

# Implementasi Arsitektur U-Net Untuk Segmentasi Tumor Otak Otomatis Pada Citra MRI Dengan Data Pengujian Asli

1<sup>st</sup> Ammar Shidqi Dhamara  
S1 Teknik Biomedis  
Univeritas Telkom Kampus Purwokerto  
Purwokerto, Indonesia  
ammarsidqi@gmail.com

2<sup>nd</sup> Sevia Indah Purnama S.ST., M.T  
S1 Teknik Biomedis  
Univeritas Telkom Kampus Purwokerto  
Purwokerto, Indonesia  
seviaindah@telkomuniversity.ac.id

3<sup>rd</sup> Mas Aly Afandi S.ST., M.T  
S1 Teknik Telekomunikasi  
Univeritas Telkom Kampus Purwokerto  
Purwokerto, Indonesia  
alyafandi@telkomuniversity.ac.id

**Abstrak** -- Tumor otak merupakan pertumbuhan sel abnormal yang mengganggu fungsi otak. Deteksi dini penting untuk meningkatkan akurasi diagnosis, namun segmentasi manual citra MRI memerlukan keahlian tinggi. Penelitian ini mengimplementasikan arsitektur U-Net sebagai metode segmentasi otomatis pada citra MRI menggunakan data asli dari Rumah Sakit Islam Jakarta Cempaka Putih. Eksperimen dilakukan dengan variasi *epoch* (20–100) dan *Learning rate* ( $1e^{-3}$  dan  $1e^{-4}$ ). Konfigurasi terbaik diperoleh pada *Learning rate*  $1e^{-4}$  dan 100 *epoch* dengan *Dice Coefficient* 0,88 dan *IoU* 0,78. Sistem U-Net ini dapat meningkatkan efisiensi dan akurasi diagnosis tumor otak.

**Kata kunci** : Tumor otak, MRI, Segmentasi, U-Net, Deep Learning

## I. PENDAHULUAN

Tumor otak adalah pertumbuhan sel abnormal di dalam otak yang dapat bersifat jinak maupun ganas [1]. Kondisi ini dapat menyebabkan gangguan neurologis seperti kejang, penurunan fungsi kognitif, serta peningkatan tekanan intrakranial [2]. Berdasarkan data Global Cancer Observatory tahun 2022, tercatat sebanyak 321.731 kasus baru tumor otak secara global dengan angka kematian tinggi, termasuk di Indonesia [3]. Tingginya angka kematian ini salah satunya disebabkan oleh keterlambatan diagnosis akibat keterbatasan alat dan metode manual yang masih digunakan [4].

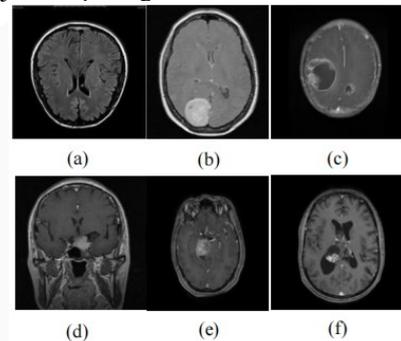
Pemeriksaan menggunakan Magnetic Resonance Imaging (MRI) menjadi metode utama dalam mendeteksi keberadaan tumor karena mampu menampilkan diferensiasi jaringan otak secara rinci [5]. Namun, proses segmentasi secara manual pada citra MRI dinilai tidak efisien, bergantung pada keahlian operator, dan rawan kesalahan [6]. Untuk mengatasi hal ini, pendekatan berbasis Deep Learning seperti U-Net banyak digunakan karena mampu mempelajari pola spasial pada citra medis secara menyeluruh [7].

Pada penelitian ini, dilakukan implementasi arsitektur U-Net untuk segmentasi tumor otak otomatis pada citra MRI menggunakan dataset asli dari Rumah Sakit Islam Jakarta Cempaka Putih, bukan dataset publik. Tujuan dari penelitian ini adalah untuk mengevaluasi performa model terhadap data klinis riil dan menganalisis pengaruh variasi hyperparameter seperti jumlah *epoch* dan *Learning rate* terhadap akurasi segmentasi.

## II. KAJIAN TEORI

### A. Tumor Otak

Tumor otak merupakan pertumbuhan sel abnormal di otak yang dapat bersifat jinak maupun ganas. Jenis-jenis tumor seperti glioma, meningioma, dan adenoma hipofisis dapat mengganggu fungsi otak seperti kontrol motorik, emosi, hingga kemampuan kognitif [8]. Tumor ini dapat menyebabkan peningkatan tekanan intrakranial, kejang, penglihatan kabur, dan gejala neurologis lainnya, sehingga diperlukan deteksi dini yang akurat. [9]. Gambar tumor otak ditunjukkan pada gambar 1 dibawah ini.



GAMBAR 1  
(TUMOR OTAK CITRA MRI) [10].

Berdasarkan gambar 1, gambar (a) merupakan otak normal, gambar (b) tumor otak pada bagian meningioma, gambar (c) tumor otak pada bagian glioma, gambar (d) tumor otak pada bagian pituitary, gambar (e) tumor otak pada bagian schwannoma, gambar (f) tumor otak pada bagian neurocytoma.

### B. Magnetic Resonance Imaging (MRI)

MRI adalah teknik pencitraan non-invasif yang sangat efektif untuk melihat struktur jaringan lunak otak. MRI menghasilkan potongan gambar dalam berbagai orientasi seperti *axial*, *coronal*, dan *sagittal*. Keunggulan utama MRI dalam mendeteksi tumor otak adalah kemampuannya menampilkan detail anatomi otak dengan jelas, termasuk diferensiasi jaringan seperti *white matter* dan *gray matter*[11].

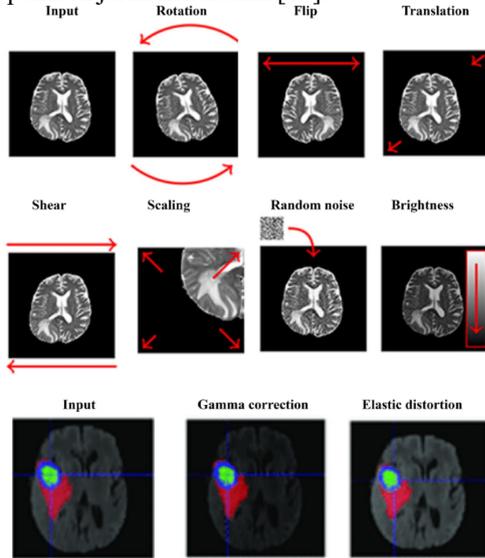
### C. Segmentasi

Segmentasi adalah proses membagi citra menjadi bagian-bagian yang bermakna. Dalam konteks medis,

segmentasi digunakan untuk memisahkan jaringan normal dari jaringan patologis seperti tumor, yang menjadi sangat penting dalam diagnosa dan perencanaan terapi [12].

#### D. Augmentasi

Augmentasi gambar adalah teknik yang digunakan untuk meningkatkan volume dan variasi data gambar dengan memodifikasi data asli atau menciptakan data baru secara sintetis. Tujuan utama dari augmentasi gambar adalah untuk mengatasi tantangan pengumpulan data yang mahal dan sulit, sekaligus meningkatkan generalisasi model pembelajaran mendalam [13].



GAMBAR 2 (AUGMENTASI CITRA OTAK) [14].

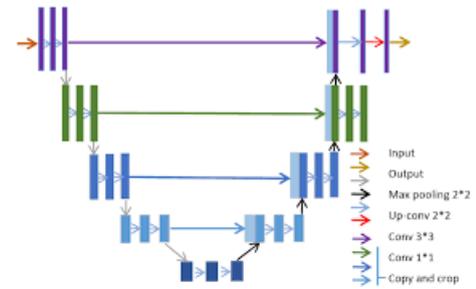
Pada gambar 2 beberapa teknik augmentasi yang umum dilakukan seperti teknik *rotation*, *flip*, *translation*, *shear*, *scalling*, *random noise* dan *brightness*.

#### E. Deep Learning

*Deep Learning* adalah metode pembelajaran mesin dengan menggunakan jaringan saraf tiruan berlapis [15]. CNN adalah jenis jaringan saraf yang efektif dalam memproses data berbentuk grid seperti gambar, melalui lapisan konvolusi yang mampu mengekstraksi fitur spasial dari citra [16].

#### F. U-NET

U-Net adalah arsitektur CNN yang dirancang untuk segmentasi citra, khususnya pada aplikasi biomedis. U-Net memiliki struktur simetris *encoder-decoder* yang memungkinkan pemrosesan citra resolusi tinggi dengan memanfaatkan fitur lokal dan global melalui *skip connection*. Lebih lengkap nya arsitektur U-Net digambarkan seperti berbentuk huruf “U”, dimana pada sisi kiri merupakan bagian *encoder*, dan pada sisi kanan merupakan bagian *decoder* [17]. Hal ini dapat dilihat pada gambar arsitektur U-Net pada gambar 3.



GAMBAR 3 (ARSITEKTUR U-NET)[18]

#### G. Metrik Evaluasi

Dalam penelitian segmentasi citra medis, diperlukan metrik evaluasi yang mampu menilai tingkat akurasi antara hasil segmentasi model dengan *ground truth* yang tersedia. Tiga metrik utama yang umum digunakan dalam evaluasi performa model segmentasi adalah *Intersection over Union (IoU)*, *Dice Coefficient (DSC)*, dan *Binary Cross-Entropy (BCE) Loss*. Ketiga metrik ini memberikan sudut pandang berbeda dalam mengukur kesesuaian prediksi model terhadap label asli, baik dari segi area tumpang tindih, kesamaan bentuk, maupun seberapa besar kesalahan prediksi secara keseluruhan. Berikut penjelasan ketiganya:

##### 1. Intersection Over Union

Mengukur seberapa besar tumpang tindih antara prediksi dan *ground truth*. Nilainya berkisar dari 0 (tidak cocok) hingga 1 (sempurna) [19].

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

- A adalah area hasil segmentasi model,
- B adalah area *ground truth*,
- $|A \cap B|$  adalah jumlah piksel yang tumpang tindih (benar terdeteksi),
- $|A \cup B|$  adalah total gabungan area prediksi dan *ground truth*.

Nilai IoU berada pada rentang 0 sampai 1, dengan nilai mendekati 1 menunjukkan segmentasi yang sangat akurat [20].

##### 2. Dice Coefficient

DSC mengukur kemiripan antara dua set piksel. Rumus ini sangat berguna dalam kasus data tidak seimbang, seperti segmentasi tumor, karena lebih toleran terhadap perbedaan ukuran objek [21].

$$DSC = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (2)$$

- $|A|$  dan  $|B|$  masing-masing adalah jumlah piksel pada hasil segmentasi dan *ground truth*,
- $|A \cap B|$  adalah jumlah piksel yang benar tersegmentasi.

Nilai DSC juga berkisar antara 0 hingga 1. Semakin tinggi nilai *Dice*, maka segmentasi semakin akurat [22].

##### 3. Binary Cross-Entropy Loss

BCE digunakan sebagai fungsi kerugian (*Loss function*) untuk mengukur seberapa jauh perbedaan prediksi model terhadap label asli (*ground truth*) dalam klasifikasi biner [23].

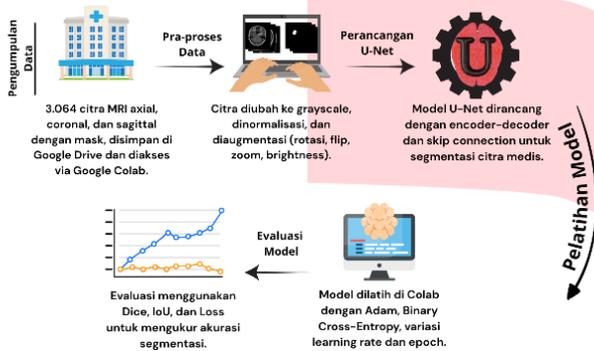
$$L_{BCE}(y, \hat{y}) = -(y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})) \quad (3)$$

- y adalah label sebenarnya (*ground truth*)

- $\hat{y}$  adalah probabilitas prediksi model untuk kelas positif (tumor)  
Fungsi ini digunakan sebagai dasar optimasi model selama proses pelatihan [24].

### III. METODE

Penelitian ini dilakukan dengan pendekatan eksperimental menggunakan data citra *Magnetic Resonance Imaging* (MRI) otak dari Rumah Sakit Islam Jakarta Cempaka Putih. Penelitian dilaksanakan selama Januari hingga Mei 2025, dengan tujuan mengimplementasikan dan mengevaluasi kinerja arsitektur U-Net dalam segmentasi otomatis tumor otak. Untuk tahapan penelitian ini di ilustrasikan dalam gambar ().



GAMBAR 4  
ILUSTRASI TAHAPAN PENELITIAN

Berdasarkan gambar 4 Tahapan dalam penelitian ini dijelaskan sebagai berikut:

#### A. Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari 3.064 citra MRI otak yang telah diberi label secara manual menggunakan mask sebagai *ground truth*. Citra yang digunakan meliputi tiga orientasi yaitu axial, coronal, dan sagittal. Seluruh data disimpan dalam Google Drive dan terintegrasi dengan Google Colab untuk proses pengolahan.

#### B. Pra-pemrosesan Data

Citra MRI dikonversi ke format *grayscale* dan dinormalisasi ke rentang piksel (0 dan 1). Tahap ini dilanjutkan dengan proses augmentasi untuk meningkatkan variasi data pelatihan dan mengurangi risiko *overfitting*. Teknik augmentasi yang diterapkan antara lain rotasi, *flipping* horizontal dan vertikal, *zooming*, serta penyesuaian *brightness*.

#### C. Perancangan Arsitektur U-Net

Model segmentasi yang digunakan adalah U-Net, yang terdiri dari dua bagian utama yaitu *encoder* dan *decoder*. *Encoder* berfungsi mengekstraksi fitur melalui lapisan konvolusi dan *max-pooling*, sementara *decoder* bertugas merekonstruksi citra segmentasi menggunakan *upsampling* serta *concatenation* dengan fitur dari *encoder* melalui mekanisme *skip connection*. U-Net dipilih karena efektif dalam menangani segmentasi citra medis beresolusi tinggi dan mampu bekerja baik meskipun data pelatihan terbatas.

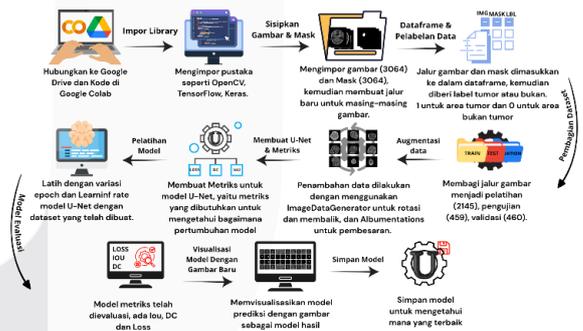
#### D. Pelatihan Model

Model dilatih menggunakan *framework* TensorFlow dengan algoritma optimasi Adam dan fungsi *Loss Binary Cross-Entropy*. Proses pelatihan dilakukan dengan variasi *Learning rate* sebesar  $1e^{-3}$  dan  $1e^{-4}$ , serta jumlah *epoch* yang bertingkat yaitu 20, 40, 60, 80, dan 100 *epoch*. Pelatihan dijalankan di Google Colab yang mendukung GPU, untuk efisiensi waktu dan performa komputasi.

#### E. Evaluasi Model

Evaluasi performa model dilakukan menggunakan tiga metrik utama, yaitu *Dice Coefficient*, *Intersection over Union* (IoU), dan *Binary Cross-Entropy Loss*. *Dice Coefficient* digunakan untuk mengukur kesamaan antara area prediksi dan *ground truth*. IoU digunakan untuk mengukur persentase tumpang tindih antara hasil prediksi dan area sebenarnya. Sedangkan *Binary Cross-Entropy Loss* digunakan untuk menilai besarnya kesalahan prediksi model terhadap label aktual.

Berdasarkan uraian dari tahapan penelitian di atas. Penulis membuat ilustrasi alur perancangan sistem yang lebih dikembangkan lagi. gambaran umum dari sistem yang dirancang dalam penelitian ini dapat dilihat pada Gambar 5. Ilustrasi Diagram tersebut memperlihatkan alur sistem segmentasi tumor otak secara otomatis menggunakan model U-Net, yang dimulai dari integrasi data, tahap pra-pemrosesan, pelatihan model, hingga evaluasi dari setiap model sampai dengan penyimpanan setiap model.



GAMBAR 5  
ILUSTRASI PEMBUATAN SISTEM PENDETEKSI TUMOR DENGAN ARSITEKTUR U-NET

Berdasarkan gambar 5 terkait thapan pembuatan sistem pendeteksi tumor otak dengan arsitektur U-Net, berikut penjelasan setiap tahapannya:

#### A. Integrasi Google Colab dan Google Drive

Penelitian ini diawali dengan mengintegrasikan Google Colab dengan Google Drive untuk mendukung pemrosesan data secara *cloud-based*. Google Drive digunakan sebagai media penyimpanan dataset citra MRI otak dan hasil segmentasinya, sementara Google Colab digunakan untuk menjalankan seluruh proses komputasi, mulai dari *preprocessing*, pelatihan, hingga evaluasi model, dengan dukungan GPU untuk mempercepat kinerja.

#### B. Import library dan inialisasi kode

Setelah integrasi berhasil, tahap selanjutnya adalah mengimpor *library* yang diperlukan, seperti TensorFlow, NumPy, Pandas, dan Albumentations. Library ini digunakan untuk mendukung proses manipulasi data, augmentasi, visualisasi, pembuatan model, serta evaluasi performa model segmentasi. Selain itu, dilakukan juga inialisasi *path direktori*, parameter *training*, dan konfigurasi lainnya dalam bentuk skrip Python.

#### C. Load dataset citra dan *mask*

Dataset yang digunakan terdiri dari 3.064 citra MRI otak dalam tiga orientasi (*axial*, *sagittal*, dan *coronal*) yang telah dilabeli secara manual menggunakan *mask* sebagai *ground truth*. Citra dan *mask* dimuat dari direktori di Google Drive, lalu disusun dalam format yang terstruktur agar dapat diproses dalam *pipeline* pelatihan model.

#### D. Pembuatan *dataframe* dan *labelling*

Citra dan *mask* yang telah dimuat selanjutnya disusun ke dalam sebuah *dataframe*, yang berfungsi sebagai struktur data utama yang menghubungkan antara gambar *input* dan *mask* target. *Dataframe* ini berisi *path file*, label, dan informasi tambahan lainnya yang akan digunakan untuk proses data generator selama pelatihan model.

#### E. Pembagian dataset

Dataset kemudian dibagi menjadi tiga subset: *training*, *validation*, dan *testing*. Pembagian ini bertujuan untuk mengevaluasi performa model secara objektif serta menghindari *overfitting*. Subset *training* digunakan untuk melatih model, *validation* untuk memantau performa selama pelatihan, dan *testing* untuk menguji kemampuan generalisasi model terhadap data baru yang tidak dikenali sebelumnya.

#### F. Pra-pemrosesan dan Augmentasi data

Pra-pemrosesan dilakukan untuk menyiapkan citra agar sesuai dengan format *input* model. Tahapan ini mencakup konversi citra ke format *grayscale* dan normalisasi nilai piksel ke rentang 0–1. Selanjutnya dilakukan augmentasi data untuk meningkatkan keragaman dataset dengan teknik seperti rotasi, *flipping* horizontal dan vertikal, *zoom*, serta penyesuaian *brightness*. Augmentasi ini bertujuan untuk meningkatkan ketahanan model terhadap variasi data.

#### G. Perancangan arsitektur U-Net

Model segmentasi yang digunakan dalam penelitian ini adalah U-Net, yang merupakan arsitektur *convolutional neural network* (CNN) khusus untuk tugas segmentasi. U-Net memiliki dua bagian utama, yaitu *encoder* untuk mengekstraksi fitur citra dan *decoder* untuk merekonstruksi hasil segmentasi. *Skip connection* digunakan untuk menghubungkan fitur antara encoder dan decoder agar model dapat mempertahankan detail spasial pada hasil segmentasi.

#### H. Pelatihan Model

Proses pelatihan model dilakukan menggunakan *framework* TensorFlow dengan algoritma optimasi Adam dan fungsi *Loss Binary Cross-Entropy*. Model dilatih dengan berbagai variasi parameter, termasuk *Learning rate*

( $1e^{-3}$  dan  $1e^{-4}$ ) dan jumlah *epoch* (20, 40, 60, 80, dan 100). Seluruh proses pelatihan dijalankan di Google Colab dengan memanfaatkan GPU untuk meningkatkan efisiensi komputasi.

#### I. Evaluasi model

Model yang telah dilatih dievaluasi menggunakan tiga metrik utama: *Dice Coefficient*, *Intersection over Union* (IoU), dan *Binary Cross-Entropy Loss*. *Dice Coefficient* digunakan untuk mengukur tingkat kesamaan antara hasil segmentasi model dan *mask ground truth*. IoU mengukur proporsi tumpang tindih antara area prediksi dan area sebenarnya, sedangkan *Binary Cross-Entropy Loss* menghitung besar kesalahan prediksi model terhadap label asli.

#### J. Visualisasi hasil segmentasi

Tahapan akhir dari sistem adalah visualisasi hasil segmentasi tumor otak. Citra hasil prediksi dibandingkan secara visual dengan *ground truth mask* untuk menilai keakuratan segmentasi secara kualitatif. Visualisasi ini membantu dalam memahami performa model secara lebih intuitif dan menjadi dasar pengambilan keputusan terhadap efektivitas sistem yang dikembangkan.

Dengan dilakukannya proses pelatihan model menggunakan arsitektur U-Net serta serangkaian konfigurasi *hyperparameter* seperti jumlah *epoch* dan nilai *Learning rate*, maka diperoleh beberapa model dengan performa yang bervariasi. Tahapan-tahapan yang telah dijelaskan pada bab ini menjadi dasar dalam mengevaluasi efektivitas masing-masing konfigurasi terhadap kemampuan segmentasi tumor otak.

## IV. HASIL DAN PEMBAHASAN

Pelatihan model segmentasi dilakukan menggunakan arsitektur U-Net pada citra MRI otak yang mengandung tumor. Dataset terdiri dari 3.064 citra, yang dibagi menjadi 2.213 data pelatihan, 460 data validasi, dan 391 data pengujian. Citra-citra ini merupakan data asli dari Rumah Sakit Islam Jakarta Cempaka Putih, lengkap dengan *mask ground truth* yang diperoleh dari ahli radiologi. Model dievaluasi menggunakan metrik *Dice Coefficient*, *Intersection over Union* (IoU), dan *Loss*, baik pada data pelatihan, validasi, maupun pengujian.

#### A. Analisis variasi jumlah *epoch* dengan *Learning rate* tetap ( $1e^{-3}$ )

Analisis ini dilakukan untuk mengevaluasi pengaruh jumlah *epoch* terhadap performa model segmentasi, dengan *Learning rate* tetap sebesar  $1e^{-3}$ . Lima konfigurasi jumlah *epoch* yang diuji adalah 20, 40, 60, 80, dan 100 *epoch*. Setiap konfigurasi dievaluasi berdasarkan performa pada data pelatihan dan validasi berdasarkan nilai – nilai terbaik yang dihasilkan menggunakan metrik *Dice Coefficient*, *Intersection over Union* (IoU), dan *Loss*. Hasil pada analisa ini dapat ditunjukkan pada tabel 1.

TABEL 1  
HASIL ANALISA VARIASI EPOCH DENGAN LEARNING RATE 1E<sup>-3</sup>

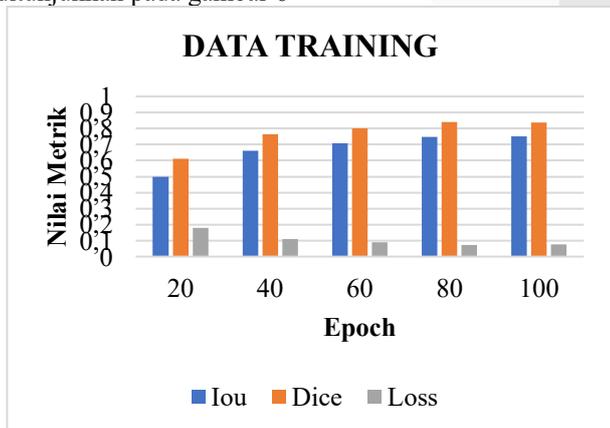
Learning rate 1e-3	Data Training			
	Epoch	Iou	Dice	Loss
	20	0,4970	0,6106	0,1790
	40	0,6626	0,7644	0,1087
	60	0,7068	0,8024	0,0909
	80	0,7487	0,8394	0,0739
	100	0,7495	0,8382	0,0747
	Data Validation			
	Epoch	Iou	Dice	Loss
	20	0,4628	0,5780	0,1905
	40	0,6226	0,7170	0,1275
60	0,6755	0,7711	0,1055	
80	0,6686	0,7665	0,1077	
100	0,6649	0,7591	0,1104	

Berdasarkan tabel 1, dengan nilai *Learning rate* yang tetap sebesar  $1e^{-3}$ . Jumlah *epoch* divariasikan sebanyak lima konfigurasi, yaitu 20, 40, 60, 80, dan 100 *epoch*. Evaluasi dilakukan menggunakan metrik *Dice Coefficient*, *Intersection over Union* (IoU), dan *Loss* pada data pelatihan serta validasi.

Hasil pada data pelatihan menunjukkan peningkatan metrik secara konsisten seiring bertambahnya jumlah *epoch*. Nilai IoU meningkat dari 0,4970 pada 20 *epoch* menjadi 0,7495 pada 100 *epoch*, dan *Dice Coefficient* dari 0,6106 menjadi 0,8382. Selain itu, *Loss* menurun dari 0,1790 menjadi 0,0747, yang mengindikasikan proses pembelajaran model berjalan efektif selama pelatihan.

Namun, pada data validasi terlihat tren berbeda. Performa terbaik justru dicapai pada *epoch* ke-60, dengan IoU sebesar 0,6755, *Dice Coefficient* 0,7711, dan *Loss* 0,1055. Setelahnya, meskipun performa pelatihan terus meningkat, nilai metrik validasi mulai menurun secara perlahan, seperti terlihat pada *epoch* ke-100 dengan *Dice Coefficient* turun menjadi 0,7591 dan *Loss* naik menjadi 0,1104.

Dengan mempertimbangkan keseimbangan antara performa pelatihan dan validasi, dapat disimpulkan bahwa 60 *epoch* merupakan konfigurasi optimal untuk *Learning rate*  $1e^{-3}$ . Hal ini dapat dilihat pada tren grafik yang ditunjukkan pada gambar 6



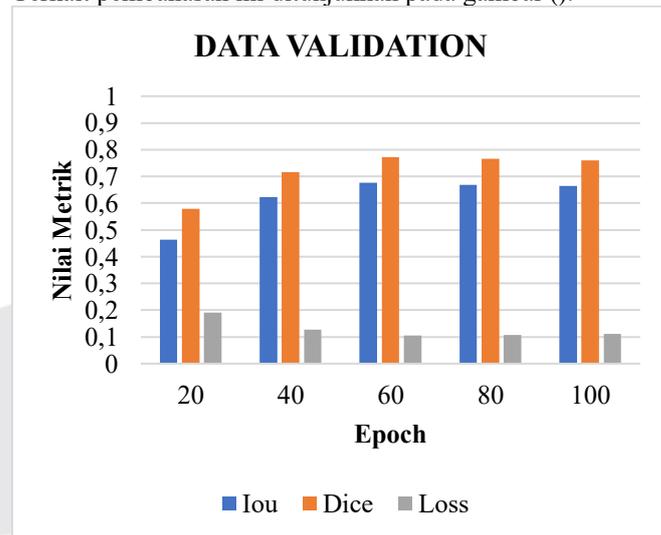
GAMBAR 6  
GRAFIK DATA TRAINING

Berdasarkan gambar 6, Berdasarkan grafik performa pada data pelatihan terhadap variasi jumlah *epoch*, terlihat adanya peningkatan konsisten pada nilai IoU dan *Dice Coefficient*, serta penurunan bertahap pada nilai *Loss* seiring bertambahnya jumlah *epoch*. Pada *epoch* ke-20, model mencatat IoU sebesar 0,4970 dan *Dice* 0,6106, dengan *Loss* relatif tinggi sebesar 0,1790. Seiring peningkatan *epoch* menjadi 40, performa meningkat signifikan, dengan IoU mencapai 0,6626 dan *Dice* 0,7644, serta *Loss* menurun drastis menjadi 0,1087.

Peningkatan terus berlanjut hingga *epoch* ke-60, di mana nilai *Dice* mencapai 0,8024 dan IoU sebesar 0,7068, menunjukkan bahwa model mulai belajar fitur segmentasi dengan baik. Pada *epoch* 80 dan 100, kualitas pelatihan terus meningkat secara marginal, dengan nilai *Dice* tertinggi sebesar 0,8394 (*epoch* 80) dan *Loss* terendah sebesar 0,0739 (*epoch* 100). Penurunan *Loss* yang stabil dan peningkatan metrik segmentasi menunjukkan bahwa model mampu melakukan pembelajaran secara efektif dan belum mengalami *overfitting* pada data pelatihan.

Secara keseluruhan, grafik ini mengindikasikan bahwa penambahan jumlah *epoch* berdampak positif terhadap kemampuan model dalam memahami pola data pelatihan, meskipun peningkatannya menjadi semakin kecil setelah *epoch* ke-60.

Kemudian analisa terkait grafik pada data *validation*, analisa ini bertujuan untuk mengetahui sejauh mana model dapat mempelajari data pada data *validation*. Dari data *validation* ini akan diketahui sejauh mana model dapat meregeneralisasi citra MRI tumor otak untuk dideteksi. Terkait pembahasan ini ditunjukkan pada gambar ().



GAMBAR 7  
GRAFIK DATA VALIDATION

Berdasarkan gambar 7. grafik performa pada data validasi, terlihat bahwa peningkatan jumlah *epoch* memberikan dampak yang signifikan terhadap kemampuan generalisasi model hingga titik tertentu. Pada *epoch* ke-20, model memperoleh IoU sebesar 0,4628, *Dice Coefficient* 0,5780, dan *Loss* sebesar 0,1905, yang mencerminkan performa awal yang masih rendah. Nilai-nilai tersebut meningkat secara signifikan pada *epoch* ke-40, di mana IoU naik menjadi 0,6226 dan *Dice* mencapai 0,7170, serta *Loss* menurun drastis menjadi 0,1275.

Performa tertinggi tercapai pada *epoch* ke-60, dengan IoU sebesar 0,6755, *Dice* 0,7711, dan *Loss* turun menjadi 0,1055. Hal ini menunjukkan bahwa pada titik tersebut, model berada pada kondisi yang optimal dalam menyeimbangkan proses pembelajaran dan kemampuan generalisasi terhadap data yang tidak dilatih sebelumnya. Namun, pada *epoch* selanjutnya (80 dan 100), meskipun nilai *Dice* dan IoU masih tergolong tinggi, tidak terdapat peningkatan signifikan. Bahkan terjadi sedikit penurunan performa validasi, misalnya pada *epoch* ke-100 nilai *Dice* turun ke 0,7591 dan *Loss* naik menjadi 0,1104.

Temuan ini mengindikasikan bahwa penambahan *epoch* setelah titik optimal justru berisiko menyebabkan *overfitting*, di mana model terlalu menyesuaikan data pelatihan dan kehilangan efektivitas saat diuji pada data baru. Dengan demikian, grafik ini menguatkan bahwa konfigurasi terbaik untuk jumlah *epoch* pada *learning rate*  $1e^{-3}$  adalah 60 *epoch*, yang menghasilkan performa validasi paling stabil dan optimal.

#### B. Analisis variasi *Learning rate* pada *epoch* tetap

Setelah menentukan jumlah *epoch* yang optimal, analisis dilanjutkan dengan mengevaluasi pengaruh variasi nilai *learning rate* terhadap performa model, dengan jumlah *epoch* tetap sebanyak 100. Dua konfigurasi *Learning rate* diuji, yaitu  $1e^{-3}$  dan  $1e^{-4}$ , yang kemudian dibandingkan berdasarkan hasil pelatihan dan validasi. Analisis ini ditunjukkan pada tabel 2 yang menunjukkan hasil pengaruh *Learning rate*  $1e^{-3}$  dan  $1e^{-4}$  terhadap *epoch* tetap (*epoch* 100).

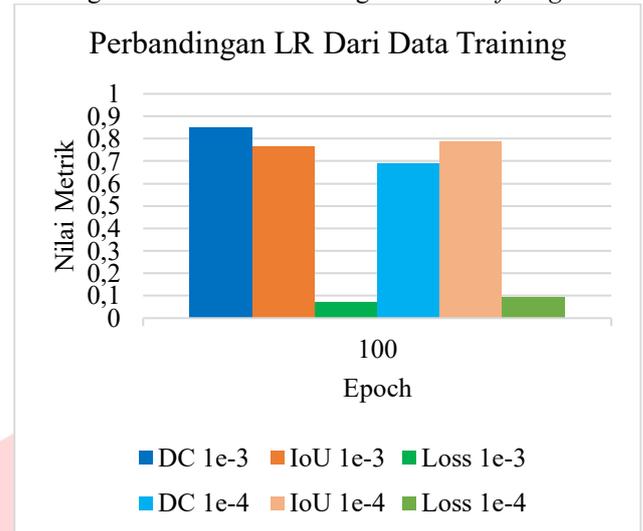
TABEL 2  
HASIL PEMBELAJARAN MODEL U-NET DARI DATA TRAINING & VALIDATION

LR	EP	DC	IoU	Loss	
	100	0,8509	0,7681	0,0691	
$1e^{-3}$	100	0,7591	0,6649	0,1104	Data Validation
	EP	DC	IoU	Loss	
$1e^{-4}$	100	0,6903	0,7891	0,0964	
	100	0,7892	0,6963	0,0964	Data Validation

Pada tabel 2, konfigurasi *Learning rate*  $1e^{-3}$ , model menunjukkan performa pelatihan yang tinggi, dengan *Dice Coefficient* mencapai 0,8382, IoU sebesar 0,7495, dan *Loss* sebesar 0,0747. Namun, pada data validasi, model justru menunjukkan adanya penurunan performa dengan *Dice* sebesar 0,7591, IoU 0,6649, dan *Loss* meningkat menjadi 0,1104. Ini menandakan bahwa meskipun model berhasil belajar dengan baik pada data pelatihan, kemampuan generalisasinya terhadap data baru menjadi terbatas, yang merupakan indikasi *overfitting*.

Pada konfigurasi *Learning rate*  $1e^{-4}$ , model belajar lebih stabil. Nilai validasi optimal dengan *Dice* 0,8891, IoU

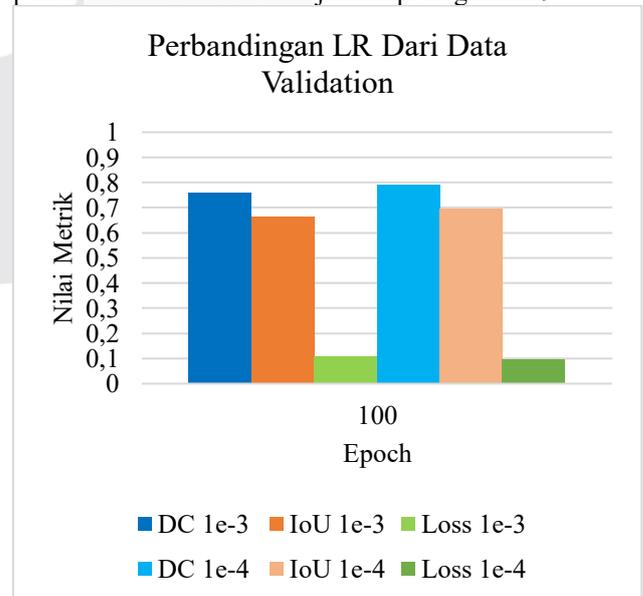
0,8121, dan *Loss* 0,0748. *Learning rate* kecil membantu konvergensi lebih baik dan menghindari *overfitting*.



GAMBAR 8  
PERBANDINGAN VARIASI *LEARNING RATE* DENGAN *EPOCH* 100 PADA DATA TRAINING.

Grafik menunjukkan performa model pada data pelatihan untuk *Learning rate*  $1e^{-3}$  dan  $1e^{-4}$ . Model dengan *Learning rate*  $1e^{-3}$  mencapai *Dice* 0,8509 dan *Loss* 0,0691, sedangkan *Learning rate*  $1e^{-4}$  memiliki performa lebih stabil meski nilai *Dice* lebih rendah. Temuan ini menunjukkan bahwa model dengan *Learning rate* lebih tinggi ( $1e^{-3}$ ) memiliki kecepatan konvergensi yang lebih baik terhadap data pelatihan, terbukti dari tingginya nilai *Dice* dan rendahnya *Loss*.

Meskipun performa pada data pelatihan menunjukkan bahwa model dengan *learning rate*  $1e^{-3}$  memiliki akurasi yang lebih tinggi, hal tersebut belum tentu mencerminkan kemampuan generalisasi model secara keseluruhan. Oleh karena itu, diperlukan analisis lanjutan pada data validasi untuk menilai kestabilan dan efektivitas model dalam menghadapi data yang belum pernah dilihat selama pelatihan. Hal tersebut ditunjukkan pada gambar 9.



GAMBAR 9  
PERBANDINGAN VARIASI *LEARNING RATE* DENGAN *EPOCH* 100 PADA DATA VALIDATION

Pada gambar 9, grafik perbandingan performa validasi antara model dengan *learning rate*  $1e^{-3}$  dan  $1e^{-4}$  menunjukkan bahwa model dengan *Learning rate*  $1e^{-4}$  memberikan hasil yang lebih stabil dan akurat dalam melakukan generalisasi terhadap data yang belum pernah dilihat. Pada konfigurasi *Learning rate*  $1e^{-3}$ , model mencapai *Dice Coefficient* sebesar 0,7591, *IoU* sebesar 0,6649, dan *Loss* sebesar 0,1104. Sementara itu, pada konfigurasi *earning rate*  $1e^{-4}$ , model mencatatkan nilai *Dice Coefficient* sebesar 0,7892, *IoU* sebesar 0,6963, dan *Loss* lebih rendah sebesar 0,0964.

Kenaikan nilai metrik *Dice* dan *IoU*, serta penurunan nilai *Loss* pada *learning rate*  $1e^{-4}$ , menunjukkan bahwa model dengan konfigurasi ini lebih optimal dalam menyeimbangkan proses pembelajaran dan kemampuan generalisasi. Hal ini mengindikasikan bahwa nilai *Learning rate* yang lebih kecil memungkinkan model melakukan pembaruan bobot secara lebih hati-hati dan stabil, sehingga meminimalisir risiko *overfitting* yang terjadi pada *Learning rate* yang lebih tinggi.

Berdasarkan hasil eksperimen dan visualisasi performa pada data pelatihan dan validasi, dapat disimpulkan bahwa *Learning rate*  $1e^{-4}$  menghasilkan performa segmentasi tumor otak yang lebih baik dan stabil dibandingkan *Learning rate*  $1e^{-3}$ . Meskipun *Learning rate*  $1e^{-3}$  menunjukkan akurasi pelatihan yang tinggi, model dengan *Learning rate*  $1e^{-4}$  lebih unggul dalam hal generalisasi, ditandai dengan metrik validasi yang lebih tinggi dan nilai *Loss* yang lebih rendah. Oleh karena itu, konfigurasi terbaik dari aspek *Learning rate* pada *epoch* tetap (100 *epoch*) adalah *Learning rate*  $1e^{-4}$ .

### C. Evaluasi performa model melalui visualisasi segmentasi dan perhitungan metrik evaluasi pada data testing.

Evaluasi akhir dilakukan untuk menilai kemampuan model dalam segmentasi tumor otak pada data uji yang tidak dilibatkan dalam pelatihan. Hasil evaluasi ditampilkan pada tabel 3.

TABEL 3  
HASIL EVALUASI METRIK PADA DATA TRAINING

Data Testing	Epoch	IoU	Dice	Loss	LR $1e^{-3}$	
	20	0,4921	0,6085	0,1754		
	40	0,6470	0,7397	0,1184		
	60	0,6830	0,7732	0,1035		
	80	0,6860	0,7776	0,1041		
	100	0,6667	0,7597	0,1097		
Data Testing	Epoch	IoU	Dice	Loss	LR $1e^{-4}$	
	20	0,6052	0,6998	0,1373		
	40	0,6509	0,7407	0,1182		
	60	0,6562	0,746	0,1144		
	80	0,6931	0,7856	0,0997		
	100	0,7077	0,795	0,0952		

Pada tabel 3, Evaluasi akhir dilakukan pada data uji untuk menilai kemampuan generalisasi model terhadap data yang benar-benar belum dilibatkan dalam proses pelatihan. Terlihat bahwa baik model dengan *Learning rate*

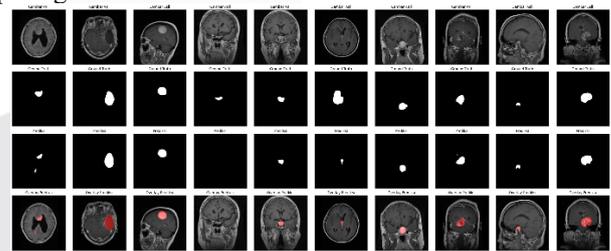
$1e^{-3}$  maupun  $1e^{-4}$  menunjukkan tren peningkatan performa seiring dengan bertambahnya jumlah *epoch*, meskipun dengan pola yang berbeda.

Pada *learning rate*  $1e^{-3}$ , nilai tertinggi untuk metrik *IoU* dan *Dice* masing-masing diperoleh pada *epoch* ke-80, yaitu *IoU* sebesar 0,6860 dan *dice* sebesar 0,7776, dengan *Loss* sebesar 0,1041. Namun, performa sedikit menurun pada *epoch* ke-100, yang ditunjukkan dengan *dice* turun ke 0,7597 dan *IoU* menjadi 0,6667. Hal ini memperkuat indikasi *overfitting* yang sudah diamati pada data validasi sebelumnya, di mana penambahan *epoch* justru menurunkan generalisasi model.

Sebaliknya, pada *learning rate*  $1e^{-4}$ , performa model menunjukkan peningkatan yang lebih stabil dan signifikan. Konfigurasi terbaik ditemukan pada *epoch* ke-100, di mana *Dice* mencapai nilai tertinggi sebesar 0,795, *IoU* sebesar 0,7077, dan *Loss* paling rendah yaitu 0,0952. Performa ini tidak hanya mengungguli semua konfigurasi pada *Learning rate*  $1e^{-4}$  sebelumnya, tetapi juga lebih baik dibandingkan semua konfigurasi dari *Learning rate*  $1e^{-3}$ .

Hal ini menunjukkan bahwa model dengan *Learning rate*  $1e^{-4}$  dan 100 *epoch* memiliki kemampuan generalisasi terbaik terhadap data uji. Nilai metrik yang tinggi dan stabil menunjukkan bahwa model tidak hanya belajar dengan baik pada data pelatihan, tetapi juga dapat diterapkan secara efektif pada data baru, yang sangat penting dalam konteks aplikasi medis nyata.

Selain ditinjau melalui metrik kuantitatif, performa model juga dievaluasi secara kualitatif melalui visualisasi hasil pada data uji. Visualisasi ini dilakukan dengan membandingkan antara citra asli, *ground truth mask*, dan hasil prediksi model. Model yang digunakan dalam visualisasi merupakan model dengan konfigurasi terbaik, yaitu pada *epoch* ke-100 dengan *learning rate*  $1e^{-4}$ , yang sebelumnya telah terbukti memberikan performa tertinggi secara metrik evaluasi. Hasil *output* model ditunjukkan pada gambar 10 dibawah ini.



GAMBAR 10  
VISUALISASI *OUTPUT* MODEL DENGAN MEMBANDINGKAN *GROUND TRUTH MASK* DAN *PREDICTED MASK*.

Visualisasi segmentasi pada gambar 10, menampilkan hasil segmentasi tumor otak menggunakan model terbaik, yaitu U-Net dengan konfigurasi 100 *epoch* dan *Learning rate*  $1e^{-4}$ . Setiap kolom pada gambar menampilkan satu sampel citra uji yang terdiri dari gambar asli, *ground truth mask*, hasil prediksi model, serta *overlay* prediksi yang menunjukkan area tumor yang terdeteksi.

Secara umum, hasil prediksi model menunjukkan kesesuaian bentuk dan posisi tumor yang sangat mendekati *ground truth*, baik pada citra *axial*, *coronal*, maupun *sagittal*. Area tumor yang berbentuk bulat, tegas, dan berukuran sedang hingga besar berhasil diprediksi dengan

sangat baik, terlihat dari *overlay* berwarna merah yang hampir menutupi seluruh area *ground truth*. Hal ini menunjukkan bahwa model mampu mengenali pola spasial tumor secara akurat.

Namun, pada beberapa kasus seperti tumor berukuran kecil (misalnya pada kolom ke-4 dan ke-6), terlihat adanya sedikit deviasi antara prediksi dan *ground truth*, terutama pada tepi objek. Hal ini kemungkinan disebabkan oleh minimnya fitur spasial yang dapat dipelajari pada area kecil, serta *noise* yang mungkin masih ada pada citra *input*. Meski demikian, bentuk umum dan lokasi prediksi tetap berada pada area yang benar, sehingga segmentasi tetap dinilai relevan dari sudut pandang medis.

*Overlay* prediksi memberikan gambaran visual yang kuat terhadap kualitas segmentasi, memperkuat hasil evaluasi metrik kuantitatif sebelumnya, dan menunjukkan bahwa model telah mampu mendeteksi objek target dengan presisi yang cukup tinggi bahkan pada variasi bentuk dan ukuran tumor yang kompleks.

Model U-Net dengan 100 *epoch* dan *learning rate*  $1e^{-4}$  menunjukkan performa terbaik. Model mencatatkan *Dice* 0,795 dan *IoU* 0,7077. Evaluasi kuantitatif dan kualitatif membuktikan kemampuan generalisasi yang baik.

## V. KESIMPULAN

Konfigurasi parameter pelatihan sangat berpengaruh terhadap performa segmentasi U-Net. *Epoch* optimal pada *learning rate*  $1e^{-3}$  adalah 60, sedangkan konfigurasi terbaik adalah *learning rate*  $1e^{-4}$  dengan 100 *epoch* karena menghasilkan performa stabil dan akurat.

Model U-Net dengan konfigurasi 100 *epoch* dan *learning rate*  $1e^{-4}$  menghasilkan *dice* 0,795 dan *IoU* 0,7077 pada data uji. Model efektif mengenali area tumor secara akurat dan berpotensi digunakan dalam sistem diagnosis medis berbasis citra.

## REFERENSI

- [1] I. B. L. M. Suta, M. Sudarma, and I. N. Satya Kumara, "Segmentasi Tumor Otak Berdasarkan Citra Magnetic Resonance Imaging Dengan Menggunakan Metode U-NET," *Maj. Ilm. Teknol. Elektro*, vol. 19, no. 2, p. 151, 2020, doi: 10.24843/mite.2020.v19i02.p05.
- [2] Kemenkes, "Panduan Penatalaksanaan Tumor Otak," *Natl. Cancer Combat Comm.*, pp. 1–96, 2017, [Online]. Available: <http://kanker.kemkes.go.id/guidelines.php?id=5>.
- [3] J. Ferlay et al., "Cancer statistics for the year 2022: An overview," *Int. J. Cancer*, vol. 149, no. 4, pp. 778–789, 2022, doi: 10.1002/ijc.33588.
- [4] N. S. Emril, D. R., Fajri, N., & Rahayu, "The New Concept of Cancer Pain Management: Should We Modify the WHO's Step Ladder? The Challenges Of Neurological Development In 4.0 Generation Of Industrial Revolutionary Era," vol. 3, no. 1, p. 296, 2020.
- [5] Mukhlis Akhadi, "Sinar-X Menjawab Masalah Kesehatan," Deepublish, 2020.
- [6] K. Munir, F. Frezza, and A. Rizzi, "Deep learning for brain tumor segmentation," *Stud. Comput. Intell.*, vol. 908, pp. 189–201, 2021, doi: 10.1007/978-981-15-6321-8\_11.
- [7] T. A. Soomro et al., "Deep Learning Models for Retinal Blood Vessels Segmentation: A Review," *IEEE Access*, vol. 7, pp. 71696–71717, 2019, doi: 10.1109/ACCESS.2019.2920616.
- [8] J. C. A. Vinay Kumar, Abul K. Abbas, *Robbins and Cotran's pathologic basis of disease*, 9th ed. Elsevier, 2020.
- [9] A. Delaidelli and A. Moiraghi, "Recent Advances in the Diagnosis and Treatment of Brain Tumors," *Brain Sci.*, vol. 14, no. 3, 2024, doi: 10.3390/brainsci14030224.
- [10] Brain Injury Law of Seattle, "Volumetric Analysis of the Brain," *Online*, 2024. <https://www.braininjurylawofseattle.com/what-is-a-volumetric-analysis-of-the-brain/> (accessed Dec. 19, 2024)
- [11] P. Prita, I. M. L. Prasetya, and R. Restiana, "Prosedur Pemeriksaan Magnetic Resonance Imaging (Mri) Pelvis Menggunakan Kontras Pada Kasus Fistula," *J. Ilmu Kedokt. dan Kesehat.*, vol. 10, no. 10, pp. 2955–2963, 2023, doi: 10.33024/jikk.v10i10.11798.
- [12] Y. Yu et al., "Techniques and Challenges of Image Segmentation: A Review," *Electron.*, vol. 12, no. 5, 2023, doi: 10.3390/electronics12051199.
- [13] M. A. I. Fahim and S. A. Tumpa, "Image Augmentation Techniques: Enhancing Deep Learning Performance," no. June, pp. 1–7, 2023, doi: 10.13140/RG.2.2.17295.97448.
- [14] G. Kaur, P. S. Rana, and V. Arora, *State-of-the-art techniques using pre-operative brain MRI scans for survival prediction of glioblastoma multiforme patients and future research directions*, vol. 10, no. 4. Springer International Publishing, 2022.
- [15] M. Karlık and B. Karlık, "Prediction of Student's Performance with Deep Neural Networks," *Int. J. Artif. Intell. Expert Syst.*, vol. 9, no. 2, pp. 39–47, 2020.
- [16] A. ANHAR and R. A. PUTRA, "Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN)," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 2, p. 466, 2023, doi: 10.26760/elkomika.v11i2.466.
- [17] N. Siddique, S. Paheding, C. P. Elkin, and V. Devabhaktuni, "U-Net and Its Variants for Medical Image Segmentation: A Review of Theory and Applications," *IEEE Access*, vol. 9, no. January 2021, pp. 82031–82057, 2021, doi: 10.1109/ACCESS.2021.3086020.
- [18] Y. Ding, F. Chen, Y. Zhao, Z. Wu, C. Zhang, and D. Wu, "A Stacked Multi-Connection Simple Reducing Net for Brain Tumor Segmentation," *IEEE Access*, vol. 7, pp. 104011–104024, 2019, doi: 10.1109/ACCESS.2019.2926448.
- [19] J. Jordan, "Evaluating image segmentation models.," *Jeremy Jordan Data Science*, 2018. <https://www.jeremyjordan.me/evaluating-image-segmentation-models/> (accessed Dec. 19, 2024).
- [20] R. Padilla, S. L. Netto, and E. A. B. Silva, "Proceedings of the 2020 International Conference on

Systems, Signals and Image Processing, IWSSIP 2020,” *Int. Conf. Syst. Signals, Image Process.*, vol. 2020-July, pp. 237–242, 2020.

- [21] C. H. Sudre, W. Li, T. Vercauteren, S. Ourselin, and M. Jorge Cardoso, “Generalised *Dice* overlap as a deep learning *Loss* function for highly unbalanced segmentations,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 10553 LNCS, pp. 240–248, 2017, doi: 10.1007/978-3-319-67558-9\_28.
- [22] H. Rezatofghi, N. Tsoi, J. Gwak, A. Sadeghian, I. Reid, and S. Savarese, “Generalized intersection over union: A metric and a *Loss* for bounding box regression,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2019-June, pp. 658–666, 2019, doi: 10.1109/CVPR.2019.00075.
- [23] D. W. Ayu and G. A. Pradipta, “Analisis Performansi Parameter pada Arsitektur U-Net untuk Segmentasi Nukleus pada Citra Kanker Serviks,” *J. Sist. dan Inform.*, vol. 18, no. 2, pp. 131–138, 2024, doi: 10.30864/jsi.v18i2.607.
- [24] S. Jadon, “A survey of *Loss* functions for semantic segmentation,” *2020 IEEE Conf. Comput. Intell. Bioinforma. Comput. Biol. CIBCB 2020*, 2020, doi: 10.1109/CIBCB48159.2020.9277638.