

IMPLEMENTASI ENHANCED PREPROCESSING PADA SEGMENTASI AREA TUMOR OTAK CITRA MRI MENGGUNAKAN YOLOV8-SEG

Ananda Bagus Fatchurroziq, Muhammad Najibulloh Muzaki, Arie Nugroho

Sistem Informasi, Universitas Nusantara PGRI Kediri

Jl. Ahmad Dahlan No.76, Mojoroto, Kec. Mojoroto, Kota Kediri, Jawa Timur 64112

nandabgs13@gmail.com

ABSTRAK

Tumor otak membutuhkan diagnosis akurat melalui pencitraan *Magnetic Resonance Imaging* (MRI) T1-CE. Namun, tingginya *noise* intensitas dan batas lesi bergradasi halus (*fuzzy boundaries*) pada citra tersebut sering menurunkan akurasi algoritma segmentasi otomatis. Penelitian ini bertujuan mengevaluasi dampak teknik *enhanced preprocessing* (kombinasi CLAHE, *Bilateral Filter*, Z-Score) pada arsitektur YOLOv8-SEG terhadap tingkat akurasi segmentasi. Metode penelitian menggunakan 3.064 citra dari 233 pasien yang dipartisi melalui *Patient-Level Split* untuk mencegah kebocoran data. Pemodelan dieksekusi dalam dua skenario: *Baseline* (citra mentah) dan *Enhanced* (citra berfilter). Hasil pengujian menunjukkan fenomena *trade-off* performa. Skenario *Enhanced* unggul dalam *Precision* (0.86026) yang secara efektif menekan deteksi palsu. Sebaliknya, skenario *Baseline* lebih superior pada metrik spasial dengan *Dice Similarity Coefficient* (0.7583), *Recall* (0.84461), dan mAP50 (0.89718) karena sukses mempertahankan piksel transisi batas lesi yang pudar. Kesimpulannya, model *Enhanced* andal sebagai penapis deteksi awal, sementara model *Baseline* optimal untuk mendelineasi batas poligon secara presisi.

Kata kunci : Tumor Otak, Segmentasi, YOLOv8-SEG, Preprocessing, MRI

1. PENDAHULUAN

Tumor otak merupakan salah satu penyakit dengan tingkat kompleksitas tinggi yang dapat menimbulkan gangguan neurologis serius, seperti defisit visual, kelemahan motorik, hingga kematian jika tidak ditangani secara cepat dan tepat [1]. Proses diagnosis penyakit ini sangat bergantung pada evaluasi pencitraan medis, terutama *Magnetic Resonance Imaging* (MRI), karena modalitas pencitraan ini mampu menampilkan struktur jaringan lunak otak dengan tingkat kontras yang sangat [2]. Pada pemeriksaan klinis, sekuens MRI *T1-weighted Contrast-Enhanced* (T1-CE) menjadi standar emas (*gold standard*). Hal ini dikarenakan area lesi tumor biasanya tampak lebih terang atau hiperintens akibat penyerapan agen kontras gadolinium melalui pembatas darah-otak yang rusak [3]. Walaupun lesi terlihat jelas, dokter spesialis radiologi tetap harus melakukan delineasi atau segmentasi batas tumor secara manual pada setiap potongan irisan (*slice*) citra untuk merencanakan tindakan pembedahan atau radioterapi [4]. Proses pengerjaan manual ini memakan waktu yang sangat lama, menguras tenaga, dan memiliki tingkat subjektivitas yang tinggi karena interpretasi batas lesi dapat berbeda antara satu dokter dengan dokter lainnya [4].

Selain faktor *human error*, tantangan teknis pada citra medis juga menjadi hambatan. Variasi kualitas citra akibat perbedaan kalibrasi antar instrumen MRI, keberadaan *noise* atau derau intensitas, serta bentuk anatomi tumor yang sangat tidak beraturan dan memiliki tepi gradasi halus (*fuzzy boundaries*) memperumit proses segmentasi [5]. Oleh sebab itu, dibutuhkan sebuah sistem otomatisasi cerdas yang mampu mendeteksi dan melakukan segmentasi tumor

secara cepat, stabil, dan konsisten guna menunjang produktivitas pakar medis. Perkembangan pesat di bidang kecerdasan buatan, khususnya *Deep Learning* dengan basis *Convolutional Neural Network* (CNN), telah menghadirkan solusi yang menjanjikan untuk visi komputer medis[5].

Sebagai studi komparasi utama, penelitian terdahulu telah mengusulkan pendekatan sistem deteksi tumor menggunakan arsitektur MobileNetV2-SSD yang dikombinasikan dengan modifikasi jaringan *Feature Pyramid Network* (FPN) [6]. Meskipun pendekatan algoritma tersebut mampu menghasilkan akurasi lokalisasi yang sangat baik, metode *Single Shot Detector* (SSD) memiliki batasan inheren, yaitu hanya berorientasi pada deteksi objek dalam bentuk kotak pembatas (*bounding box*) [6]. Representasi berbasis kotak ini dinilai kurang optimal jika digunakan untuk memetakan bentuk massa tumor yang cenderung sangat acak dan tidak beraturan (*irregular*) secara presisi piksel per piksel [7].

Seiring dengan kemajuan algoritma deteksi, muncul varian arsitektur terbaru dari keluarga *You Only Look Once* (YOLO), yaitu YOLOv8-SEG, yang difokuskan secara spesifik untuk menangani tugas *instance segmentation* [8]. Arsitektur ini memiliki kapabilitas ganda untuk mengidentifikasi keberadaan objek sekaligus menghasilkan *mask* (masker) poligon piksel secara langsung, menjadikannya kandidat yang jauh lebih relevan untuk segmentasi citra onkologi [7]. Dalam penelitian ini, dataset yang digunakan diekstraksi dari Cheng Brain Tumor Dataset yang terdiri atas 3.064 citra MRI T1-CE dari 233 pasien [9]. Untuk menanggulangi kelemahan kualitas visual MRI, penelitian ini mengusulkan sebuah *pipeline* manipulasi piksel bernama *enhanced preprocessing* yang

mencakup integrasi CLAHE, *bilateral filtering*, serta normalisasi intensitas Z-Score [10].

Penelitian ini bertujuan untuk membandingkan performa segmentasi citra mentah dengan citra hasil pra-pemrosesan, serta mengimplementasikannya ke dalam purwarupa aplikasi *Computer-Aided Diagnosis* (CAD) interaktif untuk membuktikan kelayakan operasional sistem.

2. TINJAUAN PUSTAKA

Tinjauan Pustaka dalam penelitian ini digunakan sebagai landasan ilmiah untuk mendukung pengembangan sistem segmentasi tumor otak. Kajian yang dilakukan meliputi teori pendukung dan metode penelitian. Adapun teori yang dikaji dalam penelitian ini meliputi:

2.1. Citra MRI T1-CE

Citra digital sering kali mengalami degradasi kualitas visual seperti kontras yang rendah, kehadiran *noise* impulsif, hingga pencahayaan yang tidak merata [11]. Pada domain neuro-onkologi, MRI T1-CE menjadi pilihan utama karena agen kontras gadolinium membuat area lesi tampak hiperintens setelah menembus jaringan pembatas [2]. Namun, kelemahan mendasar dari MRI adalah citra diekspresikan dalam satuan arbitrer (tidak memiliki nilai numerik absolut), sehingga sangat bervariasi antar subjek dan waktu pemeriksaan akibat perbedaan kalibrasi perangkat keras [3]. Variasi distribusi intensitas antar citra tanpa langkah normalisasi dapat mendominasi proses pembelajaran gradien fitur dan menurunkan stabilitas pelatihan pada jaringan saraf konvolusional [5].

2.2. Enhanced Preprocessing

Enhanced preprocessing merupakan rangkaian teknik manipulasi ruang warna dan intensitas piksel untuk memperbaiki distribusi histogram serta mengurangi derau tanpa merusak fitur penting dari sebuah citra medis [10]. Rangkaian tahapan yang dieksperimentalkan dalam penelitian ini disusun secara berurutan dan meliputi:

- CLAHE (*Contrast Limited Adaptive Histogram Equalization*): CLAHE adalah evolusi dari metode perataan histogram (AHE). CLAHE beroperasi secara adaptif pada sub-area lokal citra (*tiles*) dan secara spesifik membatasi proses amplifikasi kontras melalui *threshold clip limit* [12]. Pembatasan matematis ini sangat krusial karena AHE konvensional cenderung memperkuat tingkat *noise* secara berlebihan pada area citra yang memiliki intensitas warna homogen [13].
- Bilateral Filtering: Setelah kontras dinaikkan oleh CLAHE, citra sering kali memunculkan efek derau sekunder. *Bilateral filtering* hadir sebagai solusi pendekatan filter spasial non-linear yang sangat andal dalam meredam *noise* spasial tanpa mengaburkan ketajaman garis batas anatomi objek atau yang sering disebut sebagai karakteristik *edge-preserving* [14].

- Normalisasi Z-Score: Teknik standarisasi ini beroperasi pada tingkat piksel global untuk mendistribusikan ulang nilai intensitas agar memiliki nilai rata-rata (*mean*) nol dan variansi standar deviasi satu [15]. Secara komputasional, rumusan konversi standarisasi Z-Score disajikan pada Persamaan (1):

$$I_{z\text{-score}}(x) = \frac{I(x) - \mu}{\sigma}$$

2.3. YOLOv8-SEG dan Metrik Evaluasi

Instance segmentation merupakan cabang mahir dari visi komputer yang menyatukan fungsi deteksi objek lokalisasi dengan segmentasi semantik, memungkinkan model untuk mengidentifikasi objek sekaligus menggambar masker poligon untuk setiap entitas unik [7]. Ultralytics meluncurkan YOLOv8-SEG dengan pembaruan pada modul koneksi fitur C2f (*Cross Stage Partial Network*) dan *anchor-free split head*, yang memisahkan komputasi prediksi kelas objek dari komputasi regresi kotak pembatas dan poligon [8].

Untuk mengukur tingkat keandalan luaran segmentasi, evaluasi tidak dapat hanya bergantung pada akurasi biner. Penilaian medis menggunakan *Dice Similarity Coefficient* (DSC) untuk mengukur rasio luas tumpang tindih (*overlap*) antara area poligon hasil tebakan kecerdasan buatan dengan luas arsir poligon asli buatan ahli medis [16]. Metrik *Mean Average Precision* (mAP) digunakan untuk mengukur konsistensi ketepatan lokalisasi pada beberapa ambang batas IoU [17]. Sementara itu, tingkat diskriminasi model diukur melalui persentase keberhasilan (*Recall*) dan ketepatan spesifik pendeteksian tanpa alarm palsu (*Precision*) [18].

2.4. Penelitian Terdahulu

Penelitian yang dilakukan oleh Hikmah mengusulkan pendekatan sistem deteksi tumor menggunakan arsitektur MobileNetV2-SSD yang dikombinasikan dengan modifikasi jaringan *Feature Pyramid Network* (FPN) [6]. Hasil penelitian menunjukkan bahwa metode tersebut mampu mendeteksi jenis tumor meningioma dengan nilai *Recall* mencapai 98% dan *Precision* 89%. Namun, pendekatan SSD berorientasi pada deteksi kotak pembatas (*bounding box*), sedangkan penelitian ini menggunakan metode *instance segmentation* dengan algoritma YOLOv8-SEG untuk memetakan bentuk tumor otak yang tidak beraturan secara presisi piksel per piksel.


Penelitian yang dilakukan oleh Ardiansyah membahas pemanfaatan model YOLOv8 untuk deteksi dan segmentasi citra MRI tumor otak [7]. Hasil penelitian tersebut membuktikan bahwa arsitektur YOLOv8 memiliki kapabilitas lokalisasi dan pembuatan masker poligon yang sangat efisien dan akurat untuk objek medis. Berbeda dengan penelitian tersebut yang langsung menggunakan citra standar, penelitian ini menambahkan penerapan manipulasi

enhanced preprocessing (kombinasi CLAHE, *Bilateral Filter*, dan *Z-Score*) sebelum tahap pelatihan untuk mengatasi kelemahan batas tepi lesi tumor yang bergradasi halus (*fuzzy boundaries*).

Penelitian yang dilakukan oleh Arora menerapkan segmentasi tumor otak berbasis citra terproses (*processed image*) menggunakan arsitektur segmentasi semantik U-Net [16]. Hasil penelitian menunjukkan bahwa pra-pemrosesan citra medis sangat berpengaruh dalam mendongkrak ketepatan ukuran tumpang-tindih area *Dice Similarity Coefficient* (DSC). Sedangkan penelitian ini menggunakan pendekatan arsitektur *single-stage* YOLOv8-SEG dan difokuskan pada analisis komparatif performa (*trade-off*) antara penggunaan citra mentah (*Baseline*) melawan citra berfilter (*Enhanced*) untuk mengevaluasi ketahanan model terhadap hilangnya fitur spasial.

3. METODE PENELITIAN

Pengembangan sistem kecerdasan buatan pada penelitian ini dilandasi oleh kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM) [19]. Pemilihan CRISP-DM didasarkan pada strukturnya yang komprehensif, logis, dan iteratif sehingga sangat sesuai untuk menstandarisasi langkah-langkah implementasi proyek berbasis rekayasa data medis yang sensitif [20].



Gambar 1. Alur Metodologi CRISP-DM

3.1. Business Understanding (Pemahaman Masalah)

Pada tahap perumusan masalah awal, peneliti mendalami tantangan analitis yang dihadapi oleh dokter patologi dan radiologi terkait proses delineasi manual tumor otak yang memakan waktu [4]. Analisis dilanjutkan dengan melakukan bedah dataset. Data yang digunakan bersumber dari basis data publik Cheng Brain Tumor Dataset, yang tersimpan dalam format berkas biner .mat [9]. Dataset ini memuat 3.064 citra dari 233 pasien yang mengalami kasus glioma, meningioma, dan tumor pituitari [9].

3.2. Data Understanding (Pemahaman Data)

Dataset yang digunakan dalam eksperimen ini adalah *Cheng Brain Tumor Dataset* yang memuat total

3.064 citra *Magnetic Resonance Imaging* (MRI) sekuens *T1-weighted Contrast-Enhanced* (T1-CE) dari 233 subjek pasien. Karakteristik data dieksplorasi secara komputasional untuk memetakan tantangan visual yang ada, seperti adanya variasi kontras antar mesin pemindai, dominasi luasan latar belakang (*background*) hitam pekat di luar tengkorak, serta kondisi batas luar tumor yang pudar atau bergradasi halus (*fuzzy boundaries*).

3.3. Data Preparation (Preparasi Data)

Tahap preparasi data merupakan bagian paling krusial dalam penelitian ini, di mana data ditransformasikan melalui urutan strategis sebagai berikut:

- Ekstraksi Data: Pasangan citra MRI dan masker (*mask*) segmentasi asli diekstrak dari format berkas dasar .mat.
- Enhanced Preprocessing: Citra diproses melalui *pipeline* penajaman terpadu. Pertama, CLAHE diterapkan dengan *clip limit* 1.2 untuk menaikkan kontras lokal tanpa *over-exposure*. Kedua, *Bilateral Filter* digunakan untuk mereduksi *noise* impulsif hasil sampingan CLAHE dengan tetap mempertahankan ketegasan garis tepi anatomi (*edge-preserving*). Ketiga, normalisasi intensitas *Robust Z-Score* berbasis *Brain-Masking* diimplementasikan untuk menyetarakan distribusi nilai piksel agar memiliki rata-rata nol dan variansi satu.
- Format Koordinat: Masker biner *ground truth* dikonversi menjadi titik-titik koordinat poligon sesuai dengan regulasi format masukan YOLOv8-SEG.
- Patient-Level Split: Guna menghindari bias kebocoran data (*data leakage*), partisi dataset dibagi berdasarkan identitas unik pasien, bukan mengacak gambar secara serampangan. Sebanyak 233 pasien dibagi secara proporsional menjadi 70% data latih (2.090 citra), 20% data validasi (674 citra), dan 10% data uji (304 citra).

3.4. Modeling (Pemodelan)

Proses pelatihan menggunakan arsitektur YOLOv8s-SEG dijalankan secara paralel *ceteris paribus* (hiperparameter sama persis) untuk membandingkan dua skenario konfirmatif: skenario *Baseline* (menggunakan citra mentah dengan normalisasi min-max dasar) dan skenario *Enhanced* (menggunakan citra hasil *pipeline preprocessing*). Kedua model dilatih menggunakan akselerasi GPU NVIDIA Tesla P100 selama 100 *epochs*, dengan *batch size* 16, resolusi citra input 512x512 piksel, serta diperkuat oleh teknik augmentasi spasial (*mosaic*, *flip*, *rotation*, dan *scaling*).

3.5. Evaluation (Evaluasi)

Kinerja dari kedua model segmentasi diuji secara ketat menggunakan 304 citra data uji murni (*unseen data*). Tingkat keberhasilan pendeteksian objek diukur

melalui metrik *Precision*, *Recall*, *mAP50*, dan *mAP50-95*. Sementara itu, tingkat keakuratan tumpang-tindih luasan piksel poligon segmentasi secara geometris dihitung menggunakan metrik *Dice Similarity Coefficient* (DSC) terhadap masker referensi asli dari pakar medis.

3.6. Deployment (Penerapan)

Sistem model terbobot yang sudah dievaluasi tidak dibiarkan sebagai baris kode *backend* semata. Hasil diekspor dan diintegrasikan ke dalam lingkungan web aplikasi antarmuka pengguna grafis atau GUI dengan memanfaatkan pustaka *open-source* Streamlit. Modul ini memungkinkan dokter untuk melakukan unggah berkas MRI mandiri dan menyaksikan *rendering* prediktif segmentasi tumor secara langsung.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pelatihan Model (Modeling)

Selama proses pelatihan berlangsung sepanjang 100 *epochs*, performa internal dari kedua skenario terpantau berjalan secara ideal. Berdasarkan visualisasi log kurva pelatihan pada gambar hasil *training*, nilai kerugian segmentasi (*segmentation loss*) dan kerugian kotak pembatas (*box loss*) baik pada set data latih maupun set data validasi terus mengalami grafik penurunan yang melandai secara konsisten. Karakteristik kurva yang stabil dan konvergen ini membuktikan secara empiris bahwa jaringan saraf konvolusional YOLOv8-SEG sukses mengekstraksi fitur anatomi tumor otak dengan matang dan sepenuhnya terhindar dari indikasi *overfitting*.

4.2. Hasil Pengujian Kuantitatif Data Uji

Setelah proses pemodelan selesai, pengujian performa sesungguhnya dilakukan dengan mengeksekusi inferensi otomatis terhadap 304 citra pengujian pasien baru. Rekapitulasi perbandingan nilai metrik yang diproduksi oleh skenario *Baseline Model* dan *Enhanced Model* disajikan pada Tabel 1:

Tabel 1. Perbandingan metrik evaluasi model

Metrik Evaluasi	Baseline Model	Enhanced Model
Precision	0.83996	0.86026
Recall	0.84461	0.83282
mAP50	0.89718	0.87759
mAP50-95	0.59812	0.57849
DSC	0.7583	0.7350

Berdasarkan paparan data pada Tabel 1, dapat dianalisis bahwa penerapan teknik *Enhanced Preprocessing* memberikan pengaruh yang bervariasi dan memicu munculnya fenomena *trade-off* (tarik-ulur) performa metrik yang menarik secara saintifik.

Dari aspek spesifisitas deteksi instans, *Enhanced Model* mencatatkan keunggulan mutlak pada metrik *Precision* dengan skor sebesar 0.86026, mengungguli *Baseline Model* yang berada di angka 0.83996.

Lompatan nilai presisi ini mengonfirmasi secara valid bahwa integrasi penajaman kontras adaptif lokal (CLAHE) berhasil menyingkirkan komponen artefak *noise* latar belakang yang kerap membingungkan model. Dengan demikian, model *Enhanced* memiliki kemampuan yang sangat tinggi dalam mereduksi angka alarm palsu (*False Positive*), memastikan jaringan otak yang sehat tidak akan didiagnosis secara keliru sebagai area lesi tumor (*over-diagnosis*).



Namun secara kontradiktif, *Baseline Model* terbukti memimpin secara superior pada mayoritas metrik jangkauan dan kecocokan spasial piksel. Model *Baseline* unggul pada nilai *Recall* sebesar 0.84461, *mAP50* sebesar 0.89718, serta nilai kedekatan geometris poligon *Dice Similarity Coefficient* (DSC) mencapai 0.7583.


4.3. Analisis Pembahasan Fenomena Spasial (DSC)

Terjadinya penurunan nilai metrik DSC pada skenario *Enhanced* menjadi temuan teoritis yang sangat berharga dalam implementasi *computer vision* medis. Secara kualitatif, kondisi batas luar tumor pada citra MRI T1-CE sejatinya tidak berbentuk garis tegas, melainkan berupa gradasi kabur halus (*fuzzy boundaries*) akibat infiltrasi sel tumor ke jaringan sekitarnya.

Ketika citra diproses menggunakan *Bilateral Filter*—yang secara matematis dirancang untuk mereduksi fluktuasi intensitas piksel minor—algoritma filter secara keliru menganggap area gradasi pudar di batas luar tumor tersebut sebagai sebuah *noise* intensitas. Akibatnya, area transisi halus tersebut dihaluskan secara paksa hingga menyatu dengan intensitas jaringan otak normal. Dampaknya, arsitektur YOLOv8-SEG menjadi terlalu konservatif; model hanya mengekstraksi dan menyegmentasi area inti tumor (*core tumor*) yang benar-benar solid hiperintens. Hal ini membuat ukuran poligon masker segmentasi yang diproduksi oleh model *Enhanced* mengalami penyusutan geometris. Sebaliknya, *Baseline Model* yang membiarkan citra MRI tetap berada pada kondisi aslinya tanpa filter, jauh lebih sensitif dalam menangkap sisa-sisa piksel transisi samar di batas luar lesi. Kemampuan ini membuat masker milik *Baseline* menghasilkan persentase irisan tumpang-tindih yang lebih luas dan presisi tinggi mendekati cetak biru *ground truth* asli dokter radiologi.

Tabel 2. Perbandingan Hasil Prediksi dengan Ground Truth

Ground Truth	Baseline Model	Enhanced Model
Ground Truth (Dokter)	Baseline (DSC: 0.7583)	Enhanced (DSC: 0.7350)
		



Gambar 2. Antarmuka aplikasi Segmentasi Area tumor otak

Sebagai perwujudan fase *Deployment*, bobot model optimal yang dihasilkan dari riset ini diintegrasikan ke dalam antarmuka grafis interaktif berbasis web menggunakan Streamlit. Melalui dasbor interaktif ini, citra MRI masukan dapat diproses secara

real-time untuk menampilkan garis pembatas segmentasi secara aktual, membuktikan bahwa luaran penelitian ini sangat potensial diadopsi sebagai perangkat bantu kerja praktis dokter spesialis radiologi di masa depan.

4.4. Pengujian Sistem

Tahap pengujian dilakukan untuk memastikan bahwa seluruh fungsi dan fitur pada purwarupa aplikasi *Computer-Aided Diagnosis* (CAD) berbasis Streamlit dapat berjalan sesuai dengan kebutuhan interaksi pengguna. Pengujian difokuskan pada metode *black-box testing* dengan memeriksa fungsionalitas unggah citra, penyesuaian parameter, hingga proses *rendering* hasil prediksi model YOLOv8-SEG. Berikut adalah rekapitulasi hasil pengujian sistem:

Tabel 3. Pengujian Fungsionalitas Unggah Citra

Pengujian	Hasil yang Diharapkan	Hasil Pengujian	Kesimpulan
Mengunggah file citra MRI dengan format yang didukung (.jpg / .png)	Sistem menerima file dan citra MRI asli langsung ditampilkan pada panel pratinjau antarmuka	Citra berhasil diunggah dan ditampilkan dengan resolusi yang proporsional	Berhasil
Mengunggah file dengan format tidak valid (misal: .pdf atau .docx)	Sistem menolak file dan menampilkan pesan peringatan ekstensi tidak didukung	Sistem memunculkan pesan <i>error</i> dan meminta pengguna mengunggah format gambar	Berhasil

Tabel 4. Pengujian Pengaturan Parameter Inferensi

Pengujian	Hasil yang Diharapkan	Hasil Pengujian	Kesimpulan
Menggeser <i>slider Confidence Threshold</i> (misal dari 0.25 ke 0.50)	Nilai parameter batas keyakinan minimum berubah secara <i>real-time</i> dan tersimpan di sistem	Nilai parameter berhasil berubah sesuai dengan pergeseran <i>slider</i> oleh pengguna	Berhasil
Memilih skenario model prediksi (<i>Baseline</i> atau <i>Enhanced</i>) melalui <i>Radio Button</i>	Sistem memuat bobot arsitektur model (best.pt) sesuai dengan opsi yang diklik	Sistem berhasil mengganti mesin inferensi (<i>engine</i>) tanpa terjadi <i>crash</i>	Berhasil

Tabel 5. Pengujian Proses Segmentasi Tumor

Pengujian	Hasil yang Diharapkan	Hasil Pengujian	Kesimpulan
Menjalankan proses deteksi pada citra MRI yang memiliki lesi tumor	Sistem memproses gambar dan menampilkan area masker (<i>mask</i>) poligon beserta nilai <i>confidence</i> di atas lesi	Masker biru poligon dan kotak pembatas (<i>bounding box</i>) berhasil digambar secara presisi	Berhasil
Menjalankan proses deteksi pada citra otak normal (tanpa tumor)	Sistem tidak menampilkan poligon apapun dan mengeluarkan notifikasi tumor tidak ditemukan	Sistem berhasil mendeteksi ketiadaan objek dan tidak memunculkan deteksi palsu	Berhasil

5. KESIMPULAN DAN SARAN

Penerapan teknik *enhanced preprocessing* pada arsitektur YOLOv8s-SEG terbukti menghadirkan efek *trade-off* performa klinis. Manipulasi filternya sukses mendongkrak nilai *Precision* hingga 0.86026 untuk mengeliminasi maldiagnosis (*over-diagnosis*), namun mengorbankan ketepatan tumpang-tindih kontur tepi luar tumor dengan penurunan nilai DSC menjadi 0.7350 dibandingkan model *Baseline* yang mencatatkan skor superior sebesar 0.7583. Untuk pengembangan sistem diagnosis riil, direkomendasikan penggunaan arsitektur sekuensial *Dual-Engine* CAD yang menempatkan model *Enhanced* sebagai penapis lokasi awal, dilanjutkan

dengan model *Baseline* untuk melakukan penarikan poligon batas luar tumor secara presisi.

DAFTAR PUSTAKA

- [1] D. N. Louis *et al.*, "The 2016 World Health Organization Classification of Tumors of the Central Nervous System: a summary," Jun. 01, 2016, Springer Verlag. doi: 10.1007/s00401-016-1545-1.
- [2] G. Shukla *et al.*, "Advanced magnetic resonance imaging in glioblastoma: a review," *Chin. Clin. Oncol.*, vol. 6, no. 4, pp. 40–40, Aug. 2017, doi: 10.21037/cco.2017.06.28.
- [3] R. T. Shinohara *et al.*, "Statistical normalization techniques for magnetic resonance imaging,"

- Neuroimage Clin.*, vol. 6, pp. 9–19, 2014, doi: 10.1016/j.nicl.2014.08.008.
- [4] N. Gordillo, E. Montseny, and P. Sobrevilla, “State of the art survey on MRI brain tumor segmentation,” *Magn. Reson. Imaging*, vol. 31, no. 8, pp. 1426–1438, Oct. 2013, doi: 10.1016/j.mri.2013.05.002.
- [5] G. Litjens *et al.*, “A survey on deep learning in medical image analysis,” *Med. Image Anal.*, vol. 42, pp. 60–88, Dec. 2017, doi: 10.1016/j.media.2017.07.005.
- [6] N. F. Hikmah, A. D. Hajjanto, A. F. A. Surbakti, N. A. Prakosa, T. Asmaria, and T. A. Sardjono, “Brain tumor detection using a MobileNetV2-SSD model with modified feature pyramid network levels,” *International Journal of Electrical and Computer Engineering*, vol. 14, no. 4, pp. 3995–4004, 2024, doi: 10.11591/ijece.v14i4.pp3995-4004.
- [7] A. Ardiansyah, K. N. Qodri, D. Al Banna, and M. Z. Al-Baihaqi, “PEMANFAATAN SAM DAN YOLOV8 UNTUK DETEKSI DAN SEGMENTATION MRI TUMOR OTAK,” *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, vol. 5, no. 1, pp. 82–89, Jun. 2024, doi: 10.46764/teknimedia.v5i1.192.
- [8] J. Terven, D.-M. Córdova-Esparza, and J.-A. Romero-González, “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS,” *Mach. Learn. Knowl. Extr.*, vol. 5, no. 4, pp. 1680–1716, Nov. 2023, doi: 10.3390/make5040083.
- [9] J. Cheng *et al.*, “Correction: Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition,” *PLoS One*, vol. 10, no. 12, p. e0144479, Dec. 2015, doi: 10.1371/journal.pone.0144479.
- [10] A. Nugroho, A. Husin, J. Provinsi, T. Hulu, and I. Hilir Indonesia, “SISTEMASI: Jurnal Sistem Informasi Analisis Performa Random Forest Menggunakan Normalisasi Atribut Performance Analysis of Random Forest Using Attribute Normalization,” Dec. 2019. [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [11] M. T. Al Kautsar, E. Cahyono, and Jufra, “Jurnal Matematika , Komputasi dan Statistika PENERAPAN KONSEP FUNGSI CONTRAST STRETCHING TERHADAP PENAJAMAN KONTRAS CITRA DIGITAL Diterbitkan oleh Jurusan Matematika FMIPA UHO Jurnal Matematika , Komputasi dan Statistika Diterbitkan oleh Jurusan Matematik,” vol. 5, no. April, pp. 857–867, 2025.
- [12] Md. Nahiduzzaman *et al.*, “Parallel CNN-ELM: A multiclass classification of chest X-ray images to identify seventeen lung diseases including COVID-19,” *Expert Syst. Appl.*, vol. 229, p. 120528, Nov. 2023, doi: 10.1016/j.eswa.2023.120528.
- [13] V. Magudeeswaran and J. F. Singh, “Contrast limited fuzzy adaptive histogram equalization for enhancement of brain images,” *Int. J. Imaging Syst. Technol.*, vol. 27, no. 1, pp. 98–103, Mar. 2017, doi: 10.1002/ima.22214.
- [14] B. H. Menze *et al.*, “The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS),” *IEEE Trans. Med. Imaging*, vol. 34, no. 10, pp. 1993–2024, Oct. 2015, doi: 10.1109/TMI.2014.2377694.
- [15] J. C. Reinhold, B. E. Dewey, A. Carass, and J. L. Prince, “Evaluating the impact of intensity normalization on MR image synthesis,” in *Medical Imaging 2019: Image Processing*, E. D. Angelini and B. A. Landman, Eds., SPIE, Mar. 2019, p. 126. doi: 10.1117/12.2513089.
- [16] A. Arora, A. Jayal, M. Gupta, P. Mittal, and S. C. Satapathy, “Brain tumor segmentation of MRI images using processed image driven u-net architecture,” *Computers*, vol. 10, no. 11, Nov. 2021, doi: 10.3390/computers10110139.
- [17] H. Alanazi, “Optimizing Medical Image Analysis: A Performance Evaluation of YOLO-Based Segmentation Models,” 2025. [Online]. Available: www.ijacsa.thesai.org
- [18] D. Müller, I. Soto-Rey, and F. Kramer, “Towards a guideline for evaluation metrics in medical image segmentation,” Dec. 01, 2022, *BioMed Central Ltd.* doi: 10.1186/s13104-022-06096-y.
- [19] C. Schröer, F. Kruse, and J. M. Gómez, “A systematic literature review on applying CRISP-DM process model,” *Procedia Comput. Sci.*, vol. 181, no. 2019, pp. 526–534, 2021, doi: 10.1016/j.procs.2021.01.199.
- [20] A. Rianti, N. W. A. Majid, and A. Fauzi, “CRISP-DM: Metodologi Proyek Data Science,” *Prosiding Seminar Nasional Teknologi Informasi dan Bisnis (SENATIB)*, pp. 107–114, 2023