

PERBANDINGAN KINERJA MODEL *DEEP LEARNING* UNTUK SEGMENTASI TUMOR OTAK CITRA MRI DENGAN PENERAPAN CLAHE

Agnes Anastasia Putri, Nur Rachmat

Informatika, Universitas Multi Data Palembang

Jl. Rajawali No.14, Palembang, Indonesia

agnesanastasiaputri_2226250013@mhs.mdp.ac.id

ABSTRAK

Tumor otak merupakan pertumbuhan sel abnormal pada otak yang dapat mengganggu fungsi saraf dan berisiko menyebabkan kematian. Pemeriksaan menggunakan *Magnetic Resonance Imaging* (MRI) membantu dokter mendeteksi tumor otak, tetapi proses segmentasi area tumor secara manual masih memerlukan waktu yang lama dan hasilnya dapat berbeda antar pengamat. Metode *deep learning* seperti UNet banyak digunakan untuk segmentasi citra medis, namun masih memiliki keterbatasan dalam menangkap hubungan antar fitur pada citra. Penelitian ini bertujuan mengembangkan model *hybrid* UNet dengan *backbone* ResNet50V2, Xception, dan InceptionV4, serta menganalisis pengaruh *Contrast Limited Adaptive Histogram Equalization* (CLAHE) terhadap kualitas segmentasi tumor otak pada citra MRI. Metode yang digunakan melibatkan 4.793 citra dari dataset BRISC 2025 yang dibagi menjadi data pelatihan, validasi, dan pengujian. Model dievaluasi menggunakan *confussion matrix*, *dice coefficient*, dan *intersection over union* (IoU). Hasil penelitian membuktikan bahwa skenario UNet + CLAHE memperoleh performa terbaik dengan tingkat akurasi 98,58%, *dice coefficient* 75,30%, dan IoU 64,29%. Hal ini menunjukkan bahwa kombinasi arsitektur UNet standar dengan teknik peningkatan kontras CLAHE jauh lebih efektif dalam melakukan segmentasi dibandingkan menggunakan arsitektur *backbone* yang lebih kompleks.

Kata kunci : Segmentasi Tumor Otak; Deep Learning; CLAHE

1. PENDAHULUAN

Otak merupakan organ vital yang mengendalikan hampir seluruh aktivitas tubuh, mulai dari pengambilan keputusan, pengolahan informasi, hingga pengiriman sinyal ke berbagai bagian tubuh [1]. Gangguan pada pertumbuhan dan perkembangan sel-sel otak dapat menyebabkan terbentuknya tumor otak, yaitu massa sel abnormal yang berpotensi menekan jaringan otak dan mengganggu fungsi neurologis pasien [2]. Berdasarkan asal kemunculannya, tumor otak dibedakan menjadi *primary tumor* yang berasal dari jaringan otak itu sendiri dan *secondary* atau tumor metastatik yang berasal dari penyebaran tumor dari organ lain menuju otak [3][4]. Penyakit ini masih menjadi masalah kesehatan yang serius karena menyerang sekitar 7–11 individu per 100.000 penduduk setiap tahun dan menyebabkan sekitar 227.000 kematian secara global, sehingga deteksi dini menjadi faktor penting dalam meningkatkan peluang keberhasilan penanganan pasien [5][6][7].

Untuk mencegah hal tersebut diperlukan perkembangan teknologi komputasi yang canggih yang mampu memanfaatkan citra MRI dan kecerdasan buatan untuk membantu proses identifikasi tumor otak secara lebih cepat dan akurat dibandingkan metode manual [8]. Namun, pendekatan machine learning konvensional masih memiliki keterbatasan karena sangat bergantung pada proses ekstraksi fitur yang dirancang secara manual oleh peneliti [9]. Untuk mengatasi keterbatasan tersebut, *deep learning* menjadi solusi yang banyak digunakan karena mampu mempelajari representasi fitur secara otomatis, hierarkis, dan lebih efektif dalam menangkap

hubungan nonlinier yang kompleks pada citra medis [10].

Salah satu teknik *deep learning* yang banyak diterapkan pada analisis citra medis adalah segmentasi semantik, yaitu proses identifikasi dan pemisahan area objek pada tingkat piksel. Dalam bidang ini, UNet menjadi salah satu arsitektur yang paling populer karena dirancang khusus untuk menangani citra medis dan mampu menghasilkan segmentasi yang akurat meskipun menggunakan jumlah data pelatihan yang relatif terbatas [11]. Keunggulan UNet terletak pada arsitektur *encoder* dan *decoder* yang mampu mengekstraksi fitur semantik dari berbagai tingkat kedalaman serta memulihkan informasi spasial yang hilang melalui mekanisme *skip connection*, sehingga model dapat menghasilkan segmentasi objek yang lebih presisi [12].

Meskipun UNet merupakan salah satu arsitektur yang paling banyak digunakan dalam segmentasi citra medis, model ini masih memiliki beberapa keterbatasan, seperti kesenjangan informasi antara lapisan konvolusi yang berbeda serta kurang optimal dalam mengelola hubungan antar *feature maps* dari berbagai tahapan ekstraksi fitur [13].

Untuk mengatasi kelemahan tersebut, berbagai penelitian telah mengintegrasikan UNet dengan arsitektur lain, seperti ResNet, Xception, dan Inception, guna meningkatkan kemampuan ekstraksi fitur dan representasi spasial model [14]. Selain itu, agar mampu memberikan hasil yang lebih baik, pada penelitian ini akan mengintegrasikan CLAHE yang akan digunakan untuk meningkatkan performa dataset yang nantinya akan dibandingkan juga dengan model

tanpa CLAHE untuk mengetahui apakah penggunaan teknik peningkat kontras bekerja dengan sangat baik.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penelitian ini menggunakan dataset BRISC 2025 yang dipilih berdasarkan hasil studi [15] yang membandingkan empat dataset citra medis, yaitu HAM10000, BUSI, Chest X-Ray Pneumonia, dan BRISC 2025. Hasil penelitian tersebut menunjukkan bahwa BRISC 2025 memperoleh akurasi tertinggi sebesar 98,76%, melampaui Chest X-Ray Pneumonia yang berada pada posisi kedua dengan akurasi 93,11%. Meskipun demikian, evaluasi tersebut hanya dilakukan menggunakan satu model, yaitu *Spatial Spectral Summarizer Fusion Network*, sehingga masih terbuka peluang untuk mengeksplorasi performa arsitektur lain pada dataset yang sama.

Pada penelitian sebelumnya yang menggunakan BRISC 2025, pengujian telah dilakukan terhadap beberapa arsitektur seperti EfficientNet, ResNet, MobileNet, dan DenseNet. Berbeda dengan penelitian tersebut, penelitian ini mengimplementasikan ResNet50V2, Xception, dan InceptionV4 sebagai *backbone* UNet. Pemilihan ResNet50V2 didasarkan pada kemampuannya menghasilkan performa yang lebih baik dibandingkan InceptionResNetV2 dan MobileNetV2 pada segmentasi tumor otak [16], serta memperoleh hasil terbaik dibandingkan VGG16 dan Xception pada penelitian lain [17]. Xception dipilih karena mampu mencapai akurasi sebesar 95% pada klasifikasi tumor otak dan mengungguli VGG16, MobileNet, serta ResNet50 [18], selain juga menunjukkan performa yang baik pada citra paru-paru dengan akurasi 98,77% [19]. Sementara itu, InceptionV4 dipilih karena terbukti mampu menangani citra medis yang kompleks dan menghasilkan performa yang kompetitif dibandingkan berbagai arsitektur lain, seperti VGG, ResNet, DenseNet, EfficientNet, MobileNet, Xception, dan Transformer [20], serta telah digunakan pada pengembangan model segmentasi berbasis UNet pada citra *enhanced breast ultrasound* [21].

Selain modifikasi arsitektur, penelitian ini juga menerapkan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) sebagai teknik *image enhancement* untuk meningkatkan kualitas citra sebelum proses segmentasi. CLAHE mampu meningkatkan kontras citra sehingga batas antara area tumor dan jaringan normal menjadi lebih jelas, yang pada akhirnya membantu model dalam mengekstraksi fitur yang lebih representatif. Efektivitas metode ini telah dibuktikan pada berbagai penelitian segmentasi citra medis, termasuk segmentasi tumor otak menggunakan UNet [22]. Berdasarkan hal tersebut, penelitian ini membandingkan performa UNet standar, UNet + CLAHE, UNet + ResNet50V2 + CLAHE, UNet + InceptionV4 + CLAHE, dan UNet + Xception + CLAHE menggunakan metrik *dice coefficient* dan *intersection over union* (IoU) untuk menentukan

model yang paling efektif dalam segmentasi tumor otak pada dataset BRISC 2025.

2.2. Tumor Otak

Tumor otak merupakan suatu penyakit yang terjadi karena pertumbuhan sel otak mengalami perubahan yang abnormal di dalam atau di sekitar otak secara tidak wajar dan tidak terkendali [23]. Berdasarkan asal usulnya, tumor otak dibagi menjadi 2, yaitu tumor otak primer dan sekunder. Tumor otak primer merupakan perubahan sel yang tidak normal dan tidak terkontrol yang berasal dari sel otak itu sendiri. Sedangkan, tumor otak sekunder merupakan tumor yang menyebar ke otak dari kanker tubuh bagian lain [24].

2.3. Segmentasi

Segmentasi merupakan prosedur yang digunakan untuk membedakan antara objek utama dengan latar belakang atau mengklasifikasikan area gambar ke dalam segmen-segmen yang memiliki kemiripan atribut tertentu [25].

2.4. UNet

UNet merupakan arsitektur *fully convolutional network* yang diperkenalkan pada tahun 2015 dan banyak digunakan untuk segmentasi citra medis. Arsitektur ini memiliki struktur berbentuk huruf “U” yang terdiri atas dua bagian utama, yaitu *contracting path* dan *expanding path*. *Contracting path* berfungsi mengekstraksi fitur melalui kombinasi operasi konvolusi, aktivasi ReLU, dan *max pooling* untuk menangkap informasi penting dari citra, sedangkan *expanding path* bertugas memulihkan dimensi spasial menggunakan konvolusi transposisi serta menggabungkan *feature maps* dari jalur kontraksi melalui *skip connection* guna menghasilkan segmentasi yang lebih akurat [26].

2.5. ResNet50V2

ResNet50V2 merupakan pengembangan dari ResNet50 yang memanfaatkan arsitektur *residual network* untuk mempermudah pelatihan jaringan yang dalam dan meningkatkan kemampuan ekstraksi fitur pada citra yang kompleks [27]. Model ini dikenal lebih efektif dibandingkan beberapa arsitektur sebelumnya dalam menangani variasi citra serta menunjukkan performa yang lebih baik dibandingkan ResNet50 dan ResNet101 pada tugas segmentasi medis [28] [29]. Keunggulan ResNet50V2 didukung oleh penerapan *pre-activation* dan *batch normalization* yang menghasilkan pelatihan lebih stabil, efisien, dan konsisten dibandingkan versi pendahulunya [27].

2.6. Xception

Xception (*Extreme Inception*) merupakan pengembangan dari arsitektur Inception yang mengandalkan teknik *depthwise separable convolution* untuk meningkatkan efisiensi komputasi dan penggunaan memori [30]. Arsitektur ini terdiri

atas 36 lapisan konvolusi yang disusun dalam 14 modul dan dihubungkan oleh *residual connection* untuk mendukung proses pembelajaran yang lebih efektif [31]. Xception bekerja dengan memisahkan proses konvolusi menjadi *depthwise convolution* dan *pointwise convolution* (1×1), sehingga mampu mengekstraksi fitur secara efisien tanpa mengurangi kualitas representasi fitur. Alur pemrosesannya terdiri dari *entry flow*, *middle flow* yang diulang beberapa kali, dan *exit flow*, dengan seluruh lapisan menerapkan *depthwise separable convolution* sebagai komponen utama [32].

2.7. InceptionV4

InceptionV4 merupakan pengembangan dari arsitektur Inception yang dirancang untuk meningkatkan performa pengenalan citra melalui struktur yang lebih sederhana dan konsisten dibandingkan InceptionV3 [33]. Arsitektur ini terdiri atas *stem block*, modul Inception A, B, dan C, serta *reduction block* yang berfungsi menyesuaikan dimensi fitur selama proses ekstraksi. Dibandingkan dengan Xception, Inception memiliki perbedaan pada mekanisme konvolusi, yaitu mendahulukan konvolusi 1×1 sebelum konvolusi spasial serta menerapkan fungsi aktivasi ReLU setelah setiap operasi konvolusi, sedangkan Xception menggunakan pendekatan yang berbeda pada urutan operasi dan penerapan nonlinieritas [32].

2.8. CLAHE

Contrast Limited Adaptive Histogram Equalization atau CLAHE merupakan salah satu teknik peningkatan kontras yang pertama kali dibuat pada tahun 1994 oleh Karel Zuiderveld [34]. CLAHE sendiri merupakan bentuk lanjutan dari *adaptive histogram equalization* (AHE) yang bertujuan untuk meningkatkan kualitas citra dengan menghilangkan noise dan mencegah amplifikasi *noise* yang tinggi yang sering terjadi pada teknik AHE konvensional. Metode ini bekerja dengan menggunakan penguatan kontras dengan membatasi prosedur pada setiap piksel tetangga, di mana fungsi transformasinya dibentuk sedemikian rupa untuk mengurangi masalah *noise* [35].

2.9. Dice Coefficient

Dice coefficient, yang juga dikenal sebagai *dice similarity coefficient* (DSC) merupakan instrumen evaluasi untuk mengukur derajat keserupaan antara dua objek. Dalam pengolahan citra, metrik ini biasa digunakan untuk menilai performa segmentasi semantik dengan menghitung rasio tumpang tindih (*overlap*) antara hasil prediksi model terhadap data acuan (*ground truth*) dibandingkan dengan ukuran masing-masing himpunan data [36]. Nilai *dice coefficient* dapat dihitung menggunakan rumus pada persamaan 1.

$$DC = \frac{2|A \cap B|}{|A| + |B|} = \frac{2TP}{2TP + FP + FN} \quad (1)$$


2.10. Intersection over Union (IoU)

Intersection over Union (IoU), yang juga diidentifikasi sebagai indeks Jaccard atau koefisien Jaccard, merupakan metrik untuk mengukur derajat tumpang tindih antara hasil segmentasi model dengan data acuan (*ground truth*). Metrik ini memiliki rentang nilai dari 0 hingga 1, di mana nilai 0 mengindikasikan ketiadaan tumpang tindih sama sekali, sementara nilai 1 merepresentasikan kesesuaian sempurna antara area prediksi dan area actual [37]. Nilai IoU dapat dihitung melalui persamaan 2.

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}} \quad (2)$$

3. METODE PENELITIAN

Tahapan metodologi penelitian dapat dilihat pada Gambar 1.



Gambar 1. Metodologi Penelitian

3.1. Studi Literatur

Penelitian ini diawali dengan tinjauan pustaka mendalam melalui analisis jurnal, buku, dan referensi terdahulu. Langkah ini bertujuan untuk membangun landasan teori serta mendalami arsitektur UNet, InceptionV4, ResNet50V2, dan Xception dalam konteks dataset tumor otak. Selain itu, kajian ini mengevaluasi temuan riset segmentasi tumor otak sebelumnya berbasis referensi utama dalam pengembangan model penelitian yang sedang dilakukan.

3.2. Pengumpulan Dataset

Pada tahap ini, dilakukan proses pengumpulan dataset berupa dataset tumor otak yang bersifat publik yaitu BRISC 2025. Dataset ini kemudian akan digunakan dalam melatih dan menguji model segmentasi tumor otak. Dataset terdiri atas citra medis beserta mask yang merepresentasikan area tumor. Seluruh data diperoleh melalui penelitian yang dilakukan oleh [38].

3.3. Preprocessing

Pada penelitian ini, dataset BRISC 2025 dipraproses dengan mengubah ukuran citra dari 512×512 piksel menjadi 224×224 piksel untuk menyesuaikan kebutuhan model dan mengacu pada beberapa penelitian terdahulu [39]. Selain *resize*, beberapa skenario menerapkan metode *Contrast limited adaptive histogram equalization* (CLAHE) untuk meningkatkan kontras citra sehingga area tumor lebih mudah dikenali oleh model. Pada skenario UNet standar hanya digunakan *resize*, sedangkan pada UNet + CLAHE, UNet + ResNet50V2 + CLAHE, UNet + InceptionV4 + CLAHE, dan UNet + Xception + CLAHE digunakan kombinasi *resize* dan CLAHE.

Untuk proses pelatihan dan evaluasi, dataset dibagi menggunakan rasio 70:10:20 menjadi data pelatihan, validasi, dan pengujian [40]. Dari total 4.793 citra, sebanyak 3.540 citra digunakan untuk pelatihan, 393 citra untuk validasi, dan 860 citra untuk pengujian. Pembagian ini bertujuan memastikan proses pelatihan, validasi, dan pengujian dilakukan secara objektif sehingga performa model dapat dievaluasi secara akurat.

3.4. Implementasi


Penelitian ini mengimplementasikan lima skenario model, yaitu UNet, UNet + CLAHE, UNet + ResNet50V2 + CLAHE, UNet + InceptionV4 + CLAHE, dan UNet + Xception + CLAHE. Model UNet menggunakan arsitektur *encoder* dan *decoder* dengan mekanisme *skip connection* untuk mempertahankan informasi spasial selama proses segmentasi. Pada skenario berbasis CLAHE, citra masukan terlebih dahulu ditingkatkan kontrasnya untuk memperjelas batas antara area tumor dan jaringan normal sehingga fitur yang diekstraksi menjadi lebih representatif.

Perbedaan utama antar model terletak pada bagian *encoder*. UNet + ResNet50V2 + CLAHE memanfaatkan blok residual untuk mendukung ekstraksi fitur yang lebih dalam, UNet + InceptionV4 + CLAHE menggunakan modul Inception untuk menangkap fitur pada berbagai skala secara simultan, sedangkan UNet + Xception + CLAHE menerapkan *depthwise separable convolution* untuk meningkatkan efisiensi ekstraksi fitur. Seluruh model dilatih menggunakan parameter yang sama, yaitu 50 *epoch*, *batch size* 4, *learning rate* 1×10^{-3} , dan *optimizer* Adam [41].


3.5. Pengujian

Pada tahap pengujian, seluruh model dievaluasi menggunakan 860 citra data uji dari dataset BRISC 2025 yang tidak digunakan selama pelatihan. Pengujian dilakukan melalui segmentasi tingkat piksel (*pixel-wise classification*), kemudian hasil segmentasi dibandingkan dengan *ground truth* menggunakan metrik Dice Coefficient dan Intersection over Union (IoU). Untuk menjaga konsistensi hasil, proses


pelatihan dan pengujian menggunakan *random seed* 42 [42].




Gambar 2. Skenario Unet




Gambar 3. Skenario UNet dengan CLAHE



Gambar 4. Skenario UNet + ResNet50V2 dengan CLAHE




Gambar 5. Skenario UNet + InceptionV4 dengan CLAHE



Gambar 6. Skenario UNet + Xception dengan CLAHE

4. HASIL DAN PEMBAHASAN



Gambar 7. Dataset BRISC2025

Proses segmentasi dalam penelitian ini mengimplementasikan empat varian arsitektur, yaitu UNet, UNet + ResNet50V2, UNet + InceptionV4, dan UNet + Xception, dengan menetapkan parameter prapemrosesan berupa ukuran *batch* sebesar 4, dimensi citra 224 x 224, *epoch* 50 serta *learning rate* 0.001. Dataset BRISC2025 dibagi ke dalam tiga


bagian, yakni data pelatihan, validasi, dan pengujian dengan proporsi pembagian 70:10:20. Untuk menaikkan kualitas keluaran model, teknik CLAHE digunakan pada dataset BRISC2025. Gambar dari dataset yang digunakan dapat dilihat pada Gambar 7.

Dataset BRISC2025 berisi 2 gambar citra yang berbeda yaitu citra asli dan mask. Mask nantinya akan digunakan oleh model untuk mempelajari pola, letak, dan ukuran dari tumor otak yang kemudian dibandingkan dengan citra asli dan lainnya untuk mencapai suatu kesimpulan dari citra target yang ingin diketahui. Pada Eksperimen ini dataset BRISC2025 digunakan untuk menguji efektivitas penggunaan teknik CLAHE dengan membandingkan performa model UNet dasar antara yang menggunakan CLAHE dan tanpa CLAHE, yang mana hasil perbandingan pelatihannya dapat dilihat secara detail pada Tabel 1.

Tabel 1. Perbandingan hasil uji coba CLAHE pada UNET


	Akurasi	Dice Coefficient	IoU
UNet	98,33%	74,34%	62,22%
UNet + CLAHE	98,58%	75,30%	64,29%

Tabel 1 menunjukkan bahwa penerapan CLAHE pada model UNet mampu meningkatkan performa segmentasi dibandingkan UNet standar. Peningkatan terjadi pada seluruh metrik evaluasi, yaitu akurasi sebesar 0,25%, *dice coefficient* sebesar 0,96%, dan *intersection over union* (IoU) sebesar 2,07%. Hasil ini menunjukkan bahwa CLAHE efektif meningkatkan kualitas citra sehingga kinerja segmentasi model menjadi lebih optimal.




Gambar 8. Diagram hasil evaluasi model UNet + CLAHE per epoch

Grafik *dice coefficient* dan IoU pada Gambar 8 menunjukkan bahwa model belajar dengan cepat pada 20 epoch pertama dan mulai stabil setelah *epoch* ke-25. Meskipun terjadi fluktuasi pada kurva validasi antara epoch 5 hingga 15, performa model kembali stabil pada epoch berikutnya. Adanya gap yang konsisten antara kurva pelatihan dan validasi mengindikasikan terjadinya *overfitting* ringan, di mana performa model pada data latih sedikit lebih baik dibandingkan data validasi.




Gambar 9. Diagram hasil evaluasi model UNet + ResNet50V2 + CLAHE per epoch

Secara keseluruhan, grafik *dice coefficient* dan IoU pada Gambar 9 menunjukkan bahwa model mengalami fluktuasi pada tahap awal pelatihan, terutama pada kurva validasi sebelum *epoch* ke-15. Setelah *epoch* ke-20, performa model mulai stabil dan menunjukkan kondisi konvergen, menandakan bahwa model telah mencapai kapasitas pembelajaran yang optimal. Namun, terdapat gap yang cukup jelas antara kurva pelatihan dan validasi, dengan selisih sekitar 0,12 pada *dice coefficient* dan 0,16 pada IoU. Kondisi ini mengindikasikan adanya *overfitting*, di mana model lebih mampu mempelajari data latih dibandingkan data validasi.



Gambar 10. Diagram hasil evaluasi model UNet + InceptionV4 + CLAHE per epoch

Grafik pada Gambar 10 menunjukkan bahwa model memiliki kecepatan konvergensi yang baik, dengan peningkatan performa yang signifikan pada 15 epoch pertama. Setelah epoch ke-20, kurva *dice coefficient* dan IoU menjadi stabil, menandakan bahwa model telah berhasil mempelajari pola segmentasi secara optimal. Meskipun terjadi fluktuasi pada fase awal pelatihan (*epoch* 1–5), kondisi tersebut merupakan proses penyesuaian parameter yang wajar sebelum model mencapai performa yang stabil dan mampu melakukan generalisasi dengan baik.



Gambar 11. Diagram hasil evaluasi model UNet + Xception + CLAHE per epoch

Grafik *dice coefficient* dan IoU Xception pada Gambar 11 menunjukkan proses pembelajaran yang cukup dinamis pada 15 *epoch* pertama dengan

fluktuasi performa yang signifikan. Setelah epoch ke-16, model mulai mencapai kondisi stabil dengan nilai *dice coefficient* sekitar 0,72 dan IoU sekitar 0,60 hingga *epoch* ke-35. Namun, setelah *epoch* ke-38 terlihat adanya penurunan performa secara bertahap, yang mengindikasikan kemungkinan terjadinya *overfitting* atau kejenuhan pembelajaran akibat pelatihan yang terlalu lama.

Tabel 2. Perbandingan hasil evaluasi model

	Akurasi	<i>Dice Coefficient</i>	IoU
UNET + CLAHE	98,58%	75,30%	64,29%
UNet + ResNet50V2 + CLAHE	98,55%	74,83%	63,90%
UNet + InceptionV4 + CLAHE	98,51%	72,16%	60,74%
UNet + Xception + CLAHE	98,30%	71,51%	60,01%

Tabel 2 menunjukkan bahwa UNet + CLAHE memperoleh performa segmentasi terbaik dengan akurasi 98,58%, *dice coefficient* 75,30%, dan IoU 64,29%. Hasil ini menunjukkan bahwa penggunaan *backbone* yang lebih kompleks tidak selalu menghasilkan peningkatan performa segmentasi. Pada dataset BRISC2025, struktur *encoder* dan *decoder* UNet yang dipadukan dengan CLAHE mampu mempertahankan informasi spasial secara lebih efektif sehingga menghasilkan kualitas segmentasi yang lebih baik dibandingkan model *hybrid* yang diuji.

5. KESIMPULAN DAN SARAN

Penelitian ini membuktikan bahwa UNet + CLAHE merupakan model terbaik untuk segmentasi tumor otak pada dataset BRISC2025 dengan akurasi 98,58%, *dice coefficient* 75,30%, dan IoU 64,29%. Penerapan CLAHE meningkatkan performa segmentasi dibandingkan UNet standar, sementara *backbone* yang lebih kompleks tidak memberikan hasil yang lebih baik. Penelitian selanjutnya dapat difokuskan pada optimasi parameter, penerapan regularisasi, dan pengujian pada dataset yang lebih beragam.

DAFTAR PUSTAKA

- [1] R. Missaoui, W. Heckel, W. Saadaoui, A. Helali, and M. Leo, "Advanced deep learning and machine learning techniques for MRI brain tumor analysis: a review," *Sensors*, vol. 25, no. 9, pp. 1–38, 2025, doi: 10.3390/s25092746.
- [2] H. Y. Chen, Z. Y. Wu, H. F. Liu, C. H. Liu, and S. W. Feng, "Applying deep learning techniques in accurate brain tumor detection and classification," *Eng. Proc.*, vol. 103, no. 1, pp. 1–9, 2025, doi: 10.3390/engproc2025103008.
- [3] M. A. Rahman, M. B. A. Miah, M. A. Hossain, and A. S. M. S. Hosen, "Enhanced brain tumor classification using MobileNetV2: a

- comprehensive preprocessing and fine-tuning approach,” *BioMedInformatics*, vol. 5, no. 2, pp. 1–33, 2025, doi: 10.3390/biomedinformatics5020030.
- [4] M. A. Gómez-Guzmán *et al.*, “Enhanced multi-class brain tumor classification in MRI using pre-trained CNNs and transformer architectures,” *Technologies*, vol. 13, no. 9, pp. 1–33, 2025, doi: 10.3390/technologies13090379.
- [5] V. K. Velpula, K. R. Reddy, K. N. Prakash, K. P. Jasmine, and V. J. Sri, “Optimizing brain tumor classification: integrating deep learning and machine learning with hyperparameter tuning,” *Eng. Proc.*, vol. 87, no. 1, pp. 1–10, 2025, doi: 10.3390/engproc2025087064.
- [6] T. Zhang, S. Wang, Y. Zhong, H. Li, J. Hu, and H. Wang, “An augmented reality-based navigation system for stereotactic brain biopsy with multi-objective path planning and hybrid registration,” *Brain Sci.*, vol. 16, no. 3, 2026, doi: 10.3390/brainsci16030296.
- [7] A. B. Abdusalomov, M. Mukhiddinov, and T. K. Whangbo, “Brain tumor detection based on deep learning approaches and magnetic resonance imaging,” *Cancers (Basel)*, vol. 15, no. 16, 2023, doi: 10.3390/cancers15164172.
- [8] P. S. Smitha, G. Balaarunesh, C. Sruthi Nath, and A. Sabatini S, “Classification of brain tumor using deep learning at early stage,” *Meas. Sensors*, vol. 35, no. February, p. 101295, 2024, doi: 10.1016/j.measen.2024.101295.
- [9] M. Agarwal, G. Rani, A. Kumar, P. K. K. R. Manikandan, and A. H. Gandomi, “Deep learning for enhanced brain tumor detection and classification,” *Results Eng.*, vol. 22, p. 102117, 2024, doi: 10.1016/j.rineng.2024.102117.
- [10] O. B. Ayoade, S. Shahrestani, and C. Ruan, “Machine learning and deep learning approaches for predicting diabetes progression: a comparative analysis,” *Electronics*, vol. 14, no. 13, 2025, doi: 10.3390/electronics14132583.
- [11] E. K. Rutoh, Q. Zhi Guang, N. Bahadar, R. Raza, and M. S. Hanif, “GAIR-U-Net: 3D guided attention inception residual u-net for brain tumor segmentation using multimodal MRI images,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 36, no. 6, p. 102086, 2024, doi: 10.1016/j.jksuci.2024.102086.
- [12] Y. Yuan and Y. Cheng, “Medical image segmentation with UNet-based multi-scale context fusion,” *Sci. Rep.*, vol. 14, no. 1, pp. 1–9, 2024, doi: 10.1038/s41598-024-66585-x.
- [13] A. Al Qurri and M. Almekkawy, “Improved UNet with attention for medical image segmentation,” *Sensors*, vol. 23, no. 20, 2023, doi: 10.3390/s23208589.
- [14] M. Renugadevi, K. Narasimhan, K. Ramkumar, and N. Raju, “A novel hybrid vision UNet architecture for brain tumor segmentation and classification,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–18, 2025, doi: 10.1038/s41598-025-09833-y.
- [15] M. S. B. Siddiqui and M. I. H. Bhuiyan, “S³F-Net: A multi-modal approach to medical image classification via spatial-spectral summarizer fusion network,” *IEEE*, pp. 1–12, 2025, doi: 10.1109/JBHI.2026.3682634.
- [16] I. S. Ardan and R. Indraswari, “Sistem berbasis deep learning untuk segmentasi dan klasifikasi tingkat keganasan tumor otak menggunakan citra MRI 3D,” *Ilk. J. Comput. Sci. Appl. Informatics*, vol. 6, no. 2, pp. 1–10, 2024, doi: 10.28926/ilkomnika.v6i2.643.
- [17] K. N. Qodri, “Analisis perbandingan klasifikasi tumor otak menggunakan deep learning,” *IJITECH Indones. J. Inf. Technol.*, vol. 2, no. 1, pp. 16–21, 2024, doi: 10.71155/rdgrt890.
- [18] R. R. Siregar and A. M. Husein, “Klasifikasi tumor otak pada gambar magnetik resonance images (MRI) dengan pendekatan pembelajaran mendalam,” *Data Sci. Indones.*, vol. 4, no. 1, pp. 62–68, 2024, doi: 10.47709/dsi.v4i1.4265.
- [19] A. R. T. Guna, K. Rahul, and O. K. Sikha, “U-NET Xception: A two-stage segmentation-classification model for COVID detection from lung CT scan images,” *Springer*, vol. 473, pp. 335–343, 2023, doi: https://doi.org/10.1007/978-981-19-2821-5_29.
- [20] H. M. S. S. Herath, S. L. P. Yasakethu, N. Madusanka, M. Yi, and B. Il Lee, “Comparative analysis of deep learning architectures for macular hole segmentation in OCT images: a performance evaluation of U-Net variants,” *J. Imaging*, vol. 11, no. 2, 2025, doi: 10.3390/jimaging11020053.
- [21] Y. Choi, M. N. Kim, and S. Na, “Inception U-Net for enhanced breast ultrasound image segmentation using transfer learning,” *Bioengineering*, vol. 13, no. 2, pp. 1–12, 2026, doi: 10.3390/bioengineering13020181.
- [22] N. E. Putri, R. Rahmadewi, and S. M. Putri, “Studi komparasi HE dan CLAHE pada image enhancement untuk segmentasi citra dalam deteksi tumor pada otak,” *Telekontran J. Ilm. Telekomun. Kendali dan Elektron. Terap.*, vol. 13, no. 2, pp. 298–307, 2025, doi: 10.34010/telekontran.v13i2.18163.
- [23] A. N. Nafisa, E. N. D. B. Purba, F. A. A. Harahap, and N. A. Putri, “Implementasi algoritma convolutional neural network arsitektur model MobileNetV2 dalam klasifikasi penyakit tumor otak glioma, pituitary dan meningioma,” *J. Teknol. Informasi, Komputer, dan Apl. (JTIKA)*, vol. 5, no. 1, pp. 53–61, 2023, doi: 10.29303/jtika.v5i1.234.
- [24] R. A. Ramadhani, B. W. Pangestu, and R. Purbaningtyas, “Klasifikasi tumor otak menggunakan convolutional neural network,” *J. Sist. Informasi, Teknol. Inform. dan Komput.*, vol. 11, no. 3, pp. 55–59, 2021, doi: https://doi.org/10.24853/justit.12.3.55-59.

- [25] S. B. Boly and M. Akbar, "Segmentasi citra sel darah menggunakan convolutional neural network," *J. RESTIKOM Ris. Tek. Inform. dan Komput.*, vol. 6, no. 2, pp. 390–398, 2024, doi: 10.52005/restikom.v6i2.336.
- [26] A. Alenezi, A. Mayya, M. Alajmi, W. Almutairi, D. Alaradah, and H. Alhamad, "Application of the U-Net deep learning model for segmenting single-photon emission computed tomography myocardial perfusion images," *Diagnostics*, vol. 14, no. 24, pp. 1–24, 2024, doi: 10.3390/diagnostics14242865.
- [27] S. A. S. Mola, B. O. D. K. Wadu, A. N. Kenlopo, and V. C. K. Tungga, "Perbandingan arsitektur ResNet50V2, InceptionV3, dan DenseNet121 dalam klasifikasi pengenalan ekspresi wajah," *JIKO (Jurnal Inform. dan Komputer)*, vol. 9, no. 2, p. 285, 2025, doi: 10.26798/jiko.v9i2.1584.
- [28] M. A. Anwar, Y. A. Gerhana, and U. Syaripudin, "Klasifikasi pneumonia pada citra X-Ray menggunakan CNN ResNet50V2 dengan transfer learning," *SMATIKA STIKI Inform. J.*, vol. 15, no. 1, pp. 126–135, 2025, doi: <https://doi.org/10.32664/smatika.v15i01.1538>.
- [29] M. K. U. Ahamed *et al.*, "DTLCx: An improved ResNet architecture to classify normal and conventional pneumonia cases from COVID-19 instances with Grad-CAM-based superimposed visualization utilizing chest X-ray images," *Diagnostics*, vol. 13, no. 3, pp. 1–28, 2023, doi: 10.3390/diagnostics13030551.
- [30] R. Kurniawan, Y. Mulyani, P. B. Wintoro, and M. Komarudin, "Implementasi arsitektur Xception pada model machine learning klasifikasi sampah anorganik," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, pp. 233–236, 2023, doi: 10.23960/jitet.v11i2.3034.
- [31] P. Setiawati, A. S. B. Karno, W. Hastomo, and I. Setiawan, "Menggunakan Xception, transfer learning, dan permutasi untuk meningkatkan klasifikasi ketidaksempurnaan permukaan baja," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, pp. 350–358, 2024, doi: <https://doi.org/10.57152/malcom.v4i1.1258>.
- [32] Darmatasia, "Deteksi penggunaan masker menggunakan Xception transfer learning," *J. INSTEK (Informatika Sains dan Teknol.)*, vol. 5, no. 2, pp. 279–288, 2020, doi: <https://doi.org/10.24252/instek.v5i2.20132>.
- [33] U. Ungkawa and M. Jumentara, "Implementasi Inceptionv4 dalam identifikasi kesegaran daging sapi," *EProceeding Itenas*, pp. 1–9, 2024, [Online]. Available: <https://eproceeding.itenas.ac.id/index.php/fti/article/download/3539/2890>
- [34] S. I. Attaqwa, E. Y. Puspaningrum, and W. S. J. Saputra, "Implementasi contrast limited adaptive histogram equalization dalam pengolahan citra pada algoritma generative adversarial network," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3S1, 2024, doi: 10.23960/jitet.v12i3s1.5316.
- [35] M. Opoku, B. A. Weyori, A. F. Adekoya, and K. Adu, "CLAHE-CapsNet: Efficient retina optical coherence tomography classification using capsule networks with contrast limited adaptive histogram equalization," *PLoS One*, vol. 18, no. 11, November, pp. 1–22, 2023, doi: 10.1371/journal.pone.0288663.
- [36] S. Sudirman, A. Setyanto, and K. Kusnawi, "Perbandingan segmentasi citra seni tari pendet dan seni bela diri pencak silat: pendekatan dengan Multires Unet," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 1608–1614, 2024, doi: 10.23960/jitet.v12i3.4331.
- [37] D. Adriansyah and M. P. K. Putra, "Sistem deteksi objek visual sampah organik dan anorganik berbasis algoritma YOLOv9," *J. Inf. Syst. Res.*, vol. 6, no. 2, pp. 0–9, 2025, doi: 10.47065/josh.v6i2.6454.
- [38] A. Fateh *et al.*, "BRISC: Annotated dataset for brain tumor segmentation and classification," *Sci. Data*, pp. 1–10, 2025, doi: 10.1038/s41597-026-06753-y.
- [39] M. Thahiruddin and A. Wulandari, "CNNs vs. Hybrid transformers for brain tumor classification on the BRISC dataset," *J. Apl. Teknol. Inf. dan Manaj.*, vol. 6, no. 1, pp. 24–33, 2025, doi: 10.31102/jatim.v6i1.3545.
- [40] Z. Kus and M. Aydin, "MedSegBench: A comprehensive benchmark for medical image segmentation in diverse data modalities," *Sci. Data*, vol. 11, no. 1, pp. 1–15, 2024, doi: 10.1038/s41597-024-04159-2.
- [41] T. S. Nabila and A. Salam, "Classification of brain tumors by using a hybrid CNN-SVM model," *J. Appl. Informatics Comput.*, vol. 8, no. 2, pp. 241–247, 2024, doi: 10.30871/jaic.v8i2.8277.
- [42] A. Das and S. Singh, "Few-shot and zero-shot learning for MRI brain tumor classification using CLIP and vision transformers," *Sensors*, vol. 25, no. 23, pp. 1–28, 2025, doi: 10.3390/s25237341.