

Analisis Performa Segmentasi Citra MRI Tumor Otak dengan Arsitektur U-Net dan Res-UNet

Alim Misbullah^{a*}, Waliam Mursyida^b, Laina Farsiah^c, Nazaruddin^d, Kikye Martiwi Sukiakhy^e, Husaini^f, Basrul^g

^{a,b,c,d,e,f}Departemen Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Syiah Kuala
e-mail: ^amisbullah@cs.usk.ac.id, ^bwali@mhs.usk.ac.id, ^clainafarsiah@usk.ac.id, ^danzaro@usk.ac.id,
^ekikye.martiwi.sukiakhy@usk.ac.id, ^fhusaini.muhammad@usk.ac.id, ^gbasrul.a.majid@iainlhokseumawe.ac.id

Abstract. Brain tumor diagnosis via MRI faces challenges due to limitations in visualizing morphology, location, and boundaries. MRI's typical two-dimensional format requires manual interpretation by radiologists, introducing risks of human error. To improve segmentation accuracy in MRI, deep learning approaches like Convolutional Neural Networks (CNNs) have been applied to highlight critical regions. This study compares two CNN architectures, U-Net and Res-UNet, for brain tumor segmentation using the Brain Tumor Segmentation Challenge (BraTS) 2020 dataset. Both models were trained under similar settings and evaluated on their ability to identify key areas, including the tumor core, edema, and enhancing tumor regions. The models used the Adam optimizer and categorical cross-entropy loss, and evaluation metrics included accuracy. Results showed U-Net achieving optimal performance at 35 epochs with a batch size of 64 and a 0.001 learning rate, producing the lowest loss (0.0140) and highest accuracy (99.5%). Although Res-UNet also reached high accuracy (99.3%), its higher loss indicated it was less effective than U-Net.

Keywords: MRI Image Segmentation, Brain Tumor, U-Net, Res-UNet, Deep Learning

Abstrak. Diagnosis tumor otak melalui MRI menghadapi tantangan akibat keterbatasan dalam visualisasi morfologi, lokasi, dan batas-batas tumor. Format MRI yang biasanya dua dimensi memerlukan interpretasi manual oleh radiolog, yang meningkatkan risiko kesalahan manusia. Untuk meningkatkan akurasi segmentasi MRI, pendekatan pembelajaran mendalam seperti Convolutional Neural Networks (CNN) telah diterapkan untuk menyoroti area-area penting. Studi ini membandingkan dua arsitektur CNN, U-Net dan Res-UNet, untuk segmentasi tumor otak menggunakan dataset Brain Tumor Segmentation Challenge (BraTS) 2020. Kedua model dilatih dengan pengaturan yang serupa dan dievaluasi berdasarkan kemampuannya mengidentifikasi area kunci, termasuk inti tumor, edema, dan area tumor yang mengalami peningkatan. Model ini menggunakan optimizer Adam dan fungsi loss categorical crossentropy, dengan metrik evaluasi termasuk akurasi. Hasil menunjukkan bahwa U-Net mencapai performa optimal pada 35 epoch dengan ukuran batch 64 dan learning rate 0,001, menghasilkan nilai loss terendah (0,0140) dan akurasi tertinggi (99,5%). Meskipun Res-UNet juga mencapai akurasi tinggi (99,3%), nilai loss yang lebih tinggi menunjukkan bahwa model ini kurang efektif dibandingkan U-Net.

Kata Kunci: Segmentasi Citra MRI, Tumor Otak, U-Net, Res-UNet, Deep Learning

* Corresponding author. E-mail: misbullah@cs.usk.ac.id

Diterima 20 September 2024, Disetujui November 2024, Diterbitkan online November 2024

Sitasi IEEE: A. Misbullah, W. Mursyida, L. Farsiah, Nazaruddin, K. M. Sukiakhy, Husaini, Basrul, "Analisis Performa Segmentasi Citra MRI Tumor Otak dengan Arsitektur U-Net dan Res-UNet," J-SIGN, vol. 2, no. 2, pp. 83–95, 2024

1. Pendahuluan

Otak adalah organ vital yang berfungsi sebagai pusat pengendalian berbagai aktivitas tubuh manusia, termasuk pergerakan, fungsi sensorik, pemikiran, dan emosi. Secara anatomi, otak manusia terbagi menjadi tiga bagian utama: otak besar (*cerebrum*), otak kecil (*cerebellum*), dan batang otak (*brain stem*), di mana masing-masing bagian memiliki peran spesifik dalam menjaga keseimbangan dan fungsi tubuh. Salah satu gangguan serius yang dapat mengancam fungsi otak adalah tumor otak, yang muncul akibat pertumbuhan abnormal sel-sel di dalam atau sekitar otak, mengganggu fungsi normal otak dan meningkatkan tekanan intrakranial. Kondisi ini dapat menyebabkan kerusakan pada jaringan otak dan jaringan saraf di sekitarnya, memicu berbagai gejala klinis, mulai dari gangguan neurologis hingga risiko kematian [1].

Menurut data dari cancer.net, pada tahun 2023 diperkirakan sekitar 24.810 orang dewasa dan 5.230 anak-anak di bawah usia 20 tahun di Amerika Serikat didiagnosis dengan tumor otak primer. Angka kematian akibat kanker otak, baik primer maupun sekunder, juga tinggi, dengan sekitar 18.990 kematian per tahun. Tumor otak menyumbang sekitar 85%-90% dari seluruh kasus tumor primer pada sistem saraf pusat, menunjukkan bahwa kondisi ini adalah ancaman serius terhadap kesehatan global. Secara global, pada tahun 2020, lebih dari 300.000 orang diperkirakan didiagnosis dengan tumor otak primer. Data ini menegaskan kebutuhan akan upaya yang lebih efektif dalam diagnosis dan penanganan tumor otak, termasuk melalui teknologi pencitraan yang lebih canggih seperti MRI.

Teknologi informasi memainkan peran penting dalam kemajuan medis, khususnya dalam deteksi dini dan diagnosis penyakit. Salah satu teknologi pencitraan yang paling umum digunakan untuk deteksi tumor otak adalah Magnetic Resonance Imaging (MRI), sebuah teknologi yang memanfaatkan medan magnet dan gelombang radio untuk menghasilkan gambar detail dari struktur otak. MRI digunakan secara luas dalam diagnosis tumor otak karena kemampuannya dalam memberikan citra jaringan lunak yang jelas tanpa paparan radiasi [2]. Namun, meskipun bermanfaat, MRI memiliki keterbatasan, terutama dalam menyediakan citra yang akurat mengenai bentuk, lokasi, dan batas tumor. Selain itu, citra MRI biasanya berbentuk 2D, yang memerlukan interpretasi manual oleh radiolog, meningkatkan risiko kesalahan manusia.

Proses diagnosis tumor otak dengan MRI sering kali menemui tantangan dalam identifikasi batas tumor yang akurat. Ketidakmampuan MRI untuk menghasilkan citra 3D yang detail membuat pemisahan jaringan tumor dari jaringan sehat di sekitar otak menjadi sulit [3]. Untuk mengatasi tantangan ini, teknologi segmentasi citra berbasis Deep Learning telah diperkenalkan. Deep Learning, sebagai cabang dari machine learning, memiliki kemampuan untuk memproses citra medis dengan akurasi tinggi menggunakan algoritma yang meniru fungsi jaringan saraf manusia [4]. Dengan pendekatan ini, segmentasi otomatis atau semi-otomatis dapat memisahkan area penting secara medis dari bagian yang kurang relevan pada citra MRI, sehingga dapat mengurangi ketergantungan pada interpretasi manual dan menurunkan risiko kesalahan diagnosis [5].

Dalam segmentasi citra MRI untuk tumor otak, dua arsitektur Convolutional Neural Network (CNN), yaitu U-Net dan Res-UNet, sering digunakan untuk memisahkan area signifikan seperti inti tumor, edema, dan area yang mengalami peningkatan. U-Net dikenal efektif dalam segmentasi citra medis dengan ketelitian tingkat piksel yang menghasilkan akurasi tinggi [6]. Res-UNet, sebagai pengembangan dari U-Net, mengintegrasikan Residual Learning untuk meningkatkan kinerja model dalam segmentasi citra medis [7]. Penelitian ini bertujuan untuk menganalisis performa kedua arsitektur dalam segmentasi citra MRI tumor otak, dengan harapan dapat menemukan metode yang paling efektif untuk memisahkan area penting pada citra MRI, sehingga meningkatkan akurasi dan efisiensi dalam diagnosis tumor otak.

2. Penelitian Terkait

Berbagai penelitian sebelumnya telah menunjukkan bahwa metode deep learning, khususnya *Convolutional Neural Networks* (CNN) dan arsitektur U-Net, memiliki performa yang sangat baik dalam tugas segmentasi dan klasifikasi citra medis serta non-medis. *U-Net* dan variasinya secara luas digunakan dalam segmentasi citra untuk mendeteksi objek seperti tumor otak, organ dalam, dan objek lainnya, sementara CNN unggul dalam klasifikasi citra berbasis fitur. Studi-studi ini tidak hanya mengaplikasikan teknologi tersebut pada citra medis, tetapi juga pada citra lain seperti tumbuhan dan hewan, dengan berbagai adaptasi yang menekankan fleksibilitas dan keunggulan metode deep learning. Melalui berbagai pendekatan inovatif, seperti hybrid CNN dan Res-UNet, performa dalam hal akurasi, presisi segmentasi, dan kecepatan komputasi semakin ditingkatkan, menunjukkan potensi besar metode ini dalam berbagai aplikasi di bidang sains dan teknologi.

Aboelenein et al. [8] memperkenalkan model *HTTU-Net*, sebuah inovasi dari arsitektur *U-Net* yang dirancang untuk segmentasi tumor otak dari citra MRI. *HTTU-Net* terdiri dari dua jalur hibrida yang dirancang untuk menangkap informasi spasial dan kontekstual secara lebih efektif. Jalur pertama berfungsi memproses fitur spasial yang lebih halus, sementara jalur kedua menangani fitur yang lebih kasar untuk memberikan pemahaman mendalam tentang struktur tumor. Kombinasi kedua jalur ini memungkinkan model untuk mengidentifikasi bagian tumor dengan akurasi yang lebih tinggi dibandingkan metode konvensional, terutama dalam menangani variasi bentuk dan ukuran tumor.

Dalam evaluasinya, *HTTU-Net* diuji menggunakan dataset BraTS 2018 dan memberikan performa yang sangat baik dengan *Dice Similarity Coefficient* (DSC) sebesar 93%. Hal ini menunjukkan keunggulan model dalam memisahkan batas-batas tumor secara akurat, meskipun citra MRI memiliki variabilitas yang tinggi. Kelebihan lain dari model ini adalah kemampuannya untuk diadaptasi pada berbagai dataset dengan minimal pelatihan ulang, menjadikannya solusi yang fleksibel untuk berbagai aplikasi segmentasi medis. Penelitian ini menyoroti potensi besar *U-Net hybrid* dalam meningkatkan hasil diagnosis tumor otak [8].

Bagus et al. [9] mengadopsi arsitektur *U-Net* untuk melakukan segmentasi citra resonansi magnetik (MRI) otak. Penelitian ini bertujuan untuk meningkatkan akurasi deteksi bagian-bagian penting dari otak yang terkait dengan diagnosis medis. *U-Net* dipilih karena kemampuannya dalam melakukan segmentasi dengan presisi tinggi meskipun menggunakan data yang terbatas. Penelitian ini juga menyoroti keuntungan arsitektur U-Net dalam menjaga detail spasial dari citra medis yang sering kali memiliki kompleksitas struktur yang tinggi. Hasil dari penelitian menunjukkan bahwa model *U-Net* dapat melakukan segmentasi dengan akurasi yang memuaskan pada dataset lokal. Meski tidak memberikan nilai metrik kinerja spesifik, penelitian ini menunjukkan bahwa U-Net dapat diimplementasikan pada citra MRI dengan hasil yang relevan untuk membantu diagnosis klinis. Penggunaan U-Net dalam bidang ini juga mendemonstrasikan fleksibilitas dan keandalannya dalam segmentasi citra medis secara otomatis [9].

Penelitian yang dilakukan oleh Naraloka et al. [6] berfokus pada penerapan arsitektur U-Net untuk segmentasi citra hati dengan tujuan mendeteksi kanker liver secara dini. Segmentasi organ dalam, khususnya hati, adalah tugas yang kompleks mengingat struktur hati yang beragam antar individu. U-Net dalam penelitian ini digunakan untuk memisahkan batas-batas organ hati dari citra medis, dengan harapan bisa mendeteksi perubahan struktural yang terkait dengan perkembangan kanker liver pada tahap awal. Meskipun tidak disebutkan secara rinci metrik kinerja seperti akurasi atau nilai DSC, hasil penelitian menunjukkan bahwa U-Net dapat melakukan segmentasi yang baik dan memadai untuk tujuan diagnosis. Keberhasilan segmentasi hati menggunakan U-Net ini membuka jalan bagi penerapan

lebih lanjut dalam analisis citra medis yang terkait dengan penyakit organ dalam lainnya. Penelitian ini berperan penting dalam mengembangkan metode deteksi dini kanker melalui analisis citra digital [6].

Daimary et al. [5] mengembangkan pendekatan Hybrid Convolutional Neural Networks (CNN) yang menggabungkan metode tradisional CNN dengan arsitektur U-Net untuk segmentasi tumor otak dari citra MRI. Pendekatan ini didasarkan pada kekuatan U-Net dalam segmentasi spasial dan kekuatan CNN dalam pengenalan pola, sehingga menghasilkan model yang lebih unggul untuk tugas segmentasi yang kompleks. Penelitian ini bertujuan untuk meningkatkan akurasi segmentasi tumor yang sering kali memiliki variasi besar dalam hal ukuran, bentuk, dan tekstur. Pengujian pada dataset MICCAI menunjukkan bahwa metode ini mencapai 91% Dice Similarity Coefficient (DSC), sebuah indikator yang mengukur tingkat kemiripan antara hasil segmentasi otomatis dengan segmentasi manual. Hal ini menunjukkan bahwa Hybrid CNN memiliki potensi yang besar untuk aplikasi klinis. Pendekatan ini juga memberikan manfaat dalam hal generalisasi, di mana model mampu menangani berbagai jenis citra MRI dengan kinerja yang stabil [5].

Pada penelitian yang dilakukan oleh Feng et al. [10], mereka mengusulkan algoritma rekonstruksi berbasis Res-UNet untuk meningkatkan kualitas citra akustik foto (photoacoustic imaging). Photoacoustic imaging adalah teknik pencitraan medis yang memanfaatkan sinyal suara dan optik untuk merekonstruksi citra jaringan dalam tubuh. Algoritma ini mengintegrasikan arsitektur residual U-Net (Res-UNet) yang dapat menangani masalah vanishing gradient dan menghasilkan citra dengan detail yang lebih baik dibandingkan dengan metode rekonstruksi tradisional. Hasil pengujian pada data simulasi dan eksperimental menunjukkan bahwa algoritma ini secara signifikan meningkatkan peak signal-to-noise ratio (PSNR), yang merupakan indikator utama kualitas citra. Pendekatan ini menawarkan perbaikan substansial dalam hal akurasi dan kualitas visual citra, memberikan aplikasi yang penting untuk deteksi penyakit dan diagnosis yang lebih akurat. Model ini membuktikan bahwa Res-UNet bisa menjadi solusi efektif untuk berbagai tantangan rekonstruksi citra medis [10].

Penelitian yang dilakukan oleh Ilahiyah dan Nilogiri [11] menerapkan Convolutional Neural Networks (CNN) untuk mengklasifikasikan jenis tumbuhan berdasarkan citra daun. Studi ini memperlihatkan bahwa metode deep learning dapat dimanfaatkan dalam analisis citra di luar konteks medis, khususnya dalam klasifikasi tanaman. CNN dipilih karena kemampuannya dalam mengenali pola dari citra secara otomatis tanpa membutuhkan proses ekstraksi fitur manual yang kompleks. Model ini diuji pada dataset lokal yang terdiri dari berbagai variasi daun. Hasil penelitian menunjukkan bahwa CNN berhasil mengklasifikasikan jenis tumbuhan dengan tingkat akurasi mencapai 95%, membuktikan bahwa metode ini andal untuk aplikasi botani. Penggunaan CNN mempercepat dan meningkatkan akurasi proses identifikasi tanaman, memberikan dampak signifikan pada penelitian di sektor pertanian dan lingkungan [11].

Kusuma dan Ellyana [12] mengeksplorasi penggunaan algoritma K-Means untuk segmentasi citra yang telah terkompresi. Algoritma ini, meskipun lebih sederhana dibandingkan metode deep learning seperti U-Net, menawarkan kecepatan dalam melakukan segmentasi pada dataset berukuran kecil atau citra terkompresi. Tujuan utama dari penelitian ini adalah untuk mengevaluasi seberapa efektif K-Means dalam menghasilkan segmentasi yang cukup memadai untuk aplikasi yang tidak memerlukan tingkat presisi yang sangat tinggi. Hasil penelitian mengungkapkan bahwa meskipun K-Means tidak seakurat metode deep learning, algoritma ini dapat diterapkan secara efisien pada kondisi tertentu, seperti ketika citra telah dikompresi atau ketika waktu pemrosesan menjadi prioritas. Hal ini menunjukkan bahwa K-Means tetap relevan untuk tugas segmentasi yang lebih sederhana dan cepat [12].


Penggunaan arsitektur U-Net untuk segmentasi citra hewan telah dieksplorasi dalam penelitian oleh Lui et al. [13]. Sementara banyak studi sebelumnya fokus pada segmentasi organ manusia,

penelitian ini memperluas aplikasi U-Net ke citra hewan. Dengan menggunakan dataset citra hewan, penelitian ini menunjukkan bahwa U-Net dapat diadaptasi dengan baik untuk berbagai konteks, termasuk dalam bidang biologi dan lingkungan. Hasil penelitian menunjukkan bahwa U-Net mampu melakukan segmentasi citra hewan dengan hasil yang memuaskan, meskipun terdapat perbedaan dalam struktur dan tekstur hewan. Temuan ini menegaskan fleksibilitas U-Net, yang tidak hanya terbatas pada aplikasi medis tetapi juga dapat diterapkan dalam berbagai domain lainnya [13].

Convolutional Neural Networks (CNN) telah diterapkan untuk klasifikasi citra MRI tumor otak dalam studi oleh Luqyana et al. [14]. Tujuan utama dari penelitian ini adalah untuk memanfaatkan teknologi deep learning guna meningkatkan akurasi dalam diagnosis tumor otak. CNN dipilih karena kemampuannya untuk mempelajari fitur langsung dari citra MRI tanpa memerlukan proses ekstraksi fitur manual. Dengan menggunakan dataset MRI lokal, penelitian ini berhasil menunjukkan bahwa CNN dapat memprediksi jenis tumor dengan tingkat akurasi yang tinggi. Penelitian ini mencapai hasil yang sangat memuaskan, dengan akurasi klasifikasi sebesar 98%, berkat implementasi CNN dan teknik augmentasi data. Temuan ini menggarisbawahi potensi besar CNN dalam aplikasi klinis dan diagnosis berbasis citra, menekankan efisiensi dan akurasi dalam prediksi yang dihasilkan [14].

3. Metode Penelitian

Segmentasi citra Magnetic Resonance Imaging (MRI) tumor otak dengan menggunakan teknologi *deep learning* dilakukan melalui serangkaian tahapan yang terstruktur seperti yang ditunjukkan pada Gambar 1. Penelitian ini bertujuan untuk mengevaluasi performa model segmentasi dengan arsitektur U-Net dan Res-UNet pada dataset MRI, dan proses penelitian terdiri dari beberapa langkah penting.



Gambar 1. Tahapan Penelitian Analisis Performa Segmentasi Citra MRI

3.1. Studi Literatur

Langkah awal dalam penelitian ini melibatkan kajian literatur yang berfokus pada pengumpulan dan analisis referensi penelitian yang relevan. Kegiatan ini mencakup pemahaman dan pencatatan metode segmentasi yang telah diterapkan dalam konteks serupa, sehingga peneliti dapat memahami pendekatan-pendekatan yang sudah ada dan evaluasi yang telah dilakukan. Kajian literatur ini memberikan wawasan mendalam mengenai tantangan yang dihadapi dalam segmentasi tumor otak

menggunakan MRI, membantu dalam pemilihan metode yang sesuai, serta menyediakan landasan teoritis bagi pendekatan deep learning yang akan digunakan dalam penelitian ini.

3.2. Pengumpulan dan Pemrosesan Data

Data yang digunakan dalam penelitian ini berasal dari dataset *Brain Tumor Segmentation Challenge (BraTS) 2020*, yang disediakan oleh Medical Image Computing and Computer Assisted Intervention (MICCAI). Dataset ini tersedia dalam format file (.nii.gz) dan mencakup empat jenis pemindaian MRI: T1, T1ce, T2, dan Flair. Setiap jenis pemindaian memberikan informasi berbeda mengenai jaringan otak dan lesi, yang berguna untuk segmentasi yang akurat. Dataset ini juga mencakup segmentasi manual yang melibatkan empat segmen area: Not Tumor, necrotic and *non-enhancing* tumor core (NCR/NET), Peritumoral edema (ED), dan GD-enhancing tumor (ET). Segmentasi manual ini berfungsi sebagai ground truth untuk evaluasi kinerja model.

Proses pemrosesan data dimulai dengan menentukan jumlah dan kisaran lapisan (*slices*) yang akan digunakan dalam analisis. Data kemudian dibagi menjadi tiga subset: data pelatihan, validasi, dan pengujian. Pembagian data ini bertujuan untuk memastikan model dapat dilatih, divalidasi, dan diuji secara efektif. Selanjutnya, DataGenerator dibuat untuk menghasilkan data secara dinamis selama pelatihan model, yang meningkatkan efisiensi proses pelatihan dengan memuat data bertahap ke dalam memori, alih-alih memuat seluruh data sekaligus.

3.3. Membangun dan Melatih Model

Tahap pelatihan melibatkan penggunaan dua arsitektur model yang berbeda, yaitu U-Net dan Res-UNet. Kedua model ini dilatih menggunakan dataset yang sama untuk memastikan perbandingan yang adil. Pada tahap awal, parameter arsitektur model dikonfigurasi dan kedua model dikompilasi menggunakan fungsi loss 'categorical cross entropy' dan optimasi dengan algoritma Adam. Metrik evaluasi yang digunakan meliputi akurasi, Mean Intersection over Union (IoU), dice coefficient, precision, sensitivity, specificity, serta dice coefficient untuk necrotic, edema, dan enhancing tumor. Setelah konfigurasi awal, tahap berikutnya adalah pengaturan hyperparameter. Kedua arsitektur model, U-Net dan Res-UNet, di-tuning dengan pengaturan hyperparameter yang sama, termasuk epoch, learning rate, dan batch size. Pengaturan ini dilakukan untuk menemukan konfigurasi optimal yang memberikan kinerja terbaik pada model. Proses tuning ini penting untuk memastikan bahwa model tidak hanya belajar dengan baik tetapi juga dapat menggeneralisasi hasil dengan efektif pada data baru.

Selama pelatihan, objek *callbacks* digunakan untuk memantau dan mengelola proses pelatihan model. Terdapat objek CSVLogger yang menyimpan log pelatihan dalam format (.log), serta objek EarlyStopping dan ReduceLROnPlateau. EarlyStopping menghentikan pelatihan jika tidak ada perbaikan signifikan pada nilai loss, sementara ReduceLROnPlateau mengurangi learning rate jika tidak ada peningkatan pada validasi loss setelah beberapa epoch. Setelah pelatihan selesai, model yang telah dilatih disimpan untuk pengujian lebih lanjut.

3.4. Menguji dan Mengevaluasi Model

Pengujian model dilakukan dengan memuat model yang telah dilatih dan tervalidasi, kemudian menerapkan model tersebut pada data uji yang telah disiapkan. Proses ini melibatkan prediksi segmentasi pada dataset testing untuk menilai kinerja model dalam konteks data yang belum pernah dilihat

sebelumnya. Evaluasi ini penting untuk memastikan bahwa model dapat memberikan hasil yang konsisten dan akurat pada data yang tidak termasuk dalam dataset pelatihan atau validasi.

Evaluasi model dilakukan untuk menilai kinerja dari model yang telah dilatih dan diuji. Proses evaluasi melibatkan perhitungan metrik seperti akurasi, Mean IoU, dice coefficient, precision, sensitivity, specificity, serta dice coefficient untuk setiap jenis tumor (necrotic, edema, enhancing). Metrik ini digunakan untuk mengukur sejauh mana hasil segmentasi model sesuai dengan ground truth, serta untuk membandingkan kinerja antara model U-Net dan Res-UNet.

3.5. Menganalisis Hasil

Setelah evaluasi, analisis hasil dilakukan untuk menginterpretasikan performa model. Perbandingan hasil segmentasi dari kedua model, U-Net dan Res-UNet, dilakukan untuk menentukan model mana yang memberikan hasil segmentasi yang lebih baik. Analisis ini mencakup perbandingan metrik evaluasi dan diskusi tentang kekuatan dan kelemahan masing-masing model berdasarkan hasil pengujian.

4. Hasil dan Pembahasan

4.1. Pengumpulan Dataset


Penelitian ini menggunakan dataset dari Brain Tumor Segmentation Challenge (BraTS) 2020, yang berisi data MRI dari 369 pasien dengan format file NIfTI (.nii). Setiap pasien dalam dataset ini memiliki empat jenis citra pemindaian MRI, yaitu T1-Weighted, T2-Weighted, T1 dengan kontras (T1ce), dan Fluid-Attenuated Inversion Recovery (FLAIR). Citra-citra ini memberikan informasi penting untuk analisis tumor otak, seperti struktur anatomi, distribusi cairan, serta perbedaan antara jaringan tumor dan jaringan otak normal. Setiap metode pemindaian membantu memberikan visualisasi yang berbeda dalam mendeteksi tumor otak, sehingga meningkatkan akurasi diagnosis dan perencanaan pengobatan.

Selain itu, dataset BraTS 2020 juga mencakup anotasi manual yang membagi tumor otak ke dalam empat segmen area, yaitu Not Tumor (label 0), necrotic and non-enhancing tumor core (NCR/NET - label 1), peritumoral edema (ED - label 2), dan GD-enhancing tumor (ET - label 4). Label-label ini memudahkan dalam segmentasi tumor otak untuk tujuan analisis klinis, dengan fokus pada area-area yang menunjukkan aktivitas tumor atau perubahan struktural. Anotasi ini berfungsi sebagai acuan untuk pengujian dan pelatihan model deep learning yang digunakan dalam segmentasi otomatis tumor otak pada penelitian ini.

4.2. Pemrosesan Dataset

Pemrosesan data dimulai dengan konfigurasi volume slices pada citra MRI tumor otak. Setiap gambar terdiri dari dimensi 240 x 240 piksel dengan total 155 lapisan (slices), dan penelitian ini menggunakan 100 lapisan, dimulai dari lapisan ke-22. Setiap lapisan mewakili gambar 2D yang diambil dari posisi tertentu dalam volume 3D. Langkah ini penting untuk memastikan bahwa data yang diproses memiliki rentang lapisan yang relevan dan dapat menghasilkan segmentasi yang akurat. Konfigurasi ini juga membantu mengurangi noise dan meningkatkan efisiensi komputasi selama proses segmentasi. Gambar

2 memperlihatkan contoh tampilan citra FLAIR pada lapisan yang berbeda berdasarkan lapisan yang dipilih.



Gambar 2. Contoh Lapisan Citra Flair

Setelah konfigurasi volume, langkah selanjutnya adalah pemisahan data. Data dipecah menjadi tiga bagian, yaitu data pelatihan, validasi, dan pengujian. Pemisahan ini dilakukan dalam dua tahapan: pertama, data dibagi menjadi 80% untuk pelatihan dan 20% untuk validasi. Tahap kedua melibatkan pemisahan ulang data pelatihan menjadi 65% data pelatihan dan 15% data pengujian. Proses ini penting untuk memastikan bahwa model dilatih dan divalidasi dengan data yang konsisten dan relevan, sambil menyediakan data pengujian untuk evaluasi akhir. Sebelum pemisahan, file yang tidak sesuai format seperti "BraTS20_Training_355" dihapus untuk memastikan kualitas data.

Langkah berikutnya adalah pembuatan DataGenerator, yang digunakan untuk menghasilkan batch data selama pelatihan model. DataGenerator memuat dataset yang terdiri dari citra FLAIR dan T1ce, yang merupakan input utama dalam pelatihan model segmentasi. Citra-citra ini kemudian diubah ukurannya menjadi 128×128 piksel untuk menjaga konsistensi ukuran gambar. Dengan pembagian data ke dalam batch kecil, model dapat memproses data secara bertahap, yang mengurangi beban memori dan mempercepat proses pelatihan.

Selain itu, DataGenerator juga memproses data segmentasi dari file 'seg.nii', yang berfungsi sebagai ground truth untuk memvalidasi hasil segmentasi. Data segmentasi tumor yang awalnya memiliki empat kelas diubah menjadi tiga kelas dengan mengganti nilai kelas 4 (enhancing) menjadi kelas 3, untuk memudahkan interpretasi dan klasifikasi hasil segmentasi. Data kemudian diubah menjadi bentuk one-hot encoding dan diresize untuk digunakan dalam pelatihan model. Dengan adanya DataGenerator, proses pelatihan, validasi, dan pengujian menjadi lebih efisien dan memungkinkan model segmentasi citra tumor otak memanfaatkan seluruh dataset dengan lebih optimal.

4.3. Membangun dan Melatih Model

Penelitian ini melibatkan pembangunan dua arsitektur model utama, yaitu U-Net dan Res-UNet, yang keduanya dikenal efektif untuk segmentasi citra. Arsitektur U-Net memiliki dua jalur utama, encoding dan decoding. Jalur encoding bertugas mengekstraksi fitur dari citra input melalui operasi konvolusi dan maxpooling. Setelah itu, pada jalur decoding, dilakukan proses up-sampling untuk meningkatkan dimensi citra sambil mempertahankan informasi penting dari hasil encoding. Proses ini membantu menghasilkan segmentasi citra yang lebih akurat. Pada arsitektur U-Net, proses encoding dilakukan melalui beberapa lapisan konvolusi dengan peningkatan jumlah filter pada setiap lapisan. Setiap lapisan diikuti dengan fungsi aktivasi ReLU dan operasi maxpooling untuk mengurangi resolusi citra. Model ini juga menggunakan teknik dropout sebesar 20% untuk mencegah overfitting. Sementara itu,

arsitektur Res-UNet adalah pengembangan dari U-Net yang menggabungkan block residual untuk mempertahankan informasi selama proses konvolusi. Res-UNet menggunakan block residual untuk menjaga dimensi input yang sama melalui shortcut path.

Kedua model ini dikompilasi menggunakan loss function categorical crossentropy untuk mengukur perbedaan antara prediksi model dan label yang sebenarnya. Optimizer Adam dengan pengaturan learning rate antara 0,001 dan 0,0001 digunakan untuk memperbarui bobot model. Beberapa percobaan dilakukan dengan konfigurasi hyperparameter yang berbeda, termasuk pengaturan epoch, batch size, dan learning rate, untuk mendapatkan hasil terbaik. Proses early stopping digunakan untuk menghentikan pelatihan model jika tidak ada peningkatan pada validasi loss. Untuk mengevaluasi performa model, beberapa metrik digunakan, termasuk accuracy, dice coefficient, precision, sensitivity, dan specificity. Metrik accuracy mengukur seberapa akurat prediksi model dalam segmentasi, sementara dice coefficient mengevaluasi seberapa besar kesamaan antara prediksi dan label sebenarnya. Precision dan sensitivity digunakan untuk mengukur seberapa baik model dalam mengidentifikasi tumor dan menghindari kesalahan prediksi. Specificity mengukur kemampuan model dalam membedakan antara tumor dan non-tumor.

Selain metrik umum, beberapa metrik khusus seperti mean IoU (Intersection over Union) dan dice coefficient necrotic, edema, dan enhancing digunakan untuk mengevaluasi kemampuan model dalam mengidentifikasi bagian spesifik dari tumor. Mean IoU menghitung sejauh mana prediksi model sesuai dengan ground truth, sementara dice coefficient khusus digunakan untuk mengevaluasi performa segmentasi pada kelas tumor tertentu. Model ini menggunakan callbacks seperti EarlyStopping dan ReduceLROnPlateau untuk mengatur proses pelatihan secara otomatis. EarlyStopping menghentikan pelatihan saat nilai loss tidak mengalami perubahan signifikan, sedangkan ReduceLROnPlateau mengurangi learning rate saat tidak ada peningkatan performa.

Tabel 1. Konfigurasi Hyperparameter

No	Model	Konfigurasi Hyperparameter		
		Epoch	Learning Rate	Batch Size
1	U-Net	30	0,001	32
				64
			0,0001	32
				64
		35	0,001	32
				64
			0,0001	32
				64
		40	0,001	32
				64
			0,0001	32
				64
2	Res-UNet	30	0,001	32
				64
			0,0001	32
				64
		35	0,001	32
				64
			0,0001	32
				64
		40	0,001	32
				64
			0,0001	32
				64

				64
			0,0001	32
				64

4.4. Evaluasi Hasil

Tahapan ini melibatkan penggunaan dua model arsitektur, U-Net dan Res-UNet, yang telah dilatih berdasarkan konfigurasi *hyperparameter* pada Tabel 1, untuk pengujian data uji. Setelah memuat dan memproses data, model digunakan untuk memprediksi segmentasi piksel citra menjadi tiga kelas utama: *neocrotic/core* (inti tumor), *edema* (edema sekitar tumor), dan *enhancing* (peningkatan intensitas yang menyoroti tumor). Hasil prediksi ini bertujuan untuk memetakan tumor otak dan memberikan informasi penting untuk diagnosis dan perawatan pasien di masa depan.


Pada Tabel 2 memperlihatkan hasil evaluasi prediksi menggunakan arsitektur U-Net yang menunjukkan kinerja sangat tinggi. Model ini berhasil mencapai tingkat akurasi yang mendekati 99%, dengan nilai loss yang sangat rendah di setiap percobaan. Beragam metrik evaluasi seperti Mean IoU, Dice Coefficient, Precision, Sensitivity, dan Specificity memberikan gambaran yang lebih mendetail tentang performa model ini. Dari beberapa percobaan pelatihan yang dilakukan, model dengan konfigurasi epoch sebanyak 35, batch size sebesar 64, dan learning rate sebesar 0,001 menunjukkan performa terbaik. Pada percobaan tersebut, model mencapai nilai loss terendah yaitu 0,014 dan akurasi tertinggi sebesar 99.5%. Ini menunjukkan kemampuan model dalam mengklasifikasikan citra dengan sangat baik, terutama pada tugas segmentasi gambar medis.

Lebih jauh, performa metrik spesifik seperti Dice Coefficient untuk berbagai komponen jaringan otak seperti necrotic, edema, dan enhancing tumor menunjukkan hasil yang cukup baik, meskipun terdapat variasi antar percobaan. Sebagai contoh, model yang mencapai loss terendah memiliki Dice Coefficient yang relatif lebih tinggi untuk segmentasi necrotic (0,5757), edema (0,7187), dan enhancing tumor (0,6493). Nilai ini mengindikasikan kemampuan model dalam mendeteksi dan membedakan komponen-komponen tumor yang berbeda dalam gambar medis, meskipun terdapat tantangan dalam membedakan beberapa tipe jaringan yang lebih kompleks.

Tabel 2. Hasil Evaluasi Arsitektur U-Net

Loss	Akurasi	Mean IoU	Dice Coef	Precision	Sensitivity	Specificity	Dice Coef Necrotic	Dice Coef Edema	Dice Coef Enhancing
0,0206	0,9927	0,752	0,5931	0,9936	0,9909	0,9978	0,5891	0,6823	0,6428
0,0226	0,9925	0,7997	0,572	0,9933	0,9908	0,9977	0,4729	0,7166	0,5836
0,0195	0,9932	0,8158	0,5844	0,9941	0,9914	0,998	0,4942	0,7153	0,6737
0,0309	0,99	0,802	0,5092	0,9925	0,9867	0,9974	0,3582	0,6414	0,6074
0,0221	0,9924	0,805	0,6335	0,993	0,9906	0,9976	0,6382	0,7485	0,6898
0,0246	0,9913	0,8118	0,5466	0,9936	0,9885	0,9978	0,5197	0,6176	0,6105
0,014	0,995	0,7305	0,5953	0,9954	0,9938	0,9985	0,5757	0,7187	0,6493
0,0265	0,9915	0,7922	0,511	0,9932	0,9891	0,9977	0,3963	0,6924	0,5485
0,0227	0,9918	0,8045	0,5948	0,9926	0,99	0,9975	0,6012	0,6914	0,6081
0,0221	0,9926	0,8128	0,6128	0,9933	0,9908	0,9977	0,5395	0,7626	0,6696
0,0204	0,9929	0,7713	0,6069	0,9938	0,9912	0,9979	0,568	0,7414	0,6521
0,0225	0,9923	0,8204	0,5802	0,9936	0,9903	0,9978	0,505	0,7279	0,6494

Pada Gambar 3 menunjukkan bahwa model dengan arsitektur U-Net telah berhasil melakukan segmentasi secara otomatis dan kemudian melakukan prediksi terhadap segmen area dari tumor. Hasil evaluasi pada model terbaik dari arsitektur U-Net didapatkan nilai dice coefficient neocrotic sebesar 0,5757, dice coefficient edema sebesar 0,7187 dan dice coefficient enhancing sebesar 0,6493.




Gambar 3. Hasil Prediksi Model dengan Arsitektur U-Net

Berdasarkan Tabel 2, hasil evaluasi prediksi dengan arsitektur Res-UNet menunjukkan performa yang sangat baik, dengan akurasi mencapai 99%. Namun, nilai loss yang diperoleh lebih tinggi dibandingkan dengan U-Net. Setelah beberapa percobaan pelatihan, model Res-UNet dengan 40 epoch, batch size 64, dan learning rate 0,001 menghasilkan loss terendah dan akurasi yang tinggi. Pada percobaan ini, nilai loss tercatat sebesar 0,0300 dengan akurasi 0,9929.

Tabel 3. Hasil Evaluasi Arsitektur Res-UNet

Loss	Akurasi	Mean IoU	Dice Coef	Precision	Sensitivity	Specificity	Dice Coef Necrotic	Dice Coef Edema	Dice Coef Enhancing
0,1019	0,992	0,7524	0,5167	0,9937	0,9898	0,9978	0,4522	0,6179	0,5619
0,1069	0,9916	0,7756	0,5189	0,9934	0,9888	0,9979	0,4341	0,671	0,5301
0,0358	0,9918	0,7566	0,5832	0,9935	0,9906	0,9979	0,5401	0,6941	0,6035
0,1213	0,9913	0,7711	0,5538	0,9936	0,9897	0,9975	0,4665	0,6578	0,5764
0,0408	0,992	0,5704	0,5419	0,9942	0,99	0,9977	0,4826	0,659	0,5863
0,0989	0,9916	0,7134	0,5441	0,9933	0,9894	0,9976	0,4845	0,6653	0,6063
0,0344	0,9927	0,501	0,6064	0,9938	0,9911	0,9979	0,6016	0,759	0,6647
0,0449	0,9911	0,382	0,4903	0,9935	0,9882	0,9977	0,3494	0,5804	0,5721
0,084	0,9929	0,7282	0,5687	0,9938	0,9909	0,9979	0,4848	0,7013	0,6777
0,0975	0,9915	0,7116	0,5705	0,9938	0,9893	0,9979	0,4838	0,7282	0,6547
0,0306	0,993	0,7232	0,5878	0,9942	0,991	0,998	0,5302	0,7326	0,6824
0,138	0,9921	0,7236	0,5607	0,9931	0,9901	0,9977	0,5057	0,6487	0,6254

Gambar 4 menunjukkan bahwa model dengan arsitektur Res-UNet juga telah berhasil melakukan segmentasi secara otomatis dan kemudian melakukan prediksi terhadap segmen area dari tumor. Hasil evaluasi pada model terbaik dari arsitektur Res-UNet didapatkan nilai dice coefficient neocrotic sebesar 0,5302, dice coefficient edema sebesar 0,7326 dan dice coefficient enhancing sebesar 0,6824.



Gambar 4. Hasil Prediksi Model dengan Arsitektur *Res-Unet*

Berdasarkan hasil eksperimen pada kedua arsitektur, terlihat bahwa dengan menggunakan perhitungan *loss function* dan metrik akurasi yang sama, model terbaik dari arsitektur U-Net menunjukkan kinerja yang lebih unggul dibandingkan dengan model terbaik dari arsitektur Res-UNet. Model U-Net memiliki nilai *loss* yang sangat rendah, yaitu 0,014, dan akurasi yang sangat baik sebesar 0,9950. Meskipun Res-UNet juga mencapai akurasi tinggi sebesar 0,9930, nilai *loss* yang lebih tinggi mengindikasikan kinerja yang kurang optimal dibandingkan U-Net. Kesimpulan ini diperkuat oleh hasil evaluasi prediksi semua model U-Net pada Tabel 3, di mana nilai *loss* tidak melebihi 0,1 atau 10%. Sebagai perbandingan, hasil evaluasi Res-UNet pada Gambar 4 menunjukkan beberapa percobaan memiliki nilai *loss* hingga 0,1 atau 10%. Namun, perlu diingat bahwa kesimpulan ini hanya berlaku untuk perbandingan *loss* dan akurasi pada data BraTS 2020.

5. Kesimpulan

Berdasarkan analisis hasil evaluasi segmentasi citra tumor otak menggunakan arsitektur U-Net dan Res-UNet, dapat disimpulkan bahwa kedua model mampu melakukan segmentasi otomatis dan prediksi segmen area tumor dari citra input yang diberikan. Untuk mencapai kinerja yang optimal, pemilihan konfigurasi hyperparameter yang tepat sangat diperlukan. Berdasarkan perbandingan berbagai metrik, termasuk nilai *loss*, akurasi, Mean IoU, dan Confusion Matrix, arsitektur U-Net dengan pengaturan hyperparameter yaitu epoch sebesar 35, batch size sebesar 64, dan learning rate sebesar 0,001, terbukti menjadi yang terbaik dalam melakukan segmentasi pada data BraTS 2020.

Selain itu, jika dilihat dari nilai dice coefficient, model U-Net dengan konfigurasi yang sama umumnya memiliki performa lebih baik. Namun, model Res-UNet dengan hyperparameter: epoch = 40, batch size = 64, dan learning rate = 0,001, menunjukkan keunggulan dalam memprediksi area tumor yang terkait dengan edema dan peningkatan tumor. Pemilihan arsitektur deep learning yang tepat juga dipengaruhi oleh beberapa faktor lain, seperti jumlah dan kualitas data pelatihan, pengaturan parameter yang optimal, kompleksitas tumor, serta ketersediaan kapasitas komputasi yang diperlukan.

Daftar Pustaka

- [1] I. B. L. M. Suta, R. S. Hartati, dan Y. Divayana, "Diagnosa Tumor Otak Berdasarkan Citra MRI (Magnetic Resonance Imaging)," *Maj. Ilm. Teknol. Elektro*, vol. 18, no. 2, 2019, doi: 10.24843/mite.2019.v18i02.p01.
- [2] D. Hendrati dan S. Wyantuti, "Pengenalan Alat Magnetic Resonance Imaging (MRI) Sebagai Alat Deteksi Kanker Kkn Terintegrasi Ppm Desa Cileles Jatinangor Kabupaten Sumedang," *J. Unpad*, hal. 1–3, 2014.
- [3] S. F. Qonita, "Segmentasi Citra Mri Tumor Otak Menggunakan Gaussian Mixture Model Dan Hybrid Gaussian Mixture

- Model – Spatially Variant Finite Mixture Model Dengan Algoritma Expectation-Maximization.” 2018.
- [4] A. Peryanto, A. Yudhana, dan R. Umar, “Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network,” *Format J. Ilm. Tek. Inform.*, vol. 8, no. 2, hal. 138, 2020, doi: 10.22441/format.2019.v8.i2.007.
 - [5] D. Daimary, M. B. Bora, A. Amitab, dan D. Kandar, “Brain Tumor Segmentation from MRI Images using Hybrid Convolutional Neural Networks,” *Procedia Comput. Sci.*, vol. 167, hal. 2419–2428, 2020, doi: 10.1016/j.procs.2020.03.295.
 - [6] T. Naraloka dan others, “Arsitektur U-Net pada Segmentasi Citra Hati sebagai Deteksi Dini Kanker Liver,” *Techno. com*, vol. 21, no. 4, 2022.
 - [7] Z. Zhang, Q. Liu, dan Y. Wang, “Road Extraction by Deep Residual U-Net,” *IEEE Geosci. Remote Sens. Lett.*, vol. 15, no. 5, hal. 749–753, 2018, doi: 10.1109/LGRS.2018.2802944.
 - [8] N. M. Aboelenein, P. Songhao, A. Koubaa, A. Noor, dan A. Afifi, “HTTU-Net: Hybrid Two Track U-Net for Automatic Brain Tumor Segmentation,” *IEEE Access*, vol. 8, hal. 101406–101415, 2020, doi: 10.1109/ACCESS.2020.2998601.
 - [9] I. Bagus, L. Mahadya, M. Sudarma, dan I. N. S. Kumara, “Resonance Imaging dengan Menggunakan Metode U-NET,” *Maj. Ilm. Teknol. Elektro*, vol. 19, no. 2, hal. 151–156, 2020.
 - [10] J. Feng, J. Deng, Z. Li, Z. Sun, H. Dou, dan K. Jia, “End-to-end Res-UNet based reconstruction algorithm for photoacoustic imaging,” *Biomed. Opt. Express*, vol. 11, no. 9, hal. 5321–5328, 2020, doi: 10.1364/boe.396598.
 - [11] S. Ilahiyah dan A. Nilogiri, “Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network,” *JUSTINDO (Jurnal Sist. Dan Teknol. Inf. Indones.)*, vol. 3, no. 2, hal. 49–56, 2018.
 - [12] A. W. Kusuma dan R. L. Ellyana, “Penerapan Citra Terkompresi Pada Segmentasi Citra Menggunakan Algoritma K-Means,” *J. Terap. Teknol. Inf.*, vol. 2, no. 1, hal. 65–74, 2018, doi: 10.21460/jutei.2018.21.65.
 - [13] M. S. Lui, E. K. Wijaya, dan M. Hidayat, “Segmentasi Citra Hewan Dengan Convolutional Neural Network Arsitektur U-Net,” *Anim. Image Segmentation With Convolutional Neural Netw. U-Net Archit.*, vol. x(30), hal. 1–5, 2018.
 - [14] A. Luqyana, R. Saputra, dan K. Khairunisa, “Klasifikasi Citra MRI Tumor Otak dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network,” *Format J. Ilm. Tek. Inform.*, vol. 8, no. 2, hal. 138, 2020, doi: 10.22441/format.2019.v8.i2.007.