



Artikel Penelitian

# Penerapan Deep Learning dengan Mekanisme Attention untuk Meningkatkan Performa Segmentasi Liver dan Tumor pada Citra CT Menggunakan ResUnet

*Zaky Dafalas Eka Putra<sup>a\*</sup>, Danang Wahyu Utomo<sup>b</sup>*<sup>a,b</sup> Universitas Dian Nuswantoro, Jl. Imam Bonjol No.207, Pendrikan Kidul, Kec. Semarang Tengah, Kota Semarang, Jawa Tengah 50131, Indonesia

## INFORMASI ARTIKEL

### Sejarah Artikel:

Diterima Redaksi: 30 Oktober 2024

Revisi Akhir: 15 Januari 2025

Diterbitkan Online: 31 Januari 2025

## KATA KUNCI

Deep Learning,  
Residual Unet,  
Segmentasi,  
Liver,  
Attention

## KORESPONDENSI

E-mail: 111202113316@mhs.dinus.ac.id\*

## A B S T R A C T

Kanker hati merupakan salah satu penyebab kematian paling tinggi di dunia. Dalam mendeteksi kelainan pada hati perlu dilakukan segmentasi untuk mengambil bagian dari hati yang mengalami gangguan. Namun, metode segmentasi manual memakan waktu dan rawan kesalahan. Selain itu, metode tradisional juga sering kali kesulitan menangani variasi bentuk, ukuran, dan tekstur tumor, serta kualitas citra yang heterogen, sehingga mengurangi akurasi segmentasi. Oleh karena itu, penelitian ini mengusulkan penerapan model segmentasi menggunakan mekanisme Attention ResUnet, yang menggabungkan arsitektur residual dan konvolusi berbasis skip connection, ditingkatkan dengan attention untuk meningkatkan akurasi deteksi tumor. ResUnet dirancang untuk meningkatkan akurasi dan stabilitas segmentasi tumor dengan mengatasi masalah vanishing gradient dan meningkatkan kemampuan deteksi fitur kompleks. Dataset citra CT yang digunakan dalam penelitian ini diproses melalui windowing untuk fokus pada rentang intensitas organ hati dan menghilangkan organ yang tidak penting. Hasil penelitian menunjukkan bahwa model Residual Unet dengan mekanisme Attention mampu meningkatkan performa segmentasi gambar CT hati dan tumor secara signifikan, mencapai akurasi 99,54% dan nilai Dice sebesar 95% pada segmentasi liver, serta akurasi 99,5% dan nilai Dice sebesar 90% pada segmentasi tumor. Penambahan modul Residual dan Attention secara efektif membantu model menangkap fitur yang relevan, khususnya dalam menangani lesi kompleks dan batas kabur, yang sering menjadi tantangan dalam segmentasi citra medis.

## 1. PENDAHULUAN

Hati merupakan organ terbesar dalam tubuh manusia dan merupakan pusat penting bagi berbagai proses fisiologis, seperti dukungan sistem kekebalan tubuh, pengaturan volume darah, dan pemecahan zat beracun [1]. Berdasarkan statistik kanker global, salah satu penyebab utama kematian adalah penyakit hati [2]. Diagnosis dini dapat dilakukan dengan penggunaan sistem *Computer-Aided Diagnosis (CAD)*, yang memungkinkan pasien diprioritaskan berdasarkan tingkat keparahan penyakitnya dan segera diarahkan kepada radiolog. Dengan pendekatan ini, diagnosis dapat dilakukan lebih cepat, sehingga terapi dan penanganan dapat diberikan secara tepat waktu [3].

Saat ini, dokter dan ahli radiologi masih menggunakan teknik rontgen pada bagian hati untuk menemukan penyakit hati secara

manual dalam bentuk gambar *Computed Tomography (CT)* sehingga memungkinkan kita untuk melihat hati dan lesi sekaligus membantu ahli radiologi mengembangkan rencana diagnosis dan pengobatan yang tepat [4], [5]. Data rontgen ini tidak hanya menunjukkan bagian hati tetapi juga pankreas, ginjal, dan empedu [6]. Bagian-bagian tubuh lain yang muncul dalam hasil pemindaian dapat mengganggu proses deteksi penyakit pada hati. Selain itu mendelineasi area tumor hati secara manual dalam gambar ini memerlukan tenaga yang besar dan memakan waktu, sering kali dipengaruhi oleh interpretasi subjektif dari dokter [5]. Kontras yang rendah dan morfologi kompleks dari tumor hati dibandingkan dengan jaringan di sekitarnya memperumit tugas ini [7], [8]

Saat ini, anotasi pada citra medis umumnya dilakukan secara manual oleh tenaga medis menggunakan teknik segmentasi

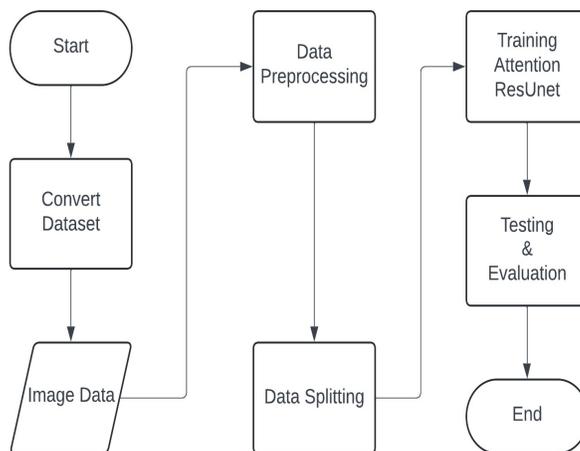
pemrosesan citra tradisional [9]. Segmentasi citra medis adalah salah satu tugas terpenting dalam bidang analisis citra medis, yang bertujuan untuk mengekstraksi informasi kuantitatif tentang berbagai struktur jaringan dan lesi dari citra medis yang rumit [10]. Namun, proses ini membutuhkan waktu yang lama, tenaga yang besar, dan sangat bergantung pada keahlian serta pengalaman tenaga medis[5]. Oleh karena itu, dengan otomatisasi, beban kerja tenaga medis dapat berkurang, meningkatkan kecepatan diagnosa, serta mengurangi risiko kesalahan akibat interpretasi manual terhadap gambar medis yang kompleks [11].

Belakangan ini, segmentasi semantik citra medis berbasis deep learning telah menarik perhatian yang sangat besar. Di antara berbagai arsitektur deep learning, *convolutional neural network* (CNN) menjadi yang paling umum digunakan dalam analisis citra medis [12]. Keunggulan CNN dibandingkan pendekatan konvensional terletak pada kemampuannya untuk secara otomatis membentuk fitur, berbeda dengan teknik rekayasa fitur manual yang digunakan pada model tradisional. Dari CNN, ratusan hingga ribuan model berbasis CNN telah dikembangkan untuk segmentasi gambar, seperti *ResNets* [13], *3D Unet* [14], *DeepSeg* [15], *Attention Unet* [16], dan banyak varian lainnya [17], [18].

Penelitian ini memfokuskan kajian pada penggunaan *Unet* untuk segmentasi citra medis, khususnya dalam segmentasi tumor hati dari citra CT scan. Arsitektur *Unet* menggunakan struktur encoder-decoder serta skip-connections untuk membangun peta segmentasi dari representasi fitur yang padat. Namun, arsitektur *Unet* standar mengalami kesulitan untuk memberikan performa optimal pada area yang jarang atau sparse. Oleh karena itu, berbagai arsitektur *encoder-decoder* yang disesuaikan dan terinspirasi dari *Unet* telah diusulkan untuk mengatasi tantangan tersebut [19], [20], [21].

*Unet* seringkali menghadapi tantangan dalam memulihkan gambar yang di-downsample karena adanya lapisan convolusi dengan stride dan pooling. Untuk membantu proses up-sampling, metode *attention* dapat membantu menghubungkan aliran informasi antara lapisan dangkal dan lapisan yang lebih dalam. Dengan pendekatan ini, akurasi model *Unet* untuk tugas segmentasi *MRI & CT scan* telah meningkat, karena kemampuannya menangkap detail lokal maupun global menjadi lebih baik [16].

Berdasarkan kinerja Standard *Unet* yang masih seringkali menghadapi beberapa tantangan, penelitian ini menggabungkan antara modul residual dan juga mekanisme *attention* kedalam *Unet*. Mengintegrasikan modul residual (*Residual Connections*) di antara *encoder* dan *decoder* yang membantu melatih model yang lebih dalam, memungkinkan untuk mengidentifikasi bentuk dan struktur kompleks, serta memastikan aliran gradien yang lebih baik dan konvergensi yang lebih cepat [22]. Sedangkan di lain sisi, mekanisme *attention* mampu mengontrol aliran informasi di berbagai tingkat dalam pipeline, melakukan transformasi fitur, menekan fitur yang tidak relevan, dan hanya memungkinkan informasi yang berguna untuk melewati lapisan-lapisan jaringan [5]. Ini memungkinkan setiap tingkat untuk fokus pada detail yang saling melengkapi dengan tingkat lainnya, sehingga meningkatkan kinerja jaringan secara keseluruhan. Melalui mekanisme ini, model dapat lebih mendalami informasi yang efektif dalam citra medis, meningkatkan daya ekspresif jaringan, dan mengurangi gangguan dari kebisingan latar belakang. Ini memungkinkan model untuk fokus pada fitur tingkat dalam dari lesi yang diinginkan dan mengklasifikasikannya dengan akurat [5].



Gambar 1. Alur Metode Penelitian

## 2. METODE

Pada bagian ini, akan dipaparkan metode yang digunakan dalam penelitian secara sistematis untuk memastikan akurasi dan validitas hasil segmentasi citra medis yang diperoleh. Penelitian

diawali dengan deskripsi dataset yang digunakan, kemudian dilanjutkan dengan tahap pra-pemrosesan data yang bertujuan untuk meningkatkan kualitas data sebelum analisis. Setiap tahapan, mulai dari persiapan dataset hingga pemilihan metrik evaluasi, dirancang untuk mendukung ketelitian model dalam mengidentifikasi fitur-fitur penting pada citra medis, khususnya dalam konteks segmentasi hati dan tumor. Sebagai tambahan,

sebuah diagram alur akan disajikan untuk menggambarkan urutan langkah-langkah penelitian ini secara terstruktur, sehingga pembaca dapat memahami proses penelitian yang dijalankan secara menyeluruh.

## 2.1. Deskripsi Dataset

Dataset LiTS digunakan untuk menguji dan melatih mode dalam penelitian ini, LiTS berisi 131 gambar tomografi perut terkomputasi yang menunjukkan lesi. Untuk menghindari identifikasi pribadi, gambar telah ditinjau secara visual untuk memastikan bahwa semua data dianonimkan. Gambar hanya diproses menjadi format NIFTY terpadu menggunakan NiBabel dan Python [23].

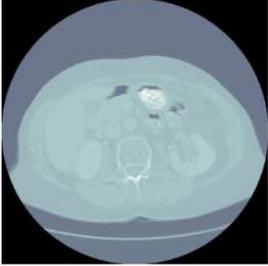
## 2.2. Persiapan dan Preprocessing Data

Pada tahap awal penelitian ini, proses persiapan dan pra-pemrosesan data menjadi langkah krusial yang perlu dilakukan untuk memastikan kualitas dan konsistensi data yang akan digunakan dalam analisis lebih lanjut. Proses ini mencakup beberapa tahapan, yaitu:

### 2.2.1. Data reading

Data NIFTY dibaca dan diconvert menjadi gambar menggunakan *library* nibabel, dengan hasil sampel sebagai berikut.

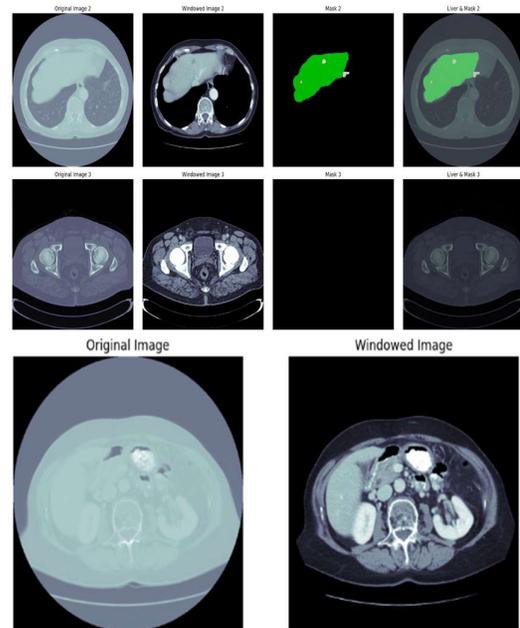
Tabel 1. Sampel Dataset

| Sampel Slice  | Sampel Mask   |
|---|---|
|  |  |

Setelah data dibaca, didapatkan gambar yang mewakili potongan-potongan (slices) dari volume citra medis. Namun, data yang dibaca ini belum sepenuhnya dapat dilihat dengan baik, karena kontras dan detail visual yang diperlukan untuk analisis mendalam masih kurang jelas. Oleh karena itu, pada tahap selanjutnya akan dilakukan proses windowing.

### 2.2.2. Apply Windowing

Untuk fokus pada rentang intensitas organ hati dan menghilangkan organ yang tidak penting, langkah windowing intensitas digunakan [24]. Dalam studi ini, windowing dengan 100 window\_center dan 300 window\_width diterapkan pada kumpulan data yang digunakan dalam pelatihan model untuk segmentasi hati dan tumor.



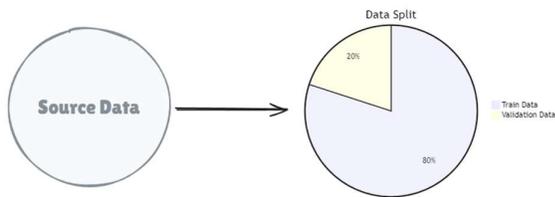
Gambar 2. Sampel Gambar Sebelum dan Setelah Windowing

Penerapan windowing ini tidak hanya membantu dalam meningkatkan kontras citra, tetapi juga berperan penting dalam meminimalkan kebisingan yang dapat mengganggu proses segmentasi. Dengan mengisolasi rentang intensitas yang relevan, informasi yang berkaitan dengan organ hati dan tumor dapat lebih mudah diidentifikasi dan diekstrak. Proses ini memungkinkan model untuk lebih fokus pada karakteristik unik dari jaringan hati, sehingga meningkatkan akurasi segmentasi yang dihasilkan.

Setelah dilakukan windowing seperti yang terlihat pada [Gambar 1](#), didapatkan hasil gambar yang lebih jelas dibandingkan dengan gambar *original sample slice*. Gambar setelah penerapan windowing menunjukkan peningkatan yang signifikan dalam visibilitas struktur dan batasan organ hati, sehingga memfasilitasi analisis lebih lanjut. Peningkatan visual ini sangat penting dalam konteks pengembangan model segmentasi, karena informasi yang lebih baik dan lebih terfokus dapat meningkatkan efektivitas model dalam mengenali dan memetakan area yang diinginkan.

### 2.2.3. Data Splitting

Proses pembagian data (data splitting) adalah langkah yang sangat penting dalam persiapan data, yang bertujuan untuk memisahkan data input yang nantinya akan digunakan untuk menguji kinerja arsitektur model yang dikembangkan [25]. Pembagian ini dilakukan untuk memastikan bahwa model dapat dievaluasi secara objektif, dengan memanfaatkan data yang belum pernah dilihat oleh model selama proses pelatihan. Pembagian yang tepat akan membantu dalam mengukur kemampuan model dalam generalisasi dan menghindari overfitting.



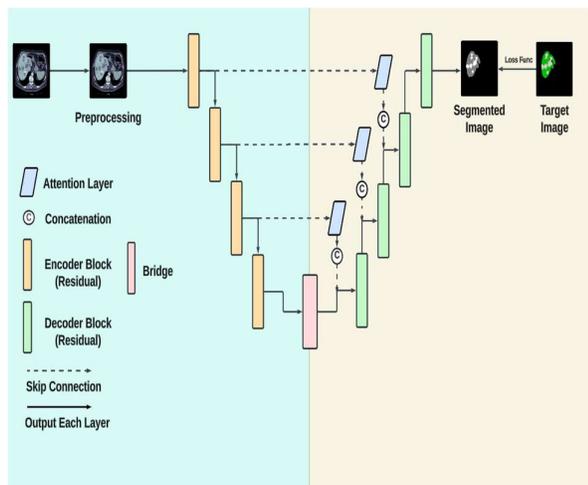
Gambar 3. Data Splitting

Dalam penelitian ini, metode yang digunakan dalam pemisahan data adalah dengan membagi dataset menjadi dua bagian utama: 80% untuk data pelatihan (training) dan 20% untuk data validasi serta pengujian (testing). Pembagian ini bertujuan untuk memberikan proporsi yang cukup bagi model untuk belajar dari data pelatihan, sambil tetap menyisakan cukup banyak data untuk evaluasi kinerja. Dengan cara ini, dipastikan bahwa model memiliki cukup informasi untuk mengenali pola-pola yang ada dalam data, sekaligus menjaga keandalan hasil evaluasi. Proses pemisahan data ini dilakukan secara acak, sehingga setiap instance data memiliki kesempatan yang sama untuk dimasukkan ke dalam set pelatihan atau set validasi/pengujian. Hal ini penting untuk menghindari bias yang mungkin timbul jika pemisahan dilakukan secara manual atau tidak merata. Setelah pemisahan dilakukan, data pelatihan akan digunakan untuk melatih model, sementara data validasi akan digunakan untuk memonitor kinerja model selama proses pelatihan.

Sebagai ilustrasi, Gambar 2 menunjukkan proses pembagian data, menggambarkan alur dari data mentah hingga menjadi set pelatihan dan pengujian yang terpisah.

2.3. Residual Attention Unet

Arsitektur model yang diusulkan adalah modifikasi dari Unet, dengan penambahan Residual Blocks dan Attention Blocks untuk meningkatkan performa segmentasi. Residual blocks digunakan untuk mengatasi masalah vanishing gradient, sedangkan attention blocks membantu model untuk fokus pada bagian citra yang lebih relevan, terutama dalam proses skip connection antara encoder dan decoder [22], [26]



Gambar 4. Arsitektur Residual Unet dengan Attention

Bagian encoder terdiri dari beberapa Residual Blocks yang bertanggung jawab untuk mengekstraksi fitur dari input citra pada

berbagai tingkat resolusi. Setiap residual block berisi dua lapisan konvolusi 3x3, batch normalization, dan aktivasi ReLU, yang dilanjutkan dengan penjumlahan antara input asli dan output lapisan konvolusi untuk menjaga stabilitas gradien [22].

Setelah setiap residual block, dilakukan downsampling menggunakan operasi MaxPooling untuk mengurangi resolusi fitur secara bertahap, memungkinkan model belajar fitur yang lebih abstrak di level yang lebih dalam [22]. Pada titik paling dalam dari model, bridge berfungsi sebagai penghubung antara encoder dan decoder. Bagian ini mengandung Residual Block dengan filter lebih besar (512 filter), dan tidak mengubah resolusi fitur tetapi membantu dalam pemrosesan fitur pada level abstraksi tertinggi sebelum diteruskan ke decoder [26].

Fitur dari encoder diteruskan ke decoder melalui skip connections yang melompati bridge, menghubungkan lapisan encoder dengan lapisan decoder yang sesuai. Namun, sebelum diintegrasikan ke dalam decoder, fitur dari skip connection terlebih dahulu diproses oleh Attention Block. Attention block bertujuan untuk menonjolkan fitur-fitur yang lebih penting dari citra input, dengan cara memfokuskan perhatian pada area-area yang lebih relevan. Setiap attention block terdiri dari dua operasi konvolusi 1x1, yang digunakan untuk mengurangi dimensi fitur dari encoder (theta\_x) dan decoder (phi\_g) sebelum kedua hasil ini dijumlahkan dan diproses melalui aktivasi ReLU [26]. Kemudian, sigmoid activation digunakan untuk membentuk peta perhatian (attention map), yang menunjukkan seberapa penting setiap bagian dari fitur tersebut. Akhirnya, peta attention ini dikalikan secara element-wise dengan fitur dari encoder, sehingga hanya informasi yang relevan yang diteruskan ke decoder [22]

Bagian decoder bertugas untuk mengembalikan resolusi fitur yang telah diperkecil oleh encoder. Setiap tahapan decoder dimulai dengan operasi upsampling yang bertujuan untuk mengembalikan resolusi fitur ke resolusi asli. Setelah upsampling, fitur dari Attention Block yang berasal dari skip connection digabungkan dengan fitur hasil upsampling dari decoder melalui operasi concatenation [22], [26]. Sama seperti pada encoder, Residual Blocks juga digunakan di decoder untuk memastikan aliran gradien yang baik dan memproses fitur secara efisien sebelum dilakukan upsampling lebih lanjut. Ukuran filter di decoder secara bertahap menurun, dari 256 filter di tahap pertama, 128 di tahap kedua, dan 64 di tahap terakhir, mendekati output akhir [22].

2.4. Loss Function

Untuk mengatasi ketidakseimbangan antar kategori dalam sampel pelatihan, Focal Tversky loss dipilih secara eksperimental sebagai fungsi kerugian, guna menghitung kesamaan antara label yang diprediksi dan label sebenarnya, menggunakan rumus berikut [10].

$$T(\alpha, \beta) = \frac{\sum_{i=1}^n p_{0i} g_{0i}}{\sum_{i=1}^n p_{0i} g_{0i} + \alpha \sum_{i=1}^n p_{0i} g_{1i} + \beta \sum_{i=1}^n p_{0i} g_{0i}} \tag{1}$$

p<sub>0i</sub> mewakili probabilitas bahwa voxel ke-i adalah tumor, sedangkan p<sub>1i</sub> mewakili probabilitas bahwa voxel ke-i bukan tumor. Jika g<sub>0i</sub> = 1, voxel tersebut adalah lesi, dan jika g<sub>0i</sub> = 0, voxel tersebut adalah normal, dengan g<sub>1i</sub> sebagai kebalikannya.

Dua hiperparameter,  $\alpha$  dan  $\beta$ , diatur sehingga  $\alpha + \beta = 1$  untuk mengatasi masalah ketidakseimbangan sampel positif dan negatif dalam kinerja model dengan menyesuaikan nilai-nilai ini [10].

### 2.5. Evaluation Metrics

Kinerja model dalam segmentasi gambar hati dievaluasi melalui confusion matrix. Confusion matrix adalah alat untuk menilai performa model pada masalah klasifikasi dalam machine learning dan digunakan sebagai dasar perhitungan evaluasi prediksi model. Matriks ini memiliki empat komponen utama: True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN).[27].

Untuk mengevaluasi kinerja model dan kemampuan generalisasi secara lebih objektif dan komprehensif, dipilihlah metrik evaluasi dice dan akurasi untuk penelitian ini.

#### - Akurasi

Akurasi menunjukkan sejauh mana arsitektur dapat melakukan segmentasi dengan tepat. Nilai akurasi dihitung sesuai dengan Persamaan 5 berikut. [28]

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2)$$

#### - Dice

Dalam segmentasi citra medis, *dice score (DSC)* merupakan ukuran penilaian yang paling sering digunakan. Koefisien Dice mengukur tingkat tumpang tindih antara *mask* yang diprediksi dan *ground truth*. Tingkat tumpang tindih terendah antara nilai prediksi dan nilai sebenarnya dikenal sebagai *dice loss* [29].

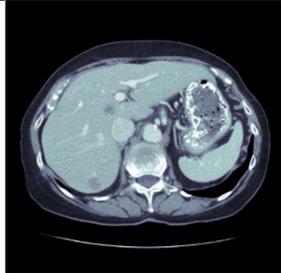
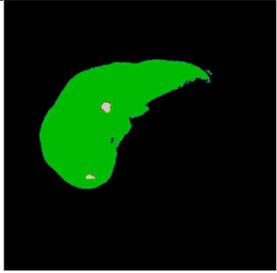
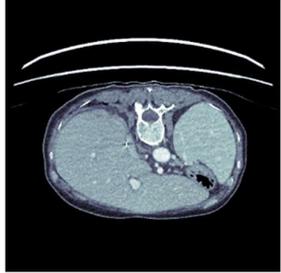
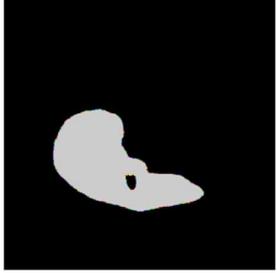
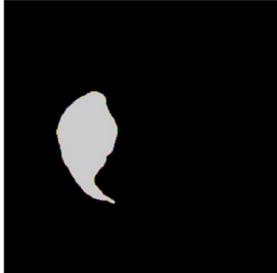
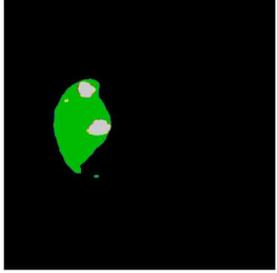
$$DSC = \frac{2TP}{2TP + FP + FN} \quad (3)$$

Koefisien Dice digunakan untuk menilai tingkat kesamaan antara prediksi model dan data sebenarnya, dengan rentang nilai dari 0 hingga 1 [5].

## 3. HASIL

Dataset LiTS digunakan untuk dilakukan uji coba pada penelitian ini, sebanyak 131 citra CT dalam bentuk Nifti file yang kemudian dibaca dan di-*generate* menjadi gambar menggunakan bantuan *library* nibabel. Setelah dataset dapat dibaca selanjutnya dilakukan tahap preprocessing diantaranya dilakukan proses windowing, menormalisasi data dan juga pemisahan data training & validasi, kemudian didapatkan gambar dan data yang telah siap dilakukan pemodelan seperti pada dibawah:

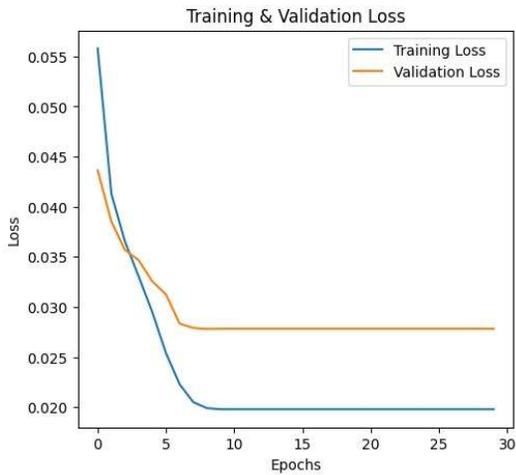
Tabel 2. Data Siap Untuk Modeling

| Slice Input  | Ground Truth  |
|--|---|
|    |    |
|    |    |
|   |   |
|  |  |
|  |  |

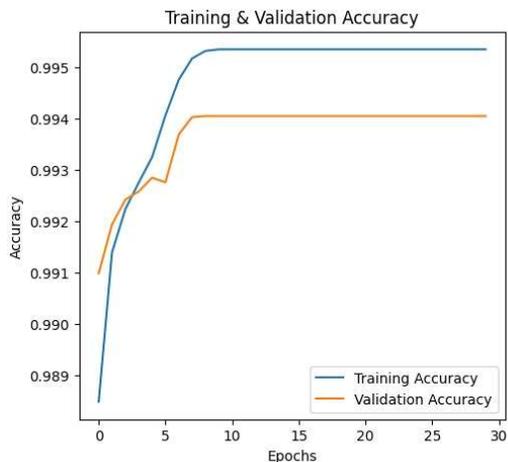
Data pada [Table 2](#) merupakan data yang sudah siap untuk dilakukan proses modeling. Setelah menyelesaikan tahap persiapan dan pra-pemrosesan data, sebanyak 131 citra CT dibagi menjadi set pelatihan dan set validasi dengan rasio 8:2. Proses pelatihan dilakukan menggunakan model *Residual Unet* dengan tambahan mekanisme *Attention* yang bertujuan untuk meningkatkan kemampuan model dalam menangkap fitur penting

pada gambar. Selain itu, *Function Tversky Loss* diterapkan untuk mengatasi ketidakseimbangan kelas pada proses segmentasi.

Dibawah ini disajikan hasil akurasi, dice score, serta grafik history dari perkembangan nilai loss dan akurasi pada setiap *epoch*.



Gambar 5. Learning Curve (Loss)

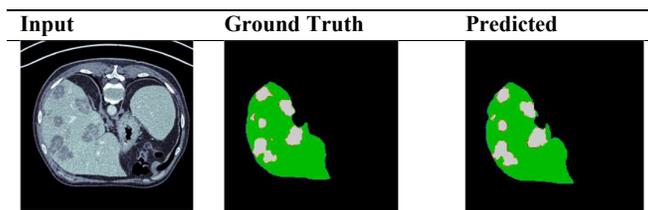


Gambar 6. Learning Curve (Accuracy)

Tabel 3. Rata-rata Dice dan Akurasi untuk segmentasi Liver

| Metode                   | Akurasi | Dice |
|--------------------------|---------|------|
| Residual Unet            | 99.4    | 90   |
| Residual Unet+ Attention | 99.54   | 95   |

Tabel 5. Visualisasi Hasil Segmentasi



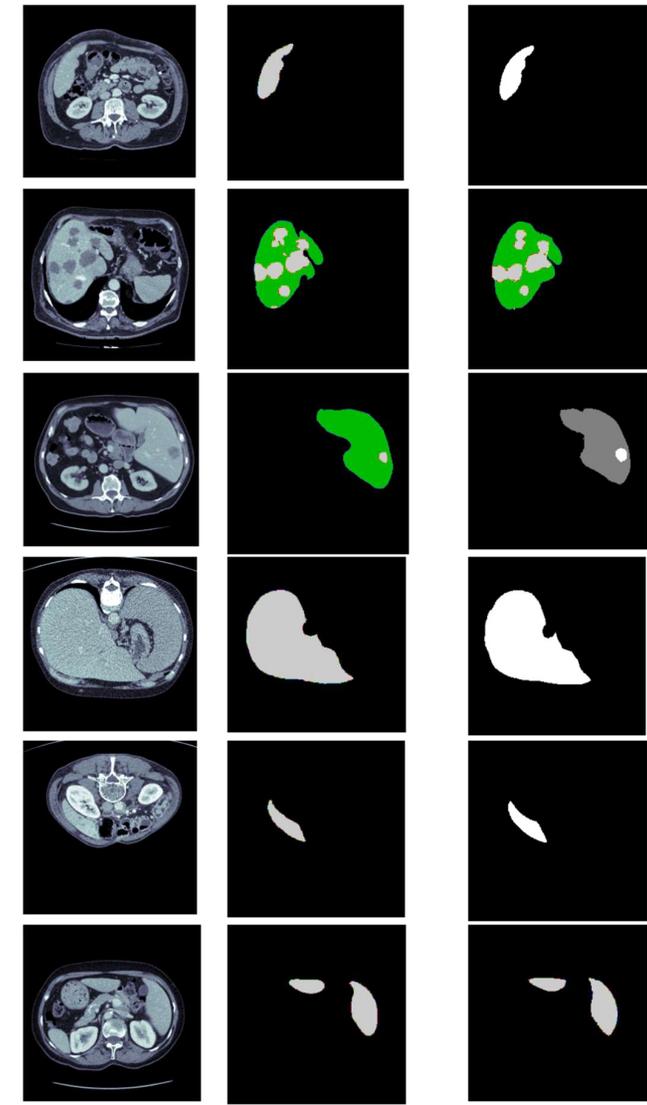
Tabel 4. Rata-rata Dice dan Akurasi untuk segmentasi Tumor

| Metode                   | Akurasi | Dice |
|--------------------------|---------|------|
| Residual Unet            | 99.4    | 65   |
| Residual Unet+ Attention | 99.5    | 90   |

Dapat dilihat pada grafik [Gambar 4](#) grafik *value loss* pada data latih dan validasi mengalami penurunan yang signifikan pada awal proses training dan terus berkurang hingga mendekati nilai yang stabil setelah *epoch* ke-8. Hal ini menunjukkan bahwa model mampu meminimalkan kesalahan selama proses *training*. Sementara itu, pada [Gambar 5](#), grafik akurasi untuk data latih dan validasi menunjukkan peningkatan yang pesat, terutama sebelum *epoch* ke-7, dan mendekati nilai 1, yang menunjukkan model telah mampu mempelajari pola dari data dengan sangat baik. Kemudian dilakukan evaluasi model sesuai dengan persamaan (2) dan (3), pada [Tabel 3](#) terlihat bahwa metode *Residual Unet* menghasilkan akurasi sebesar 99.4% dengan nilai Dice sebesar 90% untuk segmentasi liver.

Ketika ditambahkan mekanisme *Attention*, metode ini berhasil meningkatkan akurasi menjadi 99.54% dan nilai Dice menjadi 95%, yang menunjukkan peningkatan signifikan dalam performa segmentasi. Sementara itu, [Tabel 4](#) menunjukkan performa metode untuk segmentasi tumor. Metode *Residual Unet* menghasilkan akurasi sebesar 99.4% dengan nilai Dice 65%, namun dengan penambahan *Attention*, akurasi meningkat menjadi 99.5% dan nilai Dice naik tajam menjadi 90%. Peningkatan ini menunjukkan bahwa penambahan *Attention* berkontribusi signifikan terhadap peningkatan performa segmentasi, terutama pada objek yang lebih kompleks seperti tumor.

Setelah melakukan evaluasi pada tahap pelatihan dan validasi, berikutnya dilakukan testing untuk menguji kemampuan model dalam memprediksi segmentasi pada data uji. Tahap ini sangat penting untuk memastikan bahwa model mampu bekerja dengan baik pada data yang belum pernah dilihat sebelumnya, serta untuk mengukur performa model secara objektif dalam situasi yang lebih realistis. Hasil pengujian ini akan menunjukkan seberapa efektif model dalam melakukan segmentasi liver dan tumor, dan perbandingan hasil prediksi terhadap data *ground truth* akan disajikan untuk mengevaluasi akurasi dan kualitas segmentasi yang dihasilkan oleh model.



Visualisasi hasil segmentasi tumor ditampilkan pada Tabel 5. Terlihat bahwa model *Residual Unet* dengan *Attention*, memberikan performa segmentasi yang unggul, khususnya dalam menangani lesi dengan batas kabur dan ukuran kecil. Penambahan komponen *Attention* secara signifikan meningkatkan kemampuan model dalam membedakan jaringan yang serupa dan memperbaiki akurasi segmentasi, terutama di area tepi dan lesi yang kompleks.

Model ini mampu melokalisasi jaringan lesi dengan baik, menghasilkan segmentasi dengan batas yang jelas antara area lesi dan jaringan normal. Keberhasilan ini menunjukkan bahwa *Residual Unet* dengan *Attention* efektif dalam mengatasi hilangnya informasi penting dan memberikan hasil segmentasi yang presisi, sehingga memiliki nilai klinis yang tinggi untuk aplikasi segmentasi citra medis.

#### 4. PEMBAHASAN

Pada tahap ini, sangat penting untuk menelaah lebih lanjut hasil kinerja model *Residual Unet* dengan *Attention* dalam segmentasi liver dan tumor. Model ini menunjukkan kinerja yang cukup menjanjikan, baik dari segi akurasi maupun nilai Dice. Namun, untuk memperoleh pemahaman yang lebih komprehensif, kinerja tersebut perlu dibandingkan dengan hasil penelitian lain yang telah menggunakan metode segmentasi serupa. Berbagai studi sebelumnya telah melaporkan beragam pendekatan dalam segmentasi citra medis, dan hasil penelitian ini memberikan kesempatan untuk mengkaji lebih dalam keunggulan dan kelemahan model yang diusulkan. Kinerja segmentasi pada liver dan tumor menjadi salah satu tolak ukur penting karena kedua objek ini memiliki karakteristik yang berbeda, baik dari segi bentuk, ukuran, maupun batas yang kadang sulit untuk diidentifikasi.

Dengan membandingkan nilai akurasi dan Dice dengan penelitian lain, diharapkan dapat diidentifikasi apakah model *Residual Unet* dengan *Attention* telah mencapai hasil yang lebih unggul atau

masih memerlukan penyempurnaan di beberapa aspek. Berikut tabel perbandingan hasil komparasi dengan beberapa penelitian-penelitian yang pernah dilakukan sebelumnya.

Tabel 6. Komparasi Model

| Papper                                | Liver Accuracy | Liver DSC | Tumor Accuracy | Tumor DSC |
|---------------------------------------|----------------|-----------|----------------|-----------|
| Li Hefu (LiTS) [5]                    | -              | -         | -              | 69.2      |
| Yodit Abebe Ayalew (LiTS) [30]        | 99.31          | 96.12     | -              | 74        |
| Jinlin Ma MDAU-Net (LiTS) [10]        | -              | 94.33     | -              | 84        |
| Omar Ibrahim Alirr (LiTS) [24]        | -              | 95.6      | -              | 70        |
| V-Net+WGAN Ma et al [31]              | 94             | 92        | -              | -         |
| <b>Attention Residual Unet (Ours)</b> | 99.54          | 95        | 99.5           | 90        |

Pada tabel ini, terlihat bahwa model *Residual Unet* dengan *Attention* yang diusulkan memiliki keunggulan signifikan dalam beberapa metrik dibandingkan dengan penelitian lain. Model kami menunjukkan nilai akurasi tertinggi dalam segmentasi liver, yaitu 99.54%, dan *Dice Similarity Coefficient* (DSC) sebesar 95%, yang menunjukkan model mampu menangkap karakteristik liver dengan baik. Selain itu, akurasi dan nilai DSC pada segmentasi tumor juga mencapai hasil yang kompetitif, yaitu 99.5% dan 90%. Hasil ini menunjukkan kemampuan model dalam mendeteksi dan memisahkan area tumor dengan cukup presisi.

Dalam konteks ini, penting untuk dicatat bahwa meskipun beberapa model lain juga mencatat nilai DSC yang tinggi, seperti yang ditunjukkan oleh Jinlin Ma [10], dengan nilai DSC 84 untuk segmentasi tumor, model *Residual Unet* dengan *Attention* berhasil melampaui nilai tersebut. Dengan nilai DSC yang tinggi pada kedua objek (liver dan tumor), model ini menunjukkan kemampuannya untuk mengatasi tantangan segmentasi tumor yang kompleks, seperti bentuk yang tidak teratur dan batas yang sulit dikenali.

Hasil ini memperlihatkan bahwa pendekatan dengan *Attention* membantu model untuk lebih fokus pada fitur yang relevan dalam citra, terutama dalam menangani detail tumor yang sering kali kecil atau kurang terdefinisi jelas. Oleh karena itu, model *Residual Unet* dengan *Attention* berpotensi menjadi alternatif yang lebih efektif dalam segmentasi medis, terutama untuk kasus dengan karakteristik objek yang berbeda secara substansial, seperti liver dan tumor.

## 5. KESIMPULAN

Kesimpulan pada penelitian ini adalah bahwa model *Residual Unet* dengan mekanisme *Attention* yang diusulkan terbukti mampu meningkatkan performa segmentasi pada gambar CT hati dan tumor secara signifikan. Dalam segmentasi liver, model ini mencapai akurasi 99.54% dan nilai Dice sebesar 95%, sedangkan untuk segmentasi tumor, akurasi mencapai 99.5% dan nilai Dice sebesar 90%. Penambahan modul *Residual* dan *Attention* secara nyata membantu model dalam menangkap fitur yang lebih relevan, khususnya dalam menangani lesi yang kompleks dan batas yang kabur, yang sering kali menjadi tantangan dalam segmentasi citra medis. Performa ini juga unggul dibandingkan dengan beberapa penelitian sebelumnya, yang menunjukkan potensi model *Residual Unet* dengan *Attention* sebagai solusi efektif dalam aplikasi klinis untuk segmentasi tumor dan hati. Meskipun hasilnya menjanjikan, penelitian ini juga membuka peluang untuk eksplorasi lebih lanjut guna memperbaiki aspek tertentu, seperti peningkatan akurasi segmentasi pada dataset yang lebih beragam.

## DAFTAR PUSTAKA

- [1] L. Han, Y. Chen, J. Li, B. Zhong, Y. Lei, and M. Sun, "Liver segmentation with 2.5D perpendicular UNets," *Computers and Electrical Engineering*, vol. 91, May 2021, doi: [10.1016/j.compeleceng.2021.107118](https://doi.org/10.1016/j.compeleceng.2021.107118).
- [2] A. Aghamohammadi, R. Ranjbarzadeh, F. Naiemi, M. Mogharrebi, S. Dorosti, and M. Bendechache, "TPCNN: Two-path convolutional neural network for tumor and liver segmentation in CT images using a novel encoding approach," *Expert Syst Appl*, vol. 183, Nov. 2021, doi: [10.1016/j.eswa.2021.115406](https://doi.org/10.1016/j.eswa.2021.115406).
- [3] P. Balakrishnan, B. Baskaran, S. Vivekanandan, P. Gokul, and B. Sathiya, "Liver segmentation using Mnet for cirrhosis," *Measurement: Sensors*, vol. 31, Feb. 2024, doi: [10.1016/j.measen.2023.100986](https://doi.org/10.1016/j.measen.2023.100986).
- [4] T. Liu *et al.*, "Spatial feature fusion convolutional network for liver and liver tumor segmentation from CT images," *Med Phys*, vol. 48, no. 1, pp. 264–272, Jan. 2021, doi: [10.1002/mp.14585](https://doi.org/10.1002/mp.14585).
- [5] H. Li and B. Liang, "Liver Tumor Computed Tomography Image Segmentation Based on an Improved U-Net Model," *Applied Sciences (Switzerland)*, vol. 13, no. 20, Oct. 2023, doi: [10.3390/app132011283](https://doi.org/10.3390/app132011283).
- [6] M. Rela, N. R. Suryakari, and P. R. Reddy, "Liver Tumor Segmentation and Classification: A Systematic Review," in *Proceedings of 2020 IEEE-HYDCON International Conference on Engineering in the 4th Industrial Revolution, HYDCON 2020*, Institute of Electrical and Electronics Engineers Inc., Sep. 2020, doi: [10.1109/HYDCON48903.2020.9242757](https://doi.org/10.1109/HYDCON48903.2020.9242757).
- [7] W. Thong, S. Kadoury, N. Piché, and C. J. Pal, "Convolutional networks for kidney segmentation in contrast-enhanced CT scans," *Comput Methods Biomech Biomed Eng Imaging Vis*, vol. 6, no. 3, pp. 277–282, May 2018, doi: [10.1080/21681163.2016.1148636](https://doi.org/10.1080/21681163.2016.1148636).

- [8] L. Sun, L. Jiang, M. Wang, Z. Wang, and Y. Xin, "A Multi-Scale Liver Tumor Segmentation Method Based on Residual and Hybrid Attention Enhanced Network with Contextual Integration," *Sensors*, vol. 24, no. 17, Sep. 2024, doi: [10.3390/s24175845](https://doi.org/10.3390/s24175845).
- [9] Y. Zhou, Q. Kong, Y. Zhu, and Z. Su, "MCFA-UNet: Multiscale Cascaded Feature Attention U-Net for Liver Segmentation," *IRBM*, vol. 44, no. 4, Aug. 2023, doi: [10.1016/j.irbm.2023.100789](https://doi.org/10.1016/j.irbm.2023.100789).
- [10] J. Ma, M. Xia, Z. Ma, and Z. Jiu, "MDAU-Net: A Liver and Liver Tumor Segmentation Method Combining an Attention Mechanism and Multi-Scale Features," *Applied Sciences (Switzerland)*, vol. 13, no. 18, Sep. 2023, doi: [10.3390/app131810443](https://doi.org/10.3390/app131810443).
- [11] N. Alalwan, A. Abozeid, A. A. A. ElHabshy, and A. Alzahrani, "Efficient 3D Deep Learning Model for Medical Image Semantic Segmentation," *Alexandria Engineering Journal*, vol. 60, no. 1, pp. 1231–1239, Feb. 2021, doi: [10.1016/j.aej.2020.10.046](https://doi.org/10.1016/j.aej.2020.10.046).
- [12] W. Yu, M. Wang, Y. Zhang, and L. Zhao, "Reciprocal cross-modal guidance for liver lesion segmentation from multiple phases under incomplete overlap," *Biomed Signal Process Control*, vol. 88, Feb. 2024, doi: [10.1016/j.bspc.2023.105561](https://doi.org/10.1016/j.bspc.2023.105561).
- [13] L. H. Shehab, O. M. Fahmy, S. M. Gasser, and M. S. El-Mahallawy, "An efficient brain tumor image segmentation based on deep residual networks (ResNets)," Sep. 01, 2021, *King Saud University*. doi: [10.1016/j.jksues.2020.06.001](https://doi.org/10.1016/j.jksues.2020.06.001).
- [14] P. Agrawal, N. Katal, and N. Hooda, "Segmentation and classification of brain tumor using 3D-UNet deep neural networks," *International Journal of Cognitive Computing in Engineering*, vol. 3, pp. 199–210, Jun. 2022, doi: [10.1016/j.ijcce.2022.11.001](https://doi.org/10.1016/j.ijcce.2022.11.001).
- [15] R. A. Zeineldin, M. E. Karar, J. Coburger, C. R. Wirtz, and O. Burgert, "DeepSeg: deep neural network framework for automatic brain tumor segmentation using magnetic resonance FLAIR images," *Int J Comput Assist Radiol Surg*, vol. 15, no. 6, pp. 909–920, Jun. 2020, doi: [10.1007/s11548-020-02186-z](https://doi.org/10.1007/s11548-020-02186-z).
- [16] W. R. Khan *et al.*, "A Hybrid Attention-Based Residual Unet for Semantic Segmentation of Brain Tumor," *Computers, Materials and Continua*, vol. 76, no. 1, pp. 647–664, 2023, doi: [10.32604/cmc.2023.039188](https://doi.org/10.32604/cmc.2023.039188).
- [17] F. J. Díaz-Pernas, M. Martínez-Zarzuola, D. González-Ortega, and M. Antón-Rodríguez, "A deep learning approach for brain tumor classification and segmentation using a multiscale convolutional neural network," *Healthcare (Switzerland)*, vol. 9, no. 2, Feb. 2021, doi: [10.3390/healthcare9020153](https://doi.org/10.3390/healthcare9020153).
- [18] H. Fu *et al.*, "HMRNet: High and Multi-Resolution Network With Bidirectional Feature Calibration for Brain Structure Segmentation in Radiotherapy," *IEEE J Biomed Health Inform*, vol. 26, no. 9, pp. 4519–4529, Sep. 2022, doi: [10.1109/JBHI.2022.3181462](https://doi.org/10.1109/JBHI.2022.3181462).
- [19] W. Wang *et al.*, "PVT v2: Improved baselines with Pyramid Vision Transformer," *Comput Vis Media (Beijing)*, vol. 8, no. 3, pp. 415–424, Sep. 2022, doi: [10.1007/s41095-022-0274-8](https://doi.org/10.1007/s41095-022-0274-8).
- [20] C.-H. Huang, H.-Y. Wu, and Y.-L. Lin, "HarDNet-MSEG: A Simple Encoder-Decoder Polyp Segmentation Neural Network that Achieves over 0.9 Mean Dice and 86 FPS," Jan. 2021, [Online]. Available: <http://arxiv.org/abs/2101.07172>
- [21] M. Y. Ansari, Y. Yang, P. K. Meher, and S. P. Dakua, "Dense-PSP-UNet: A neural network for fast inference liver ultrasound segmentation," *Comput Biol Med*, vol. 153, Feb. 2023, doi: [10.1016/j.compbiomed.2022.106478](https://doi.org/10.1016/j.compbiomed.2022.106478).
- [22] A. M. Khan, A. Ashrafee, F. S. Khan, Md. B. Hasan, and Md. H. Kabir, "AttResDU-Net: Medical Image Segmentation Using Attention-based Residual Double U-Net," Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.14255>
- [23] P. Bilic *et al.*, "The Liver Tumor Segmentation Benchmark (LiTS)," Jan. 2019, doi: [10.1016/j.media.2022.102680](https://doi.org/10.1016/j.media.2022.102680).
- [24] O. I. Alirr, "Deep learning and level set approach for liver and tumor segmentation from CT scans," *J Appl Clin Med Phys*, vol. 21, no. 10, pp. 200–209, Oct. 2020, doi: [10.1002/acm2.13003](https://doi.org/10.1002/acm2.13003).
- [25] M. A. Djohar *et al.*, "Liver Segmentation Using Convolutional Neural Network Method with U-Net Architecture," *Journal Of Informatics And Telecommunication Engineering*, vol. 6, no. 1, pp. 221–234, Jul. 2022, doi: [10.31289/jite.v6i1.6751](https://doi.org/10.31289/jite.v6i1.6751).
- [26] J. Cha and J. Jeong, "Improved U-Net with Residual Attention Block for Mixed-Defect Wafer Maps," *Applied Sciences (Switzerland)*, vol. 12, no. 4, Feb. 2022, doi: [10.3390/app12042209](https://doi.org/10.3390/app12042209).
- [27] M. Hasnain, M. F. Pasha, I. Ghani, M. Imran, M. Y. Alzahrani, and R. Budiarto, "Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking," *IEEE Access*, vol. 8, pp. 90847–90861, 2020, doi: [10.1109/ACCESS.2020.2994222](https://doi.org/10.1109/ACCESS.2020.2994222).
- [28] O. Sule and S. Viriri, "Enhanced Convolutional Neural Networks for Segmentation of Retinal Blood Vessel Image," in *2020 Conference on Information Communications Technology and Society, ICTAS 2020 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., Mar. 2020. doi: [10.1109/ICTAS47918.2020.233996](https://doi.org/10.1109/ICTAS47918.2020.233996).
- [29] A. Rehman, M. A. Butt, and M. Zaman, "Attention Res-UNet: Attention Residual UNet with Focal Tversky Loss for Skin Lesion Segmentation," *International Journal of Decision Support System Technology*, vol. 15, no. 1, Dec. 2022, doi: [10.4018/IJDSST.315756](https://doi.org/10.4018/IJDSST.315756).
- [30] Y. A. Ayalew, K. A. Fante, and M. A. Mohammed, "Modified U-Net for liver cancer segmentation from computed tomography images with a new class balancing method," *BMC Biomed Eng*, vol. 3, no. 1, Dec. 2021, doi: [10.1186/s42490-021-00050-y](https://doi.org/10.1186/s42490-021-00050-y).
- [31] J. Ma, Y. Deng, Z. Ma, K. Mao, and Y. Chen, "A Liver Segmentation Method Based on the Fusion of VNet and WGAN," *Comput Math Methods Med*, vol. 2021, 2021, doi: [10.1155/2021/5536903](https://doi.org/10.1155/2021/5536903).