squeezeNet architecture for induction motor fault diagnosis using limited thermal image dataset,” *IEEE Access*, vol. 12, pp. 50986–50997, 2024, doi: 10.1109/access.2024.3385430.
- [23] F. Alantali, Y. Halawani, B. Mohammad, and M. Al-Qutayri, “Slid: exploiting spatial locality in input data as a computational reuse method for efficient cnn,” *IEEE Access*, vol. 9, pp. 57179–57187, 2021, doi: 10.1109/access.2021.3071409.
- [24] C. Lee, J. Kong, and A. Munir, “Arithmetic coding-based 5-bit weight encoding and hardware decoder for cnn inference in edge devices,” *IEEE Access*, vol. 9, pp. 166736–166749, 2021, doi: 10.1109/access.2021.3136888.
- [25] Y. Kok *et al.*, “Classification of osteoarthritic and healthy cartilage using deep learning with raman spectra,” *Sci. Rep.*, vol. 14, no. 1, 2024, doi: 10.1038/s41598-024-66857-6.
- [26] Z. A. Hasibuan, *Metodologi penelitian pada bidang ilmu komputer dan teknologi informasi: Konsep, teknik, dan aplikasi*. Fakultas Ilmu Komputer Universitas Indonesia, 2007.