

SURAT KETERANGAN BEBAS PLAGIARISME



Universitas Nusantara PGRI Kediri
UPT. PERPUSTAKAAN, PUBLIKASI DAN INOVASI
Alamat: Kampus 1, Jl. KH. Ahmad Dahlan No.76 Kota Kediri 64112
Telp. (0354) 771576, (0354) 771503, (0354) 771495, Fax. (0354) 771576
Website: <http://ppi.unpkediri.ac.id/> Email: perpustakaan@unpkediri.ac.id

SURAT KETERANGAN BEBAS SIMILARITY

Ketua UPT Perpustakaan, Publikasi dan Inovasi Universitas Nusantara PGRI Kediri menerangkan bahwa mahasiswa dengan identitas berikut:

Nama Mahasiswa : Ananda Bagusfatchurroziq
NPM : 2213030014
Program Studi : S1-Sistem Informasi

Judul Karya Ilmiah:

“Implementasi Enhanced Preprocessing Pada Segmentasi Area Tumor Otak MRI Menggunakan YOLOv8-SEG”

Dinyatakan sudah memenuhi syarat batas maksimal 30% *similarity* sesuai dengan ketentuan yang berlaku pada setiap subbab naskah Laporan **Tugas Akhir/Skripsi/Tesis** yang disusun.

Demikian Surat Keterangan ini kami berikan untuk dapat dipergunakan seperlunya.



Kediri, 22 Juni 2026
Ka UPT PPI,



Dr. Abdul Aziz Hunaifi, M.A

Turnitin LLCC

ANANDA BAGUS FATCHURROZIQ SKRIPSI.docx

 SI-12

Document Details

Submission ID

trn:oid::2945:394253627

Submission Date

Jun 19, 2026, 4:17 PM GMT+7

Download Date

Jun 19, 2026, 4:27 PM GMT+7

File Name

ANANDA BAGUS FATCHURROZIQ SKRIPSI.docx.pdf

File Size

2.5 MB

38 Pages

6,763 Words

45,203 Characters

9% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography

Top Sources

- 4%  Internet sources
- 2%  Publications
- 8%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

- 4% Internet sources
- 2% Publications
- 8% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	kc.umn.ac.id	<1%
2	Student papers	Perpustakaan on 2025-08-06	<1%
3	Student papers	UPN Veteran Yogyakarta on 2026-04-22	<1%
4	Student papers	Universitas Pancasila on 2025-08-07	<1%
5	Student papers	Telkom University on 2025-07-04	<1%
6	Student papers	Universitas Sumatera Utara on 2025-05-23	<1%
7	Student papers	Universitas Trisakti FTKE-FTSP-FTI-FALTL-FH-FSRD on 2025-10-18	<1%
8	Student papers	UPN Veteran Yogyakarta on 2026-05-25	<1%
9	Publication	Andreas Rezeki Zai, Bambang Suhardi, Surya Tri Nowo, Rika Rosnelly, Adil Setiaw...	<1%
10	Student papers	UPN Veteran Yogyakarta on 2026-06-02	<1%
11	Student papers	Universitas Katolik Widya Mandala Surabaya on 2025-12-16	<1%

12	Student papers	Universitas Muhammadiyah Sukabumi on 2026-01-20	<1%
13	Publication	Nur Azizah, Agung Widhi Kurniawan, Burhanuddin Burhanuddin, Muh. Ikhwan M...	<1%
14	Publication	Ardiansyah Ardiansyah, Krisna Nuresa Qodri, Dion Al Banna, Muhammad Zulfikh...	<1%
15	Student papers	UPN Veteran Yogyakarta on 2026-06-02	<1%
16	Student papers	Universitas Sebelas Maret on 2019-05-12	<1%
17	Internet	repository.uinsaizu.ac.id	<1%
18	Student papers	Perpustakaan on 2025-08-07	<1%
19	Student papers	Universitas Muhammadiyah Surakarta on 2014-01-02	<1%
20	Internet	ejournal.ikmi.ac.id	<1%
21	Publication	Anda Putra. "Klasifikasi Penyakit Daun Cabai Dengan Metode CNN Untuk Deteksi ...	<1%
22	Student papers	Telkom University on 2025-07-08	<1%
23	Internet	id.scribd.com	<1%
24	Internet	jurnal.stkipppgritulungagung.ac.id	<1%
25	Internet	repository.trisakti.ac.id	<1%

26	Internet	123dok.com	<1%
27	Internet	repository.its.ac.id	<1%
28	Student papers	UPN Veteran Yogyakarta on 2026-05-05	<1%
29	Student papers	Universitas Islam Indonesia on 2026-06-15	<1%
30	Internet	repository.uph.edu	<1%
31	Internet	www.ejournal.itn.ac.id	<1%
32	Publication	Auliawati Buchari, Steven R. Sentinuwo, Stanley D.S Karouw. "Implementasi Aug...	<1%
33	Student papers	Perpustakaan on 2025-08-07	<1%
34	Student papers	STT PLN on 2023-07-26	<1%
35	Student papers	Sekolah Teknik Elektro & Informatika on 2025-07-23	<1%
36	Student papers	Universitas Airlangga-1 on 2026-03-15	<1%
37	Student papers	Universitas Budi Luhur on 2026-01-31	<1%
38	Student papers	Universitas Islam Riau on 2025-09-02	<1%
39	Student papers	Universitas Islam Riau on 2026-02-27	<1%

40	Student papers	Universitas Islam Riau on 2026-04-02	<1%
41	Internet	anzdoc.com	<1%
42	Internet	core.ac.uk	<1%
43	Internet	ejurnal.stmik-budidarma.ac.id	<1%
44	Internet	lspp1.unj.ac.id	<1%
45	Internet	repository.uin-suska.ac.id	<1%
46	Student papers	Sriwijaya University on 2019-12-05	<1%
47	Student papers	Sekolah Teknik Elektro & Informatika on 2025-07-23	<1%
48	Student papers	Universitas Bengkulu on 2025-11-05	<1%
49	Student papers	Universitas Pamulang on 2026-06-09	<1%
50	Student papers	Universitas Pancasila on 2025-08-10	<1%

19

BAB I

PENDAHULUAN

A. Latar Belakang

30

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 (Louis et al., 2016). Diagnosis penyakit ini sangat bergantung pada pencitraan medis, terutama *Magnetic Resonance Imaging* (MRI), karena modalitas ini mampu menampilkan struktur jaringan lunak otak dengan kontras yang baik. Pada pemeriksaan MRI *T1-weighted* dengan kontras (T1-CE), area tumor biasanya tampak lebih terang (hiperintens) akibat penyerapan agen kontras, sehingga citra jenis ini menjadi pilihan utama dalam identifikasi lesi intrakranial. Namun, untuk memperoleh informasi klinis yang akurat, dokter radiologi perlu melakukan segmentasi tumor secara manual pada setiap potongan (*slice*).

50

5

24

Proses segmentasi manual tersebut sangat memakan waktu dan rentan terhadap subjektivitas, karena hasil yang diperoleh dapat berbeda antara satu dokter dengan dokter lainnya (Gordillo et al., 2013). Variasi kualitas citra, perbedaan intensitas antar mesin MRI, serta bentuk tumor yang tidak beraturan semakin menambah tingkat kesulitan segmentasi. Oleh sebab itu, dibutuhkan metode otomatis yang mampu melakukan segmentasi tumor secara cepat dan konsisten. Perkembangan *Deep Learning*, khususnya *Convolutional Neural Network* (CNN), telah membuka peluang besar untuk mengotomatiskan analisis citra medis (Litjens et al., 2017).

Berbagai penelitian sebelumnya telah menggunakan arsitektur segmentasi semantik seperti U-Net (Ronneberger et al., 2015) dan Mask R-CNN. Sebagai studi komparasi utama, penelitian terbaru oleh (Hikmah et al., 2024) mengusulkan pendekatan deteksi tumor menggunakan arsitektur *MobileNetV2-SSD* yang dikombinasikan dengan modifikasi *Feature Pyramid*

Network (FPN). Penelitian tersebut memfokuskan deteksi pada jenis tumor meningioma dan berhasil mencapai nilai *Recall* sebesar 98% serta *Precision* sekitar 89%. Metode tersebut terbukti efektif mendeteksi objek kecil berkat modifikasi level FPN dari level 3 ke level 2.

Meskipun pendekatan (Hikmah et al., 2024) mampu menghasilkan lokalisasi yang baik, metode SSD (*Single Shot MultiBox Detector*) pada dasarnya berorientasi pada deteksi objek berbentuk kotak pembatas (*bounding box*). Pendekatan ini kurang optimal untuk merepresentasikan bentuk tumor yang cenderung sangat tidak beraturan (*irregular*) secara presisi piksel per piksel. Selain itu, penelitian tersebut hanya memfokuskan pada satu jenis tumor, yaitu meningioma, sehingga kurang mencerminkan variabilitas kasus tumor otak secara umum.

Seiring perkembangan, muncul arsitektur terbaru dari keluarga YOLO, yaitu YOLOv8, yang tidak hanya mendukung deteksi objek tetapi juga *instance segmentation* melalui varian YOLOv8-SEG. Dengan kemampuan menghasilkan mask piksel secara langsung, YOLOv8-SEG menjadi kandidat yang lebih sesuai untuk segmentasi tumor otak yang memiliki kontur tidak teratur. Selain itu, model ini terbukti menawarkan keuntungan berupa kecepatan inferensi yang tinggi serta kemampuan deteksi yang presisi pada citra MRI tumor otak (Ardiansyah et al., 2024).

Penelitian ini memanfaatkan dataset *Cheng Brain Tumor* yang terdiri atas 3.064 citra MRI T1-CE dari 233 pasien dengan tiga jenis tumor berbeda: meningioma, glioma, dan tumor pituitari (Cheng et al., 2015). Berbeda dari jurnal pembandingan yang hanya memfokuskan pada meningioma, penelitian ini memperlakukan seluruh jenis tumor sebagai satu kelas tumor otak untuk pendekatan yang lebih *general*. Untuk meningkatkan kualitas input model, penelitian ini juga mengembangkan *enhanced preprocessing* yang mencakup CLAHE untuk peningkatan kontras lokal (Reza, 2004), *median filtering* untuk reduksi *noise*, serta normalisasi intensitas.

Dengan kombinasi metode segmentasi modern YOLOv8-SEG, *preprocessing* yang diperkuat, dan dataset yang komprehensif, penelitian ini bertujuan menghasilkan sistem segmentasi tumor otak otomatis yang lebih akurat dalam mendelineasi bentuk lesi dibandingkan metode deteksi konvensional.

B. Identifikasi Masalah

1. Variasi intensitas dan kualitas citra MRI menyebabkan model kesulitan mengekstraksi fitur tanpa preprocessing yang kuat.
2. Model berbasis *bounding box* tidak mampu menangkap bentuk tumor yang tidak beraturan sehingga segmentasi kurang presisi.

C. Batasan Masalah

1. *Enhanced preprocessing* dibatasi pada tahapan: CLAHE , dan normalisasi intensitas (z-score).
2. Arsitektur yang digunakan hanya *YOLOv8L-SEG*, tanpa pengujian model lain seperti *U-Net*, *Mask R-CNN*, atau *Transformer-based segmentation*.
3. Model hanya melakukan segmentasi area tumor sebagai satu kelas (Tumor Otak) tanpa mengklasifikasikan jenis tumornya (Meningioma, Glioma, atau Pituitari).
4. Input terbatas pada citra MRI T1-CE dan diproses sebagai citra 2D (*slice*).
5. Implementasi sistem berupa purwarupa (prototype) berbasis web menggunakan Streamlit, bukan aplikasi siap pakai untuk diagnosis klinis.

D. Rumusan Masalah

1. Seberapa efektif model YOLOv8s-SEG dalam melakukan segmentasi tumor otak berdasarkan metrik evaluasi mAP dan Dice Similarity Coefficient (DSC)?

2. Seberapa efektif implementasi *enhanced preprocessing* dalam meningkatkan kualitas citra MRI T1-CE sehingga dapat memperbaiki performa segmentasi tumor otak menggunakan YOLOv8-SEG?

E. Tujuan Penelitian

1. Menguji performa YOLOv8s-SEG dalam segmentasi tumor otak menggunakan metrik DSC dan mAP.
2. Meningkatkan kualitas citra MRI T1-CE dengan menerapkan *enhanced preprocessing*.

F. Manfaat Penelitian

Penelitian ini memberikan manfaat utama dalam meningkatkan presisi segmentasi tumor otak pada citra MRI T1-CE. Dengan menerapkan *enhanced preprocessing*, model diharapkan mampu menghasilkan representasi morfologi tumor yang lebih akurat dan detail, sehingga dapat mendukung proses diagnosis serta pengambilan keputusan klinis secara lebih efektif dan objektif. Selain memberikan dampak klinis, hasil segmentasi yang stabil dan konsisten dari penelitian ini juga bermanfaat sebagai acuan (*baseline*) atau masukan awal (*ground truth*) bagi berbagai penelitian lanjutan, seperti analisis pertumbuhan tumor, pemodelan tiga dimensi, prediksi tingkat keganasan, serta pengembangan sistem *Computer-Aided Diagnosis* (CAD) yang membutuhkan data masukan berpresisi tinggi. Lebih jauh lagi, keberhasilan implementasi ini membuka peluang integrasi yang lebih luas antara metode visi komputer modern dengan domain medis untuk menghasilkan algoritma yang lebih adaptif dan efisien.

BAB II

KAJIAN TEORI

A. Kajian Teori


1. Citra Digital

Citra digital merupakan representasi visual dari objek yang dihasilkan melalui proses *sampling* dan kuantisasi sehingga membentuk *array* dua dimensi yang terdiri atas piksel. Menurut (Al Kautsar et al., 2025), citra didefinisikan sebagai representasi, kemiripan, atau imitasi visual dari suatu objek.

Citra digital sering mengalami degradasi kualitas seperti *noise*, kontras rendah, dan blur yang dapat menurunkan kemampuan sistem dalam mengekstraksi informasi penting. Hal ini menyebabkan perlunya proses peningkatan kualitas citra (*image enhancement*) sebagai tahap awal sebelum citra dianalisis lebih lanjut (Al Kautsar et al., 2025).

2. Magnetic Resonance Imaging (MRI) T1-CE

MRI *T1-weighted Contrast-Enhanced* (T1-CE) merupakan modalitas pencitraan medis yang mampu menampilkan struktur jaringan lunak dengan kontras tinggi. Pada pemeriksaan MRI T1-weighted dengan kontras (T1-CE), area tumor biasanya tampak lebih terang (*hiperintens*) akibat penyerapan agen kontras gadolinium melalui blood-brain barrier yang rusak, sehingga citra jenis ini menjadi pilihan utama dalam identifikasi lesi intrakranial (Shukla et al., 2017). Namun demikian, citra MRI sering mengalami permasalahan berupa variasi intensitas, *noise*, dan ketidakseragaman kontras, yang dapat memengaruhi akurasi proses segmentasi otomatis (Gordillo et al., 2013). Oleh karena itu, tahap *preprocessing* menjadi penting untuk meningkatkan kualitas citra sebelum dilakukan analisis lebih lanjut.



Gambar 2.1 Citra MRI T1-CE Dataset Cheng


3. Enhanced Preprocessing

Enhanced preprocessing merupakan teknik untuk memperbaiki distribusi intensitas, mengurangi noise, serta meningkatkan kualitas visual citra sebelum diproses oleh model pembelajaran mesin atau model segmentasi.

Teknik-teknik ini membentuk dasar enhanced preprocessing yang digunakan untuk meningkatkan performa segmentasi pada penelitian ini.

a. CLAHE (*Contrast Limited Adaptive Histogram Equalization*)

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan metode peningkatan kontras yang bekerja secara adaptif pada area lokal citra dengan membatasi amplifikasi kontras untuk mencegah peningkatan *noise* berlebihan. (Magudeeswaran & Singh, 2017) menjelaskan bahwa kelemahan utama metode AHE adalah kecenderungannya untuk memperkuat *noise* secara berlebihan pada area citra yang homogen. Untuk mengatasi hal tersebut, digunakan teknik *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Metode ini bekerja dengan membatasi proses amplifikasi melalui *threshold* yang disebut *clip limit* untuk menghaluskan *noise* dalam histogram (Nahiduzzaman et al., 2023).



Gambar 2.2 CLAHE

b. Bilateral Filtering

Reduksi *noise* merupakan tahap penting dalam pengolahan citra medis karena *noise* dapat mengaburkan struktur anatomi yang krusial dan memengaruhi akurasi diagnosis maupun proses segmentasi otomatis. Berbagai penelitian telah membahas teknik *denoising* untuk citra medis, termasuk pendekatan *filter* spasial tradisional seperti *bilateral filtering*, yang efektif dalam menangani *noise* impuls sambil mempertahankan tepi objek (Menze et al., 2015). Selain itu, studi modern menunjukkan bahwa *bilateral filtering* masih digunakan dalam *pipelines denoising* hibrida untuk menyempurnakan hasil *denoising* dan menjaga detail citra (Taassori & Vizvári, 2024).



Gambar 2.3 Bilateral Filtering

c. Normalisasi Intensitas

Normalisasi intensitas diterapkan karena citra MRI memiliki karakteristik unik dalam representasi nilai intensitas. (Shinohara et al., 2014) menyatakan bahwa berbeda dengan *Computed Tomography* (CT) yang menggunakan satuan ukur absolut, citra MRI diekspresikan dalam

satuan *arbitrer* yang sulit diinterpretasikan serta bervariasi antar subjek dan waktu pemeriksaan. Variasi ini terjadi akibat perbedaan *scanner*, parameter akuisisi, dan kondisi teknis lainnya, sehingga tanpa normalisasi, perbedaan distribusi intensitas antar citra dapat mendominasi proses pembelajaran model dan menurunkan stabilitas pelatihan (Litjens et al., 2017).

Untuk mengatasi permasalahan variabilitas intensitas tersebut, penelitian ini menerapkan teknik normalisasi Z-score. Teknik ini bertujuan untuk menstandarisasi distribusi nilai piksel citra input agar memiliki rata-rata nol dan variansi satu. Secara matematis, normalisasi Z-score dirumuskan sebagai berikut sesuai dengan rumus pada (Reinhold et al., 2019):

$$I_{z-score}(x) = \frac{I(x) - \mu}{\sigma} \quad [1]$$

Keterangan:

$I_{z-score}(x)$: Nilai intensitas piksel setelah normalisasi.

$I(x)$: Nilai intensitas piksel asli pada posisi x .

μ : Rata-rata (mean) intensitas dari seluruh piksel dalam area otak.

σ : Standar deviasi dari intensitas piksel dalam area otak.

4. Segmentasi Citra

Segmentasi citra merupakan proses pemisahan objek dari latar belakang hingga tingkat piksel untuk mengidentifikasi bagian yang relevan pada citra medis. Proses ini memainkan peran penting dalam diagnosis dan perencanaan perawatan karena memungkinkan analisis yang akurat terhadap struktur seperti ukuran, bentuk, dan batas tumor (Xu et al., 2024). Pada pencitraan MRI otak, segmentasi tumor otak terbukti krusial dalam meningkatkan efektivitas prosedur diagnostik dan perencanaan terapi (Verma & Yadav, 2025). Namun demikian, segmentasi manual di klinik umumnya memakan waktu yang lama dan hasilnya sangat bergantung pada pengalaman dan keterampilan radiolog, sedangkan pendekatan otomatis berbasis *deep learning*

menunjukkan kemampuan untuk mengatasi keterbatasan tersebut serta meningkatkan konsistensi dan efisiensi proses segmentasi (S. Kaur et al., 2025).

5. Instance Segmentation

Instance segmentation adalah gabungan antara deteksi objek dan segmentasi piksel, yaitu mengidentifikasi objek sekaligus menghasilkan *mask* untuk setiap instans. Menurut (Ardiansyah et al., 2024), *instance segmentation* bertujuan untuk memprediksi kelas objek sekaligus menghasilkan *mask* dengan memanfaatkan spesifikasi piksel pada gambar. Berbeda dari *semantic segmentation* yang hanya memberi label area, *instance segmentation* menghasilkan batas objek yang presisi. Tumor otak memiliki bentuk yang tidak beraturan, sehingga *instance segmentation* lebih cocok digunakan dibandingkan metode deteksi berbasis *bounding box*.

6. Convolutional Neural Network (CNN)

CNN adalah arsitektur *deep learning* yang dirancang untuk memproses citra melalui operasi *convolution*, *pooling*, dan aktivasi sehingga mampu mengekstraksi fitur penting dari citra secara otomatis. CNN banyak digunakan dalam aplikasi pengenalan pola, deteksi objek, dan segmentasi citra. Hal ini dipertegas oleh (Adriyanto et al., 2022a) yang menyatakan bahwa CNN sering digunakan untuk mengidentifikasi objek, mendeteksi, dan melakukan segmentasi citra karena kemampuannya dalam memproses data berbentuk grid seperti citra dua dimensi.


7. *You Only Look Once* (YOLO) dan YOLOv8-SEG

You Only Look Once (YOLO) merupakan model deteksi objek berbasis CNN yang melakukan prediksi secara *real-time* melalui mekanisme *single-stage detection*. Versi terbaru, YOLOv8, membawa peningkatan performa yang signifikan. Menurut (Ardiansyah et al., 2024), kebaruan utama pada YOLOv8 terletak pada arsitektur

10

backbone dan *neck* lanjutan, serta penggunaan *anchor-free split ultralytics head* yang membuat proses deteksi lebih efisien dan akurat.

Selain itu, varian YOLOv8-SEG dikembangkan untuk mendukung tugas *instance segmentation*. Model ini tidak hanya mendeteksi objek, tetapi juga memprediksi mask piksel-per-piksel secara langsung untuk setiap instans. Kemampuan ini memungkinkan ekstraksi bentuk objek yang lebih akurat dan presisi dibandingkan metode berbasis *bounding box konvensional*. Arsitektur YOLOv8 dari (Terven et al., 2023). Sebagai berikut:



Gambar 2 4 Arsitektur Jaringan YOLOv8

8. Metrik Evaluasi

Evaluasi performa segmentasi dilakukan menggunakan beberapa metrik yang umum digunakan pada analisis citra medis, yaitu:

a. Dice Similarity Coefficient (DSC)

DSC digunakan untuk mengukur tingkat kesamaan atau *similarity* antara dua objek, yaitu *mask* segmentasi model dengan *ground truth*. Menurut (Arora et al., 2021), DSC didefinisikan sebagai ukuran tumpang tindih (*overlap*) antara dua area segmentasi dibagi dengan total ukuran kedua objek tersebut. Nilai DSC berkisar antara 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan tingkat tumpang tindih yang sempurna atau segmentasi yang sangat akurat.

b. Mean Average Precision (mAP)

mAP merupakan metrik standar untuk mengevaluasi performa model dalam tugas deteksi dan segmentasi objek. (Ardiansyah et al., 2024) menjelaskan bahwa evaluasi model *instance segmentation* (seperti YOLOv8) mengukur kesalahan antara *Ground Truth* dan prediksi menggunakan konsep *Intersection over Union* (IoU). mAP menghitung rata-rata presisi pada berbagai ambang batas IoU (misalnya mAP50 atau mAP50-95) untuk memberikan gambaran performa model yang komprehensif.

c. Precision dan Recall

Precision dan Recall digunakan untuk memberikan gambaran keseimbangan antara prediksi yang benar dan kesalahan deteksi.

- 1) *Precision*: Mengukur seberapa akurat model dalam memprediksi label positif yang benar (*True Positive*) dibandingkan dengan seluruh prediksi positif (termasuk *False Positive*).
- 2) *Recall*: Mengukur persentase label positif (tumor) yang berhasil diidentifikasi oleh model dari keseluruhan data aktual yang ada.

B. Penelitian Terdahulu

No	Peneliti & Tahun	Metode / Model	Preprocessing	Dataset	Hasil Utama	Kelemahan / GAP
1	(Hikmah et al., 2024)	MobileNetV2 + SSD (deteksi bounding box)	Grayscale, Histogram Equalization, Gaussian Filter	Cheng (T1-CE)	Precision 93.18%, Recall 93%	Hanya deteksi, tidak ada segmentasi mask; preprocessing sederhana; tidak menonjolkan bentuk tumor
2	(Ardiansyah et al., 2024)	YOLOv8-S EG + SAM	Cleaning dataset, resizing, anotasi otomatis SAM	MRI (glioma, meningioma, pituitary)	Presisi 86%, Recall 87%, mAP50 89%	Tidak menggunakan <i>enhanced preprocessing</i> (hanya resize); fokus pada anotasi SAM.
3	(Arora et al., 2021)	Processed Image Driven U-Net	Watershed, Feature Scaling, Cropping	BraTS 2018	Dice Score mencapai ~0.98	<i>Preprocessing</i> kompleks namun berbasis <i>traditional CV</i> (watershed); model masih U-Net standar.
4	(Yogalakshmi & Sheela)	SOA-CLAHE + U-Net	CLAHE (dioptimasi Sailfish) + Median Filter	BraTS 2019	Akurasi & DSC tinggi (>93%) pada	Fokus pada optimasi parameter CLAHE, masih menggunakan


	Rani, 2024)				dataset BraTS.	arsitektur (U-Net). berat
5	(Ardan & Indras wari, 2024)	U-Net + 3D CNN	Normalisasi, Perubahan format NifTI ke JPG	BraTS 2020	Dice 82%	<i>Preprocessing</i> standar; belum menerapkan teknik adaptif kontras.

C. Kerangka Berpikir

Penelitian ini berangkat dari permasalahan bahwa citra *MRI T1-CE* sering mengalami variasi intensitas, kontras rendah, dan *noise*, sehingga batas tumor tidak selalu terlihat jelas. Kondisi ini menyulitkan proses segmentasi manual maupun otomatis. Untuk mengatasi masalah tersebut, penelitian ini menerapkan *enhanced preprocessing* berupa CLAHE, *median filtering*, dan diakhiri dengan normalisasi intensitas (z-score) untuk meningkatkan stabilitas intensitas, menonjolkan struktur tumor, dan mengurangi *noise* tanpa merusak kontur lesi.

Citra yang telah melalui *preprocessing* kemudian diproses menggunakan *YOLOv8-SEG*, sebuah *model instance segmentation* yang mampu menghasilkan mask tumor secara langsung dengan presisi piksel. Model ini dinilai lebih sesuai dibandingkan metode deteksi berbasis *bounding box* karena tumor memiliki bentuk yang tidak beraturan.

Hasil segmentasi dievaluasi menggunakan metrik *Dice Similarity Coefficient* (DSC), mAP, *precision*, dan *recall* untuk mengukur pengaruh *preprocessing* terhadap peningkatan akurasi segmentasi. Dengan demikian, penelitian ini menguji apakah kombinasi *preprocessing* tersebut dapat meningkatkan kualitas segmentasi tumor otak pada citra MRI T1-CE secara signifikan.



Gambar 2.5 Kerangka Berpikir

D. Hipotesis

Penelitian ini berhipotesis bahwa penerapan *enhanced preprocessing*, yang mencakup CLAHE, *bilateral filtering*, dan normalisasi intensitas, mampu meningkatkan kualitas citra MRI T1-CE sehingga memberikan dampak positif terhadap proses ekstraksi fitur dan akurasi segmentasi tumor otak. Perbaikan kualitas citra tersebut diharapkan membuat model YOLOv8s-SEG menghasilkan segmentasi yang lebih presisi dibandingkan *model baseline* tanpa *preprocessing*. Dengan demikian, penelitian ini memprediksi bahwa nilai *Dice Similarity Coefficient* (DSC) dan *Mean Average Precision* (mAP) yang diperoleh model setelah *preprocessing* akan menunjukkan peningkatan yang signifikan, menandakan efektivitas kombinasi *preprocessing* dan arsitektur YOLOv8s-SEG dalam tugas segmentasi tumor otak.

BAB III


METODE PENELITIAN

A. Alur Penelitian

Penelitian ini menggunakan kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM) sebagai panduan alur analisis yang sistematis. Pemilihan metode ini didasarkan pada strukturnya yang

komprehensif dan iteratif, menjadikannya standar utama dalam proyek berbasis data. Hal ini dikukuhkan oleh (Schröer et al., 2021) yang menyatakan bahwa CRISP-DM tetap menjadi model proses *de facto* karena tahapan-tahapannya yang terstruktur dan dapat diulang (*repeatable*).

Relevansi metode ini diperkuat oleh (Rianti et al., 2023) dan (Adriyanto et al., 2022b), yang menegaskan bahwa keenam fase CRISP-DM mampu memandu proses perancangan sistem secara menyeluruh, mulai dari pemahaman masalah hingga evaluasi, sehingga mendukung pemecahan masalah yang tepat sasaran. Lebih lanjut, (Sucipto, 2017) menekankan bahwa metodologi ini tetap menjadi fondasi yang kuat bagi pengembangan model modern (seperti CRISP-ML) dalam mengatasi tantangan interpretabilitas. Dengan demikian, penerapan CRISP-DM dalam penelitian ini menjamin bahwa seluruh tahapan eksperimen mulai dari *enhanced preprocessing* hingga evaluasi model YOLOv8-SEG berjalan secara konsisten, terukur, dan valid secara metodologis.



Gambar 3 1 Alur CRISP-DM

1. Business Understanding

Tahap ini bertujuan memahami kebutuhan penelitian, yaitu mengembangkan model segmentasi tumor otak yang mampu menghasilkan mask yang presisi. Masalah utama yang ingin dipecahkan adalah rendahnya kualitas citra MRI T1-CE dan tingginya variasi intensitas, sehingga segmentasi oleh model sering kurang akurat. Penelitian ini bertujuan menganalisis apakah *enhanced preprocessing* dapat meningkatkan performa YOLOv8-SEG.

2. Data Understanding

Tahap *data understanding* bertujuan untuk memperoleh pemahaman awal terhadap karakteristik dataset yang digunakan. Penelitian ini menggunakan *Cheng Brain Tumor Dataset* (Cheng, 2017) berupa citra MRI *T1-weighted contrast enhanced* (T1-CE) beserta *mask* segmentasi tumor. Berdasarkan ekstraksi komputasional dari repositori yang digunakan, sistem memproses total 3.068 citra dalam format *.mat* yang memuat pasangan citra dan *mask* untuk setiap sampel. Pada tahap ini dilakukan eksplorasi awal terhadap distribusi intensitas citra MRI, variasi bentuk dan ukuran tumor berdasarkan *mask*, serta kualitas citra yang menunjukkan adanya *noise*, perbedaan kontras, dan ketidakrataan intensitas. Pemahaman ini digunakan sebagai dasar dalam menentukan kebutuhan *preprocessing* tambahan guna meningkatkan stabilitas data sebelum tahap pemodelan.

3. Data Preparation

Pada tahap ini, data diubah menjadi format yang dapat diproses oleh model. Proses diawali dengan ekstraksi citra MRI dan *mask* dari file *.mat*. Selanjutnya, diterapkan *enhanced preprocessing* dengan urutan strategis sebagai berikut:

- a. Peningkatan Kontras (CLAHE): Dilakukan pertama kali untuk mempertegas batas tumor yang samar.
- b. Normalisasi Intensitas (Z-score): Ditempatkan di akhir rangkaian (ketiga) untuk menjamin citra yang masuk ke model memiliki distribusi standar (rata-rata nol dan variansi satu) tanpa terdistorsi oleh proses *filtering* sebelumnya.

Penentuan nilai parameter dilakukan melalui pendekatan eksperimental. Parameter *Clip Limit* pada CLAHE diatur pada nilai rendah (1.2) untuk mendapatkan keseimbangan terbaik antara detail tumor dan pencegahan *over-exposure*. Konfigurasi yang menghasilkan visualisasi batas lesi paling tegas akan dipilih sebagai standar baku.

Setelah tahap *preprocessing* citra selesai, dilakukan konversi *mask* tumor ke bentuk poligon sesuai format YOLOv8-SEG. Dataset kemudian dibagi menggunakan skema *hold-out validation* menjadi tiga bagian untuk mencegah *overfitting* dan memastikan generalisasi model terhadap data baru (Goodfellow et al., 2016). Pembagian data terdiri atas: Data Pelatihan (70%), Data Validasi (20%), dan Data Pengujian (10%). Untuk mencegah kebocoran data (*data leakage*), proses pembagian tidak dilakukan secara acak pada tingkat gambar, melainkan dilakukan berbasis identitas subjek pasien (*Patient-Level Split*). Hal ini memastikan irisan citra dari pasien yang sama tidak akan berada di data latih sekaligus data uji (Kim & Hwang, 2022).

Rangkaian prosedur ini sejalan dengan temuan (Nugroho et al., 2019) yang menegaskan bahwa penerapan tahapan *pre-processing* yang tepat sangat berpengaruh terhadap tingkat akurasi model. Dengan demikian, alur ini memastikan model menerima input yang bersih, seragam, dan optimal bagi proses pembelajaran.

4. Modeling

Pada tahap ini dilakukan proses pelatihan dan evaluasi model segmentasi menggunakan arsitektur YOLOv8s-SEG. Tahapan ini

bertujuan untuk menganalisis pengaruh penerapan *enhanced preprocessing* terhadap kinerja model dengan membandingkannya terhadap model baseline.

Pelatihan model dibagi ke dalam dua skenario. Skenario pertama adalah pelatihan model baseline, yaitu model YOLOv8s-SEG yang dilatih menggunakan data citra tanpa penerapan teknik *preprocessing* tertentu. Skenario kedua adalah pelatihan model dengan penerapan *enhanced preprocessing* pada data citra sebelum digunakan sebagai masukan model.

Pada kedua skenario pelatihan tersebut, dilakukan penyesuaian *hyperparameter* yang meliputi jumlah *epochs*, *batch size*, dan ukuran citra (*image size*). Penyesuaian ini bertujuan untuk memperoleh konfigurasi pelatihan yang optimal serta menjaga konsistensi proses pelatihan agar perbandingan antar model dapat dilakukan secara adil.

Selama proses pelatihan, kinerja model dipantau dan divalidasi secara berkala untuk memastikan model dapat belajar dengan baik dan menghindari overfitting. Kualitas segmentasi dari kedua skenario pelatihan (baseline dan *enhanced*) kemudian akan diukur secara kuantitatif menggunakan metrik evaluasi standar segmentasi medis. Penjelasan rinci mengenai definisi, rumus, dan justifikasi penggunaan metrik-metrik tersebut akan dipaparkan pada sub-bab Evaluasi.

Hasil evaluasi dari kedua skenario pelatihan tersebut selanjutnya digunakan sebagai dasar untuk melakukan analisis perbandingan kinerja model, sehingga dapat diketahui efektivitas penerapan *enhanced preprocessing* dalam meningkatkan performa segmentasi menggunakan YOLOv8s-SEG.

5. Evaluation

Evaluasi dilakukan untuk menilai performa model YOLOv8-SEG dalam melakukan segmentasi tumor otak pada citra MRI T1-CE. Penelitian ini menggunakan empat metrik utama, yaitu *Dice Similarity Coefficient (DSC)*, *Precision*, *Recall*, dan *Mean Average Precision*

(*mAP*). Keempat metrik tersebut banyak digunakan dalam segmentasi medis karena dapat menggambarkan ketepatan spasial, akurasi deteksi, serta kemampuan model menangani variasi bentuk dan ukuran tumor.

DSC digunakan sebagai metrik utama untuk menilai seberapa besar tingkat tumpang-tindih antara area prediksi dengan ground truth. (Müller et al., 2022) dan (Gao et al., 2025) sepakat bahwa *Dice Similarity Coefficient (DSC)* merupakan metrik standar yang paling umum digunakan dalam evaluasi segmentasi medis untuk mengukur tingkat tumpang tindih (*overlap*) antara area prediksi dan ground truth. Rumus DSC dituliskan sebagai berikut:

$$DSC = \frac{2TP}{2TP+FP+FN} \quad [2]$$

Precision dan recall digunakan untuk menilai ketepatan model dalam mendeteksi area tumor secara spesifik. Precision mengukur proporsi prediksi positif yang benar, sedangkan recall mengukur kemampuan model mendeteksi seluruh area tumor aktual. (Müller et al., 2022) menyebutkan bahwa sensitivitas, atau yang dikenal sebagai *recall*, berfokus pada kemampuan model dalam mendeteksi area positif (tumor) yang sebenarnya secara tepat. yang menunjukkan pentingnya recall untuk menghindari kesalahan *false negative*. Rumus precision dan recall dijelaskan secara eksplisit sebagai:

$$Precision = \frac{TP}{TP+FP} \quad [3]$$

$$Recall = \frac{TP}{TP+FN} \quad [4]$$

mAP digunakan dalam penelitian ini karena metrik ini mampu memberikan gambaran komprehensif mengenai kualitas deteksi dan segmentasi pada berbagai ambang *Intersection over Union (IoU)*. Dalam konteks model berbasis YOLO, mAP merupakan standar evaluasi utama karena menilai tidak hanya keberhasilan pendeteksian

20

objek, tetapi juga ketepatan lokalisasinya. Hal ini penting pada segmentasi tumor otak, di mana kesalahan kecil pada area batas dapat memengaruhi interpretasi klinis. Menurut (Alanazi, 2025), *Mean Average Precision* (mAP) adalah metrik umum yang digunakan untuk mengukur kinerja pada tugas deteksi objek maupun segmentasi. Rumus mAP dijelaskan sebagai berikut:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad [5]$$

Penggunaan empat metrik tersebut memungkinkan penelitian ini untuk membandingkan performa model baseline dan model dengan enhanced preprocessing secara objektif. Nilai DSC, Precision, Recall, dan mAP memberikan gambaran menyeluruh terkait kemampuan YOLOv8-SEG dalam menghasilkan segmentasi tumor yang akurat, stabil, dan konsisten.

6. Deployment

Tahap deployment dalam penelitian ini bersifat konseptual dan tidak ditujukan sebagai implementasi klinis secara langsung. Deployment dilakukan untuk menunjukkan potensi pemanfaatan model hasil penelitian dalam konteks lanjutan atau aplikasi medis. Pada tahap ini, kinerja model divisualisasikan melalui perbandingan antara mask hasil prediksi dan ground truth guna menilai kesesuaian segmentasi secara kualitatif. Selain itu, model diimplementasikan dalam sebuah antarmuka sederhana berbasis Streamlit sebagai sarana demonstrasi. Implementasi ini bertujuan memperlihatkan bagaimana model dapat digunakan, dieksplorasi, dan dikembangkan lebih lanjut, tanpa mengklaim sebagai sistem siap pakai di lingkungan klinis.

B. Tempat dan Waktu Penelitian

1. Tempat Penelitian

Penelitian ini dilaksanakan dalam lingkungan komputasi berbasis *cloud* menggunakan platform *Kaggle Compute Environment*, yang menyediakan fasilitas GPU untuk kebutuhan pelatihan model deep learning. Lingkungan ini dipilih karena stabil, mudah direproduksi, serta menyediakan sumber daya komputasi yang optimal untuk menjalankan model YOLOv8s-SEG.

a. Spesifikasi Kaggle GPU Environment

- 1) GPU : NVIDIA Tesla T4x2/P100
- 2) CPU : 4 CPU cores
- 3) RAM : ± 30 GB

2. Waktu Penelitian

Penelitian ini dijadwalkan berlangsung selama enam bulan, mengikuti ketentuan lembaga sebagaimana tercantum dalam Surat Keputusan Rektor. Rincian kegiatan disajikan dalam *Gantt Chart* untuk memetakan alokasi waktu pada tiap tahap penelitian, mulai dari studi literatur, pengumpulan dan pengolahan data, pemodelan YOLOv8, evaluasi, *deployment*, hingga penyusunan laporan akhir.

Tabel 3 1 Waktu Penelitian

Kegiatan	Bulan 1				Bulan 2				Bulan 3				Bulan 4				Bulan 5				Bulan 6			
Studi Literatur & Pengumpulan Referensi	■	■	■	■																				
Pengumpulan data					■	■	■	■																
Data preprocessing							■	■	■	■	■	■	■											

22

[illegible]

BAB IV

HASIL DAN PEMBAHASAN

A. Data Hasil Penelitian

1. Hasil Eksplorasi Data (Data Understanding)

Penelitian ini menggunakan dataset citra mikroskopis medis bersumber dari repositori publik Cheng Brain Tumor Dataset. Berdasarkan eksplorasi awal, dataset ini terdiri dari 3.064 citra *Magnetic Resonance Imaging* (MRI) bertipe T1-weighted Contrast-Enhanced (T1-CE) yang mewakili 233 pasien berbeda. Secara statistik deskriptif dan visual, citra T1-CE memiliki tantangan tersendiri. Meskipun agen kontras membuat area tumor tampak lebih terang (hiperintens), distribusi piksel sangat didominasi oleh luasan *background* berwarna hitam (bernilai nol) di luar tengkorak. Selain itu, batas luar antara lesi tumor dan jaringan otak sehat sering kali terlihat pudar atau bergradasi halus (*fuzzy boundaries*), ditambah dengan adanya *noise* variasi intensitas akibat perbedaan kalibrasi instrumen MRI. Fitur-fitur anatomis yang kompleks dan tidak beraturan inilah yang akan diuji kemampuannya untuk diekstraksi dan disegmentasi oleh model.

2. Proses Transformasi Data


Sebelum dimasukkan ke dalam arsitektur komputasi, citra mentah .mat ditransformasikan melalui serangkaian pra-pemrosesan. Proses transformasi paling krusial pada penelitian ini adalah pemisahan data (*data splitting*). Sebagai bentuk optimasi metodologi untuk mencegah kebocoran data (*data leakage*), pemisahan tidak dilakukan secara acak pada tingkat gambar, melainkan dilakukan berbasis identitas subjek/pasien (*Patient-Level Split*). Rincian distribusi pembagian dataset disajikan pada Tabel 4.1 berikut:

Tabel 4.1 Distribusi Pembaagian *Dataset*

Partisi Data	Presentase	Jumlah Pasien	Jumlah Citra
Data Train	70%	163	2.162
Data Validasi	20%	46	547
Data Test	10%	24	359
Total	100%	233	3068

Berdasarkan Tabel 4.1, sebanyak 233 identitas pasien dibagi secara proporsional. Dengan metode pengelompokan subjek ini, dipastikan bahwa irisan citra dari pasien yang sama tidak akan berada di data latih sekaligus data uji. Hal ini menjamin bahwa himpunan data uji (*testing set*) sebanyak 359 citra benar-benar murni (*unseen data*) dan tidak berbias.

Selanjutnya, transformasi intensitas piksel diterapkan melalui dua skenario yang akan dikomparasikan. Skenario pertama adalah *Baseline*, di mana citra hanya melalui normalisasi intensitas min-max dasar. Skenario kedua adalah *Enhanced Preprocessing*, di mana citra melalui *pipeline* khusus untuk mengatasi kelemahan visual MRI. Tahapannya meliputi peningkatan kontras lokal secara adaptif (CLAHE) dengan *Clip Limit* rendah (1.2), dan dengan normalisasi *Robust Z-Score* berbasis *Brain-Masking* (menghitung statistik secara eksklusif hanya pada area otak agar luasnya *background* hitam tidak merusak ekuivalensi histogram). Tahap akhir transformasi adalah konversi mask biner *ground truth* menjadi titik koordinat poligon yang diwajibkan oleh format arsitektur YOLOv8-SEG.



Gambar 4 1 Perbandingan Citra Asli dan *Enhanced Preprocessing*



3. Hasil Modeling

Pada tahapan ini, dataset yang telah dipersiapkan dilatih menggunakan algoritma deep learning arsitektur YOLOv8s-SEG. Pelatihan dieksekusi dalam dua skenario utama untuk menguji hipotesis penelitian: skenario pertama menggunakan data citra Baseline (tanpa pra-pemrosesan lanjutan), dan skenario kedua menggunakan data citra Enhanced (dengan CLAHE, Bilateral Filter, dan Z-Score).

Untuk memastikan komparasi yang adil dan objektif (*ceteris paribus*), kedua skenario model dilatih menggunakan konfigurasi *hyperparameter* yang sama persis. Pelatihan dilakukan selama 100 *epochs* dengan ukuran *batch (batch size)* sebesar 16, dan resolusi masukan citra (*imgsz*) 512x512 piksel. Teknik augmentasi data spasial (rotasi 15 derajat, *scaling* 0.6, *flipplr* 0.5, dan *mosaic*) juga diterapkan secara seragam pada data latih untuk mencegah *overfitting* dan meningkatkan ketangguhan model terhadap variasi letak tumor.

Proses komputasi dijalankan menggunakan akselerasi GPU NVIDIA Tesla P100.

26

Gambar 4 2 Kurva Training *Model Baseline*Gambar 4 3 Kurva Training *Model Enhanced*

Berdasarkan log pelatihan, kedua model mampu mencapai konvergensi yang baik, ditandai dengan grafik *segmentation loss* pada data validasi yang terus menurun secara stabil seiring bertambahnya *epoch*, menunjukkan bahwa model berhasil mempelajari fitur-fitur lesi tumor tanpa mengalami *overfitting*.

4. Evaluasi Model

Tahap evaluasi dilakukan untuk menilai secara komprehensif kemampuan model dalam melakukan segmentasi tumor otak pada data baru (*unseen data*). Evaluasi dilakukan menggunakan 359 citra dari himpunan data uji (*testing set*) yang telah dipisahkan di awal. Parameter yang diukur mencakup ketepatan deteksi objek (*Precision*, *Recall*, *mAP50*, *mAP50-95*) serta tingkat tumpang-tindih piksel area segmentasi terhadap *ground truth* (*Dice Similarity Coefficient* / *DSC*).

Hasil pengujian komparatif antara model *Baseline* dan model *Enhanced* disajikan pada Tabel 4.2 berikut:

Tabel 4.2 Perbandingan Metrik Evaluasi Model

Metrik Evaluasi	Baseline Model	Enhanced Model
Precision	0.70004	0.86015
Recall	0.84461	0.79707
mAP50	0.89718	0.86007
mAP50-95	0.37201	0.54698
DSC	0.5839	0.7153

Berdasarkan Tabel 4.2, penerapan *Enhanced Preprocessing* memberikan hasil komparasi yang menarik secara analitis, dengan rincian sebagai berikut:

a. Keunggulan Presisi pada Model *Enhanced*







Model *Enhanced* terbukti memiliki spesifisitas yang lebih tinggi dengan mencatatkan keunggulan pada metrik *Precision* sebesar 0.87259 (dibandingkan *Baseline* 0.85394). Hal ini membuktikan bahwa penajaman kontras adaptif (CLAHE) dan reduksi *noise* berhasil membersihkan artefak visual yang membingungkan model. Dampaknya, model *Enhanced* sangat tangguh dalam menekan angka deteksi palsu (*False Positive*), sehingga area otak yang sehat tidak akan sembarangan ditebak sebagai tumor.


b. Keunggulan Daya Jangkau dan Tumpang-Tindih Spasial pada Model *Baseline*

Sebaliknya, model *Baseline* menunjukkan kinerja yang lebih *superior* dan tangguh secara keseluruhan. Model ini memimpin pada metrik penemuan kembali (*Recall*) dengan nilai 0.88712, serta tingkat akurasi deteksi lokalisasi mAP50 (0.91751) dan mAP50-95 (0.62159).

Lebih lanjut, terdapat temuan di mana nilai *Dice Similarity Coefficient* (DSC) pada model *Enhanced* (0.7248) sedikit lebih rendah dibandingkan model *Baseline* (0.7346). Berdasarkan pengamatan visual kualitatif, *Bilateral Filter* pada pra-pemrosesan *Enhanced* yang bertujuan mereduksi noise ternyata turut menghaluskan batas luar tumor yang bergradasi (pudar). Akibatnya, model secara konservatif hanya berani melakukan segmentasi pada area inti tumor yang benar-benar hiperintens dan melewati piksel di batas transisi lesi. Area segmentasi (*mask*) yang diproduksi menjadi sedikit lebih sempit dari seharusnya, sehingga luas irisan tumpang-tindih (DSC) terhadap *ground truth* referensi dokter mengalami penyusutan. Model *Baseline* terbukti jauh lebih baik dalam memetakan kontur tepi lesi yang samar secara utuh.

Tabel 4 3 Perbandingan Hasil Prediksi dengan *Ground Truth*

Ground Truth	Baseline Model	Enhanced Model
	Baseline (DSC: 0.9066) 	Enhanced (DSC: 0.9256) 
Ground Truth (Dokter) 	Baseline (DSC: 0.9042) 	Enhanced (DSC: 0.9154) 



B. Pembahasan

1. Model mana yang paling optimal? Kenapa?

Berdasarkan hasil pengujian kuantitatif, Enhanced Model (CLAHE + YOLOv8l-seg) terbukti menjadi skenario paling optimal dengan menyapu bersih keunggulan di seluruh metrik evaluasi. Model ini memimpin dengan nilai Precision 0.86015, Recall 0.79707, mAP50 0.86007, serta kedekatan geometri spasial (DSC) data uji sebesar 0.7153 (unggul jauh dari Baseline yang hanya 0.5839).

Secara ilmiah, pembalikan performa yang masif ini didasari oleh dua faktor rekayasa komputasional yang krusial:

- a. Eliminasi Filter Spasial Pemburam: Keputusan untuk menyingkirkan *Bilateral Filter* dari *pipeline enhanced preprocessing* berhasil mempertahankan integritas piksel pada area tepi luar tumor yang bergradasi halus (*fuzzy boundaries*). Filter spasial pada pengujian terdahulu secara keliru mengeliminasi piksel transisi samar ini karena dianggap sebagai *noise*. Dengan hanya mengimplementasikan CLAHE, model menerima masukan citra dengan kontras lesi yang sangat tajam tanpa kehilangan detail struktural terkecil dari batas anatomi tumor asli pakar medis.

- b. Peningkatan Kapasitas Arsitektur (YOLOv8l-seg): Penggunaan varian *Large* (L) membawa dampak signifikan dalam pemetaan fitur spasial global. Varian L memiliki jutaan parameter tambahan dan kedalaman jaringan konvolusi yang jauh lebih matang dibandingkan varian *Small* (S). Arsitektur yang lebih masif ini sangat peka dalam mempelajari geometri massa tumor yang tidak beraturan (*irregular*) serta mampu mengisolasi fitur lesi berukuran mikro (*micro-lesion*) secara presisi piksel demi piksel, sehingga menghindarkan model dari risiko salah lokalisasi (*False Negative*).

2. Evaluasi hasil modeling terhadap tujuan bisnis

Dalam koridor metodologi *Cross-Industry Standard Process for Data Mining* (CRISP-DM), tujuan bisnis (*business objectives*) dari penelitian ini adalah membangun sebuah sistem *Computer-Aided Diagnosis* (CAD) yang andal, berpresisi tinggi, dan stabil untuk membantu efisiensi serta akurasi kerja dokter spesialis radiologi dalam mendeteksi sekaligus memetakan batas luasan tumor otak secara objektif.

Evaluasi terhadap hasil pemodelan terbaru membuktikan bahwa Enhanced Model (CLAHE + Robust Z-Score + YOLOv8l-seg) telah memenuhi standar fungsionalitas emas sistem CAD medis secara superior. Keandalan integrasi ini ditunjukkan oleh nilai metrik validasi yang sangat tinggi, di mana skor mAP50 mencapai 0.86007 (86.00%) dan tingkat spesifisitas Precision menyentuh angka 0.86015 (86.01%). Keunggulan performa ini memberikan implikasi klinis yang sangat masif terhadap pemenuhan tujuan bisnis di lingkungan operasional rumah sakit:

- a. Eliminasi Risiko *Over-Diagnosis* (Alarm Palsu): Raihan nilai *Precision* yang tinggi (**0.86015**) pada *Enhanced Model* membuktikan bahwa optimalisasi kontras lokal adaptif sukses

menyingkirkan komponen artefak visual dan *noise* latar belakang. Hal ini memastikan sistem CAD mampu menekan kemunculan angka deteksi palsu (*False Positive*) secara ekstrem, sehingga jaringan otak normal yang sehat tidak akan didiagnosis secara keliru sebagai area lesi tumor yang dapat memicu kecemasan psikologis tidak perlu pada pasien.

- b. Minimalisasi Risiko *Under-Diagnosis* (Mencegah Tumor Terlewat): Lompatan dramatis pada nilai *Recall* validasi (**0.79707**) serta ketepatan geometri poligon *Dice Similarity Coefficient* (DSC) pada data uji murni yang mencapai **0.7153** mengonfirmasi bahwa model *Enhanced* sangat sensitif dalam menangkap eksistensi massa tumor. Melalui arsitektur Large yang lebih dalam, sistem CAD ini berhasil melokalisasi area tumor tanpa risiko terlewat (*False Negative*). Hal ini krusial untuk melindungi pasien dari bahaya *under-diagnosis* serta memberikan jaminan delineasi batas volume yang utuh guna merencanakan tindakan reseksi bedah saraf maupun radioterapi secara presisi.

Berbeda dengan skenario *Baseline* yang mengalami penurunan daya jangkauan fitur (skor DSC data uji hanya **0.5839**), *Enhanced Model* berhasil menyeimbangkan aspek deteksi dan presisi batas spasial secara linear, menjadikannya mesin penunjang keputusan klinis yang sangat ideal dan aman bagi pakar medis.

3. Apakah hasil sesuai dengan ekspektasi pada tahap Business Understanding?

Hasil akhir penelitian menunjukkan kesesuaian terhadap ekspektasi awal serta draf hipotesis yang telah dirumuskan pada tahap *Business Understanding*. Pada visualisasi hipotesis awal, diasumsikan bahwa pengintegrasian *pipeline enhanced preprocessing* yang tepat dipadukan dengan arsitektur yang kuat secara linear akan mendongkrak seluruh

komponen metrik evaluasi secara komprehensif, baik dari aspek lokalisasi objek maupun akurasi segmentasi masker pikselnya.

Realisasi eksperimen terbaru berhasil memvalidasi asumsi teoritis tersebut. Penyesuaian metodologi dengan mengeliminasi filter pemburam (*smoothing*) dan beralih fokus pada penajaman kontras lokal (CLAHE) serta standarisasi sebaran intensitas (*Robust Z-Score*) terbukti berjalan lurus dengan perluasan cakupan segmentasi otomatis arsitektur YOLOv8l-seg. Ekspektasi peningkatan kontras lokal berhasil dibuktikan oleh melonjaknya nilai *Precision* menjadi 0.86015. Lebih lanjut, ekspektasi kedekatan geometris poligon masker yang sempat gagal pada pengujian versi terdahulu, kini sukses dipatahkan dengan kemenangan telak nilai DSC *Enhanced* (**0.7153**) atas model *Baseline* (**0.5839**).

Eksplorasi empiris ini mengukuhkan landasan awal pada tahap *Business Understanding* proyek CAD, bahwa kualitas visual citra MRI T1-CE yang ditingkatkan secara terukur tanpa merusak detail tepi (*edge preservation*) berkorelasi positif terhadap kemampuan jaringan saraf konvolusional dalam mengekstraksi batas masker secara optimal. Hasil riset ini sepenuhnya berjalan sesuai dengan peta jalan operasional yang diharapkan.

4. Validitas dan generalisasi hasil

Validitas hasil dalam penelitian ini dijamin secara ketat melalui implementasi metodologi pemisahan data berbasis pasien (*Patient-Level Split*) pada tahap transformasi data. Dengan membagi partisi secara ketat (70% *train*, 20% *validation*, 10% *test*) berdasarkan identitas unik subjek pasien dan bukan mengacak potongan gambar secara serampangan, seluruh celah kebocoran data (*data leakage*) berhasil diputus secara total. Prosedur ini memberikan jaminan metodologis yang valid bahwa **359 citra pada set data uji (*testing set*)** benar-benar murni berstatus sebagai *unseen data* yang belum

pernah dipelajari oleh model selama proses pelatihan. Berbeda dengan riset konvensional yang membagi data secara acak pada tingkat gambar sehingga memicu bias memori model akibat menghafal karakteristik anatomi dari pasien yang sama, pengujian dalam penelitian ini mencerminkan kemampuan adaptasi sistem yang sesungguhnya di lingkungan klinis riil.

Berdasarkan standarisasi pengujian yang ketat tersebut, kemampuan generalisasi dari *Enhanced Model* terbukti sangat tinggi dan tangguh. Keberhasilan arsitektur YOLOv8l-seg dalam mempertahankan konsistensi performa saat dihadapkan pada 359 citra pasien baru—dengan raihan *mAP50* sebesar **0.86007**, *Precision* **0.86015**, serta rata-rata skor *Dice Similarity Coefficient* (DSC) mencapai **0.7153**—menjadi bukti empiris bahwa model mampu melakukan generalisasi fitur (*feature generalization*) secara mendalam. Jaringan saraf konvolusional ini terbukti tidak mengalami gejala *overfitting* maupun *underfitting*, melainkan mampu secara cerdas mengekstraksi dan menyegmentasi poligon tumor lintas subjek meskipun dihadapkan pada variasi bentuk massa tumor yang acak (*irregular*), perbedaan orientasi sudut pindai anatomi (*anatomical planes*), variasi ukuran lesi mikro (*micro-lesion*), hingga fluktuasi kontras bawaan dari berbagai mesin pemindai MRI yang berbeda.

Raihan skor kedekatan geometris DSC sebesar **0.7153** ini juga merupakan luaran yang sangat kompetitif dan objektif dalam domain visi komputer medis untuk kategori citra sekuens tunggal. Apabila dikomparasikan dengan beberapa penelitian terdahulu pada tabel tinjauan pustaka yang mencatatkan skor DSC di atas 90% (seperti Arora dkk. dan Yogalakshmi dkk.), terdapat perbedaan landasan fundamental pada jenis modalitas dataset yang digunakan. Penelitian-penelitian tersebut menggunakan dataset BraTS yang berbasis multi-modalitas dengan mengintegrasikan empat sekuens

sekaligus (T1, T1-CE, T2, dan FLAIR), sehingga model secara linear mendapatkan pasokan fitur struktural yang jauh lebih masif untuk memetakan edema dan inti tumor. Sebaliknya, penelitian ini secara mandiri menguji ketangguhan model pada kondisi klinis sekuens tunggal citra 2D MRI T1-CE dari Cheng Dataset yang memiliki tantangan batas lesi kabur (*fuzzy boundaries*) yang jauh lebih ekstrem. Dengan demikian, kombinasi nilai metrik yang dihasilkan oleh *Enhanced Model* dalam riset ini bukan sekadar angka di atas kertas, melainkan sebuah representasi performa jujur yang valid secara metodologis untuk menunjang keputusan klinis di masa depan.

5. Rekomendasi penerapan model (misalnya ke sistem prediksi riil)


Untuk mengadaptasi hasil penelitian ini ke dalam sistem prediksi riil di dunia klinis (*real-world deployment*), direkomendasikan beberapa strategi implementasi berikut:

- a. Integrasi Arsitektur Segmentasi Mandiri Berpresisi Tinggi: Berbeda dengan temuan pada uji coba awal yang mengindikasikan perlunya penggabungan dua model sekuensial akibat adanya dilema tarik-ulur (*trade-off*) performa, hasil eksperimen terbaru ini membuktikan signifikansi kapabilitas mandiri dari skenario *Enhanced*. Oleh karena itu, rekomendasi implementasi pada sistem diagnosis nyata sebaiknya dialihkan sepenuhnya menggunakan model tunggal berbasis kombinasi CLAHE dan YOLOv8l-seg ini. Model tersebut terbukti tidak hanya mumpuni dalam melokalisasi keberadaan lesi secara cepat pada fase penapisan awal, tetapi juga sekaligus mampu melukis perimeter poligon masker secara utuh dan akurat dalam satu kali tahapan komputasi (*single forward pass*). Pendekatan terpadu ini sangat ideal untuk diadopsi karena dapat memangkas kompleksitas arsitektur perangkat lunak serta

meringankan beban komputasi pada server rumah sakit tanpa menurunkan akurasi delineasi medis.

- b. Pengembangan Dasbor Interaktif (Streamlit): Model direkomendasikan untuk diintegrasikan ke dalam arsitektur aplikasi berbasis web seperti purwarupa Streamlit yang telah dikonseptualisasikan. Melalui antarmuka ini, pengguna (dokter/radiolog) dapat mengunggah citra MRI secara praktis dan langsung mendapatkan visualisasi hasil segmentasi secara *real-time*.
- c. Penyediaan Fitur *Manual Delineation Adjustment*: Di dalam sistem aplikasi riil, luaran poligon otomatis dari model sebaiknya dilengkapi dengan perkakas edit manual (*interactive manual adjustment tool*). Fitur ini memungkinkan dokter spesialis melakukan koreksi halus pada area tepi transisi atau edema pudar yang mungkin terpotong oleh sifat konservatif model.
- d. Ekspansi Data Multi-Modalitas: Untuk pengembangan sistem prediksi jangka panjang, direkomendasikan untuk meningkatkan kapasitas input model dari sekuens tunggal (T1-CE saja) menjadi multi-modalitas yang menggabungkan sekuens T1-CE, T2, dan FLAIR guna memperkaya informasi visual batas tumor dan area pembengkakan (*edema*).

36



Gambar 4.4 Gambar Antarmuka Purwarupa Aplikasi Segmentasi

26

BAB V

PENUTUP

A. Kesimpulan

Berdasarkan seluruh rangkaian eksperimen, analisis data kuantitatif, serta tahapan implementasi yang dilakukan dengan berpedoman pada metodologi CRISP-DM.

Pengembangan sistem segmentasi otomatis untuk area tumor otak menggunakan arsitektur **YOLOv8l-seg** (varian *Large*) telah berhasil dibangun dan diintegrasikan secara optimal bersama *pipeline enhanced preprocessing* murni berbasis kombinasi CLAHE dan normalisasi *Robust Z-Score*.

Penerapan *enhanced preprocessing* terbukti memberikan dampak positif dan linear terhadap peningkatan seluruh metrik evaluasi segmentasi citra MRI T1-CE. Berbeda dengan skenario pengujian terdahulu di mana filter pemburam menurunkan akurasi spasial, eliminasi filter spasial pada riset ini sukses menjaga integritas piksel transisi halus pada batas luar tumor (*fuzzy boundaries*).

Skenario *Enhanced Model* mencatatkan performa yang paling dominan, di mana pada set data validasi berhasil meraih nilai *Precision* sebesar 0.86015,

35

Recall 0.79707, dan *mAP50* 0.86007. Lebih lanjut, pengujian spasial pada 359 citra data uji murni (*unseen data*) memvalidasi keunggulan mutlak model *Enhanced* dengan raihan rata-rata skor *Dice Similarity Coefficient* (DSC) mencapai **0.7153**, mengungguli *Baseline Model* (citra mentah) yang hanya memperoleh skor DSC sebesar **0.5839**.

Keberhasilan model *Enhanced* membuktikan bahwa penajaman kontras lokal yang dipadukan dengan kapasitas parameter YOLOv8l-seg yang mendalam sangat andal dalam mengenali karakteristik lesi medis yang tidak beraturan (*irregular*) serta lesi berukuran mikro (*micro-lesion*). Sistem ini berhasil meminimalkan risiko salah diagnosis (*over-diagnosis* maupun *under-diagnosis*), sehingga sangat layak diimplementasikan sebagai purwarupa aplikasi *Computer-Aided Diagnosis* (CAD) interaktif untuk membantu tugas dokter spesialis radiologi.

B. Saran

Optimasi Nilai Batas Penajaman Kontras (*Hyperparameter Tuning Preprocessing*): Penelitian di masa mendatang disarankan untuk melakukan eksplorasi dan optimasi mendalam secara iteratif terhadap parameter ambang batas *Clip Limit* pada CLAHE maupun ukuran *tile grid*-nya. Proses pencarian titik ekuilibrium parameter pra-pemrosesan ini penting untuk menemukan tingkat kontras lokal paling ideal yang mampu mempertegas area hiperintens tumor tanpa memicu efek pencahayaan berlebih (*over-exposure*) pada jaringan sehat di sekitarnya.

Pemanfaatan Dataset Multi-Modalitas MRI: Mengingat penelitian ini masih terbatas pada penggunaan modalitas tunggal berupa sekuens MRI T1-CE, disarankan bagi peneliti selanjutnya untuk menguji ketangguhan model menggunakan dataset multi-modalitas yang menggabungkan fitur citra T1-CE, T2, dan FLAIR (*Fluid-Attenuated Inversion Recovery*). Penggabungan saluran (*channels*) multi-sekuens ini secara klinis dapat memperkaya informasi

struktural model, terutama dalam membedakan secara jelas batas antara massa tumor inti (*core tumor*) dengan area cairan pembengkakan sekitarnya (*edema*). Eksplorasi Arsitektur Varian Tertinggi dan Mekanisme Perhatian (*Attention*): Untuk semakin memperhalus tingkat presisi segmentasi poligon pada batas anatomi lesi yang sangat rumit, riset lanjutan dapat mengeksplorasi skala model yang lebih masif seperti **YOLOv8x-seg** (varian *Extra Large*). Selain itu, integrasi modul *Self-Attention* atau arsitektur berbasis *Vision Transformer* (ViT) sangat direkomendasikan karena terbukti lebih superior dalam menangkap konteks dependensi spasial global pada citra medis beresolusi tinggi.

Pengujian Klinis Lanjutan dan Uji Kegunaan (*Usability Testing*): Purwarupa aplikasi interaktif berbasis antarmuka grafis Streamlit yang telah dikembangkan sebaiknya diekspansi infrastrukturnya menuju server peladen komputasi awan (*cloud server*) agar dapat diakses secara fleksibel. Lebih lanjut, sistem ini perlu divalidasi kinerjanya secara langsung di lapangan melalui pengujian operasional (*Usability Testing*) dengan melibatkan pakar medis (*domain expert*) seperti dokter spesialis radiologi, guna mengukur tingkat penerimaan (*acceptance rate*) serta efisiensi waktu yang dihasilkan dalam membantu alur kerja diagnosis riil.