

**KOMBINASI ARSITEKTUR U-NET VGG-19 DENGAN
ATTENTION GATE DALAM SEGMENTASI SEMANTIK PEMBULUH
DARAH ARTERI DAN VENA PADA CITRA RETINA**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar sarjana di
Jurusan Matematika pada Fakultas MIPA**

Oleh:

REFKY MAULANA

NIM 08011282126072



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2025**

LEMBAR PENGESAHAN

**KOMBINASI ARSITEKTUR U-NET VGG-19 DENGAN
ATTENTION GATE DALAM SEGMENTASI SEMANTIK PEMBULUH
DARAH ARTERI DAN VENA PADA CITRA RETINA**

SKRIPSI

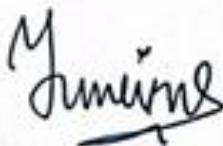
**Diajukan sebagai salah satu syarat untuk memperoleh gelar sarjana di
Jurusan Matematika pada Fakultas MIPA**

Oleh

**REFKY MAULANA
08011282126072**

Indralaya, 13 Januari 2025

Pembimbing Kedua


Irmeilyana, S.Si., M.Si.
NIP. 197405171999032003

Pembimbing Utama


Dr. Anita Desiani, S.Si., M.Kom.
NIP. 197712112003122002

Mengetahui

Ketua Jurusan Matematika



Dr. Dian Cahyawati, S.Si., M.Si

NIP. 197303212000122001

HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH

Yang beranda tangan di bawah ini:

Nama Mahasiswa : Refky Maulana
NIM : 08011282126072
Jurusan : Matematika
Fakultas : Matematika dan Ilmu Pengetahuan Alam

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain. Semua informasi yang dimuat dalam skripsi ini berasal dari penulis lain baik yang dipublikasikan atau telah diberikan penghargaan dengan mengutip nama sumber penulis secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, 30 Januari 2025
Penulis



Refky Maulana
NIM. 08011282126072

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk:

Yang MahaKuasa Allah Subhanahu Wa Ta'ala,

Orang tuaku yang sangat kucinta,

Kakak-kakakku tersayang,

Keluarga Besarku,

Semua Dosenku,

Teman baik yang Kubanggakan,

Almamaterku

Motto

"Leave a follow to join the 1%"

-Refky Maulana

KATA PENGANTAR

Puji syukur atas kehadirat Allah *Subhanahu Wa Ta'ala* yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi berjudul “Kombinasi Arsitektur *U-Net* VGG-19 dengan *Attention Gate* dan *Dropout* dalam Segmentasi Semantik Pembuluh Darah Arteri dan Vena pada Citra Retina”. Skripsi ini ditulis sebagai salah satu syarat memperoleh gelar sarjana sains studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa skripsi ini tidak mungkin terselesaikan tanpa adanya semangat, dukungan, bantuan, bimbingan dan nasihat yang diberikan berbagai pihak selama proses penyusunan ini berlangsung. Penulis mengucapkan terima kasih yang sebesar-besarnya kepada orang tua tercinta, Ibu **Depi Darmita** yang tidak pernah berhenti berjuang dan memberikan yang terbaik untukku sebagai putranya, terkhusus Almarhum Ayahku **Suryono** yang sudah memberikan doa serta pengajaran terbaik kepadaku selama masa hidupnya. Terima kasih karena tak pernah lelah mendidik, menasehati, membimbing, mendukung dan terus mendoakan. Penulis juga ingin menyampaikan ucapan terima kasih kepada sebesar-besarnya dan penghargaan setinggi-tingginya kepada:

1. Bapak **Prof. Hermansyah, S.Si., M.Si., Ph.D** selaku Dekan Fakultas MIPA Universitas Sriwijaya. Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Ketua Jurusan Matematika serta Ibu **Des Alwine Zayanti, S.Si., M.Si.** selaku Sekretaris Jurusan Matematika yang telah membimbing dan mengarahkan dalam urusan akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya.

2. Ibu **Dr. Anita Desiani, S.Si., M.Kom** dan Ibu **Irmeilyana, M.Si.** selaku Dosen Pembimbing yang telah bersedia meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan, arahan dan didikan yang berharga selama pembuatan skripsi, perlombaan dan proses perkuliahan.
3. Bapak **Dr. Bambang Suprihatin, S.Si., M.Si.**, Ibu **Endang Sri Kresnawati, S.Si., M.Si.** dan Ibu **Dra. Ning Eliyati, M.Pd** selaku dosen pembahas yang telah memberikan saran, tanggapan, dan kritik yang sangat bermanfaat untuk penyelesaian dan perbaikan skripsi ini.
4. **Seluruh Dosen di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya** yang telah memberikan ilmu yang sangat bermanfaat bagi penulis. Bapak **Irwansyah** dan Ibu **Hamidah** selaku staf administrasi di Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu penulis selama perkuliahan.
5. Kakak dan adikku tersayang, **Dimas Prabowo** dan **Rapa Bastian** yang senantiasa memberikan semangat dan doa terbaik untuk penulis
6. **Terima kasih kepada kakak-kakak tingkat angkatan 2019 dan 2020 bidang minat komputasi** yang telah membagikan ilmu dan membantu selama proses pembuatan skripsi, **teman-teman bidang minat komputasi angkatan 2021** yang telah berjuang bersama, memberikan bantuan, dan semangat, serta **teman-teman Matematika angkatan 2021** yang telah menemani masa perkuliahan penulis.
7. Semua pihak yang tidak dapat penulis sebutkan satu per satu, semoga semua kebaikan yang telah diberikan mendapatkan balasan dari Allah.

Semoga skripsi ini dapat menambah pengetahuan dan bermanfaat bagi mahasiswa/i Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya dan semua pihak yang membutuhkan.

Indralaya, Januari 2025

Penulis

**KOMBINASI ARSITEKTUR U-NET VGG-19 DENGAN
ATTENTION GATE DALAM SEGMENTASI SEMANTIK PEMBULUH
DARAH ARTERI DAN VENA PADA CITRA RETINA**

By:

Refky Maulana

08011282126072

ABSTRACT

Retinal blood vessels are categorized into arteries and veins. Arteries and veins have distinct functions and characteristics. Separation of arteries and veins in retinal images by semantic segmentation is an important step in supporting the diagnosis process of various diseases. Differences in the characteristics of arteries and veins can indicate the presence of disorders in the retina. This research uses a combination of U-Net architecture with the addition of VGG-19 and Attention Gate to segment arterial and venous blood vessels in retinal images. VGG-19 is applied in all parts of the convolution block contained in the encoder section aimed at learning more complex images. Attention Gate is inserted in the skip connections to focus the model on relevant features. The results of the application of the proposed architecture resulted in average performance on accuracy, sensitivity, specificity, f1-score, and IoU are good in segmenting arterial and venous blood vessels with 98.61%, 81.72%, 91.34%, 82.43% 72.67%. The average performance on the background label shows that the accuracy, sensitivity, f1-score, and IoU values have achieved good performance above 90%, although the specificity is still at 75%. Meanwhile, on vein labels, accuracy and specificity show good performance with values above 90%. However, the performance on sensitivity, f1-score, and IoU is already quite good at above 70%. However, the arterial label is still low due to the relatively small size of arterial features and is difficult to recognize. It is necessary to improve this architecture to get sensitivity, f1-score, and IoU values above 90%.

Keywords: Semantic Segmentation, Retina, *U-Net*, VGG-19, Attention Gate.

**KOMBINASI ARSITEKTUR U-NET VGG-19 DENGAN
ATTENTION GATE DALAM SEGMENTASI SEMANTIK PEMBULUH
DARAH ARTERI DAN VENA PADA CITRA RETINA**

Oleh:

Refky Maulana

08011282126072

ABSTRAK

Pembuluh darah retina terbagi menjadi arteri dan vena. Pembuluh darah arteri dan vena memiliki fungsi dan karakteristik yang berbeda. Pemisahan arteri dan vena pada citra retina secara segmentasi semantik merupakan langkah penting dalam mendukung proses diagnosis berbagai penyakit. Perbedaan karakteristik arteri dan vena dapat menunjukkan adanya gangguan pada retina. Penelitian ini menggunakan kombinasi arsitektur *U-Net* dengan penambahan VGG-19 dan *Attention Gate* untuk segmentasi pembuluh darah arteri dan vena citra retina. VGG-19 diterapkan di seluruh bagian blok konvolusi yang terdapat pada bagian *encoder* ditujukan untuk mempelajari citra yang lebih kompleks. *Attention Gate* disisipkan pada bagian *skip connections* untuk memfokuskan model pada fitur-fitur yang relevan. Hasil penerapan dari arsitektur yang diusulkan menghasilkan rata-rata kinerja pada akurasi, sensitivitas, spesifitas, f1-score, dan IoU sudah baik dalam melakukan segmentasi pembuluh darah arteri dan vena dengan sebesar 98,61%, 81,72%, 91,34%, 82,43% 72,67%. Secara rata-rata kinerja pada label background menunjukkan bahwa nilai akurasi, sensitivitas, f1-score, dan IoU telah mencapai kinerja yang baik sudah berada di atas 90%, meskipun spesifitas masih berada pada 75%. Sementara itu, pada label vena, akurasi dan spesifitas menunjukkan kinerja yang baik dengan nilai di atas 90%. Namun, kinerja pada sensitivitas, f1-score, dan IoU sudah cukup baik berada di atas 70%. Namun, pada label arteri masih rendah disebabkan oleh ukuran fitur arteri yang relatif kecil dan sulit dikenali. Hal ini diperlukan perbaikan pada arsitektur ini untuk mendapatkan nilai sensitivitas, f1-score, dan IoU diatas 90%.

Kata Kunci: Segmentasi Semantik, Retina, *U-Net*, VGG-19, *Attention Gate*.

DAFTAR ISI

HALAMAN PENGESAHAN	ii
HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH	iii
HALAMAN PERSEMPAHAN	iv
KATA PENGANTAR.....	v
ABSTRACT	viii
ABSTRAK	ix
DAFTAR ISI.....	x
DAFTAR TABEL	xiii
DAFTAR GAMBAR.....	xiv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	6
1.3 Tujuan	6
1.4 Batasan Masalah	6
1.5 Manfaat	7
BAB II TINJAUAN PUSTAKA.....	8
2.1 Retina	8
2.2 Citra Digital	8
2.3 Segmentasi Citra Semantik	9
2.4 <i>Preprocessing</i> Data.....	9
2.4.1 Augmentasi Data	9
2.4.2 Perbaikan Kualitas Citra: <i>Contrast Limited Adaptive Histogram Equalization</i>	10
2.4.3 <i>Patch</i>	11
2.5 <i>Convolutional Neural Network</i> (CNN).....	11
2.5.1 <i>Encoder VGG-19</i>	11
2.5.2 <i>Bridge U-Net</i>	17
2.5.3 <i>Decoder U-Net</i> dan <i>Attention Gate</i>	18
2.6 <i>U-Net</i>	22
2.7 VGG-19	23
2.8 Fungsi Aktivasi Softmax	24

2.9	<i>Loss Function: Categorical Cross-Entropy</i>	24
2.10	<i>Optimization Function: Adaptive Moment Estimation (Adam)</i>	25
2.11	<i>Confusion Matrix</i>	26
BAB III METODOLOGI PENELITIAN	29
3.1	Tempat	29
3.2	Waktu.....	29
3.3	Alat.....	29
3.4	Tahapan Penelitian.....	30
3.4.1	Pengumpulan Data	30
3.4.2	<i>Preprocessing Data</i>	30
3.4.3	Implementasi Arsitektur <i>U-Net VGG-19</i> dengan <i>Attention Gate</i>	31
3.4.4	Evaluasi kinerja model	34
3.4.5	Analisis dan Pengambilan kesimpulan penelitian	34
BAB IV HASIL DAN PEMBAHASAN	35
4.1	Deskripsi Data.....	35
4.2	<i>Preprocessing Data</i>	36
4.3	Kombinasi Arsitektur VGG19, <i>U-Net</i> dan <i>Attention Gate</i>	38
4.4	Operasi Manual CNN	39
4.4.1	<i>Encoder VGG</i>	40
4.4.2	<i>Decoder</i> dan <i>Attention Gate</i>	49
4.4.3	Fungsi Aktivasi Softmax	54
4.4.4	<i>Loss Function: Categorical Cross Entropy</i>	57
4.4.5	<i>Optimization Function: Adaptive Moment Estimation (Adam)</i>	59
4.5	Hasil Implementasi Kombinasi Arsitektur <i>U-Net VGG-19</i> dan <i>Attention Gate</i>	62
4.5.1	<i>Training</i>	62
4.5.2	<i>Testing Data</i>	64
4.5.3	Evaluasi	68
4.6	Pembahasan, Analisis dan Interpretasi Hasil	74
BAB V KESIMPULAN DAN SARAN	77
5.1	Kesimpulan	77

5.2 Saran	77
DAFTAR PUSTAKA	79

DAFTAR TABEL

Tabel 2.1 <i>Confusion Matrix</i>	26
Tabel 2.2 Kategori Nilai Evaluasi Kinerja Model	28
Tabel 4.1 Dataset Citra Retina pada Dataset RITE.....	35
Tabel 4.2 Perbandingan Citra Asli, <i>Ground Truth</i> dan Hasil Segmentasi	65
Tabel 4.3 <i>Confusion Matrix</i> dari Proses <i>Testing</i>	66
Tabel 4.4 Evaluasi Kinerja Model	74
Tabel 4.5 Perbandingan Hasil Evaluasi Kinerja dengan Penelitian Lain.....	75

DAFTAR GAMBAR

Gambar 2.1 Arteri dan Vena pada Citra Retina	8
Gambar 2.2 Proses Augmentasi Citra	10
Gambar 2.3 <i>Padding Same</i>	12
Gambar 2.4 Ilustrasi Proses Konvolusi	13
Gambar 2.5 Ilustrasi <i>Dropout</i>	16
Gambar 2.6 Ilustrasi <i>Max pooling</i>	17
Gambar 2.7 Ilustrasi <i>Upsampling</i>	18
Gambar 2.8 <i>Attention Gate</i>	19
Gambar 2.9 Ilustrasi <i>Concatenate</i>	21
Gambar 2.10 Arsitektur <i>U-Net</i>	22
Gambar 2.11 Ilustrasi Arsitektur VGG-19.....	23
Gambar 4.1 Segmentasi Semantik Arteri dan Vena.....	36
Gambar 4.2 Proses Augmentasi dan perbaikan citra	37
Gambar 4.3 Proses <i>Patching</i>	38
Gambar 4.4 Kombinasi Arsitektur <i>U-Net</i> , VGG-19, dan <i>Attention Gate</i>	39
Gambar 4.5 Proses Pembagian Matriks <i>Input</i> ke Submatriks.....	48
Gambar 4.6 Proses <i>Concatenate</i>	54
Gambar 4.7 Grafik Akurasi.....	63
Gambar 4.8 Grafik <i>Loss</i>	64

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pembuluh darah merupakan salah satu bagian dari retina yang terbagi ke dalam dua jenis utama, yaitu arteri dan vena, yang masing-masing memiliki fungsi yang berbeda (Yin *et al.*, 2019). Arteri berfungsi mengalirkan darah yang kaya oksigen, sehingga tampak lebih terang karena kandungan oksigennya yang tinggi (Kiruthika *et al.*, 2019). Sebaliknya, vena membawa darah dengan kadar oksigen yang lebih rendah, sehingga terlihat lebih gelap (Kiruthika *et al.*, 2019). Ketidaknormalan pembuluh darah pada retina, seperti penyempitan arteri dapat menunjukkan adanya peningkatan risiko hipertensi (Hemelings *et al.*, 2019). Sebaliknya, pelebaran vena berhubungan dengan kerusakan yang disebabkan oleh glaukoma (Morano *et al.*, 2021).

Pemisahan pembuluh darah berguna untuk mendeteksi ketidaknormalan pada pembuluh darah melalui segmentasi citra. Segmentasi citra adalah teknik untuk membagi citra menjadi dua atau lebih bagian yang memiliki makna tertentu (Minaee *et al.*, 2022). Segmentasi citra pada pembuluh darah bertujuan untuk memisahkan area pembuluh darah dari *background* citra retina, sehingga bagian-bagian pembuluh darah dapat dianalisis secara terpisah. Segmentasi citra pada pembuluh darah dapat dilakukan secara manual oleh ahli pakar, namun membutuhkan waktu, tenaga, dan biaya yang besar (Qin & Chen, 2024). Pengembangan algoritma segmentasi otomatis menggunakan metode *Convolutional neural network* (CNN) diperlukan untuk mengatasi keterbatasan

yang ada pada segmentasi manual (Zhang *et al.*, 2020). CNN merupakan metode yang memiliki kemampuan untuk mengenali dan mengidentifikasi objek pada berbagai jenis data seperti teks, sinyal, dan citra (Hashemi, 2019). *Input* CNN berupa matriks dengan dimensi $m \times n$ sehingga cocok digunakan pada data citra. Arsitektur CNN yang dikembangkan untuk segmentasi citra yaitu *U-Net*. Arsitektur *U-Net* terdiri dari *encoder* dan *decoder* (Huang *et al.*, 2020). Pada bagian *encoder* *U-Net* menggunakan *convolution* dan *max pooling*, sedangkan pada bagian *decoder* menggunakan *upsampling*, *Concatenate*, dan *convolution* (Ren *et al.*, 2022). *Encoder* berfungsi untuk mengambil fitur penting dari citra melalui serangkaian operasi konvolusi dan *downsampling*, sedangkan *decoder* berfungsi untuk mengembalikan citra ke resolusi aslinya melalui proses *upsampling* (S. Wang *et al.*, 2020). Struktur *encoder-decoder* yang simetris pada arsitektur *U-Net* memungkinkan model mendekripsi detail penting dalam segmentasi citra, seperti tepi objek dan struktur kecil yang sulit dikenali (Chen, 2023).

Hemelings *et al.*, (2019) menerapkan *U-Net* untuk segmentasi pembuluh darah arteri dan vena pada citra retina mencapai akurasi 94,27%, namun penelitian ini tidak mengukur evaluasi kinerja lain seperti sensitivitas, spesifitas dan F1-score. Z. Wang *et al.*, (2019) menerapkan arsitektur *U-Net* pada segmentasi semantik pembuluh darah retina menghasilkan sensitivitas 90,74%, sayangnya akurasi dan spesifitas hanya 87,12% dan 82.87%. *U-Net* sendiri merupakan arsitektur yang sangat populer dalam segmentasi citra (Fu *et al.*, 2020; Z. Liu, 2018). Namun, bagian *encoder* *U-Net* memiliki lapisan pembelajaran yang cukup dangkal. Pembelajaran yang cukup dangkal dapat menyebabkan mengurangi

kemampuan model dalam mempelajari citra kompleks (Desiani *et al.*, 2022). Selain itu, penambahan lapisan pada arsitektur *U-Net* dapat meningkatkan jumlah parameter (Desiani *et al.*, 2022). Salah satu arsitektur yang memiliki bagian *encoder* dengan lapisan yang lebih dalam dan dikenal dapat mempelajari citra yang lebih kompleks adalah *Visual Geometry Group* (VGG).

VGG merupakan arsitektur CNN yang memiliki lapisan mendalam yang menggunakan kernel berukuran 3×3 untuk ekstraksi fitur (Desiani *et al.*, 2022) . Penggunaan kernel 3×3 secara berturut-turut memungkinkan model menganalisis bagian kecil citra terlebih dahulu, lalu menggabungkannya secara bertahap sehingga dapat memahami area yang lebih besar dan pola yang lebih kompleks. VGG adalah arsitektur yang dirancang khusus untuk klasifikasi sehingga VGG hanya memiliki bagian *encoder*. Modifikasi arsitektur VGG dengan *U-Net* telah banyak diterapkan dalam berbagai penelitian. Desiani *et al.*, (2022) menerapkan VGG pada *U-Net* sebagai *encoder* dengan penambahan dense blok dalam segmentasi pembuluh darah pada citra retina menghasilkan akurasi 95,36%, spesifisitas 97,61%. Namun, IoU dan sensitivitasnya dibawah 80%. Anene & Li, (2023) mengkombinasikan arsitektur *U-Net* dengan VGG sebagai *encoder* dalam segmentasi pembuluh darah pada citra retina memperoleh akurasi sangat baik 95.52%. Namun, *sensitivitas* dan *F1-score* memperoleh dibawah 70%. Desiani *et al.*, (2022) menerapkan VGG pada *U-Net* dengan penambahan *Batch normalization* dalam segmentasi pembuluh darah pada citra retina menghasilkan akurasi sebesar 96,39%, spesifisitas 98,1%. Namun sensitivitas, *F1-score* dan IoU masih dibawah 80%. Penelitian-penelitian tersebut masih berfokus pada segmentasi dua kelas,

yaitu pembuluh darah dan *background*. Selain kekurangan pada bagian *encoder*, *U-Net* juga memiliki kekurangan pada bagian *decoder*. Pada bagian *decoder U-Net*, di mana fitur-fitur yang telah diperkecil oleh *encoder* dikembalikan ke resolusi aslinya melalui proses *upsampling* (S. Wang *et al.*, 2020). Namun, terdapat kekurangan pada bagian *decoder*, yaitu pencampuran informasi yang tidak relevan, yang mengurangi kemampuan model untuk fokus pada fitur penting dan menghasilkan segmentasi yang kurang akurat (Ying *et al.*, 2020). Salah satu mekanisme pada CNN yang dapat digunakan untuk memilih fitur yang diteruskan adalah *attention gate*.

Attention Gate merupakan mekanisme dalam arsitektur jaringan saraf yang berfungsi untuk memfokuskan model pada fitur-fitur yang relevan, sekaligus menyaring fitur-fitur yang tidak relevan (Al Qurri & Almekkawy, 2023). Fitur-fitur disaring melalui penggunaan melibatkan dua *input* yang dilakukan operasi konvolusi 1×1 dan menggunakan dua fungsi aktivasi yaitu ReLU dan sigmoid (Oktay *et al.*, 2018). ReLU memperkuat fitur relevan dengan menekan nilai negatif, sedangkan sigmoid mengidentifikasi fitur relevan dengan nilai mendekati 1 dan mengabaikan yang mendekati 0. Zhao *et al.*, (2023) menerapkan *attention gate* pada arsitektur *U-Net* dalam segmentasi pembuluh darah retina menghasilkan akurasi 95%. Namun IoU dibawah 70% dan belum melakukan segmentasi semantik. R. Li *et al.*, (2019) menerapkan *attention gate* pada arsitektur *U-Net* dalam segmentasi pembuluh darah retina menghasilkan akurasi 96,2%, tetapi IoU dibawah 80%. K. Li *et al.*, (2020) menerapkan *attention gate* pada arsitektur *U-Net* dalam segmentasi pembuluh darah retina menghasilkan akurasi 97,64%, spesifisitas 98,71% dan

sensitivitas 82,47%. Namun penelitian-penelitian tersebut masih berfokus pada segmentasi dua kelas, yaitu pembuluh darah dan *background*.

Penambahan VGG pada *U-Net* dapat menyebabkan peningkatan jumlah parameter yang signifikan, karena VGG dikenal sebagai arsitektur dengan jumlah parameter yang besar, sebesar 138 juta (Militante *et al.*, 2020). Jumlah parameter yang berlebihan sering kali menyebabkan model mengalami *overfitting*. Untuk mengatasi masalah *overfitting*, salah satu teknik yang dapat digunakan adalah *dropout*. *Dropout* bekerja dengan menghapus secara acak sejumlah unit dalam jaringan pada setiap iterasi pelatihan, berdasarkan probabilitas yang telah ditentukan, dan berlangsung secara dinamis selama pelatihan (Qian *et al.*, 2020). Penghapusan unit neuron ini bertujuan untuk mencegah model terlalu bergantung pada pola tertentu dalam data pelatihan. Guo *et al.*, (2019) menerapkan metode *dropout* pada arsitektur *U-Net* untuk segmentasi pembuluh darah pada citra retina menghasilkan akurasi 96.74%, namun penelitian ini tidak mengukur evaluasi kinerja lain seperti sensitivitas dan spesifitasnya. Li *et al.*, (2019) menerapkan metode *dropout* pada arsitektur ResNet dalam segmentasi pembuluh darah pada citra retina menghasilkan F1-score 81,47%, namun sensitivitasnya masih di bawah 80%.

Penelitian ini memodifikasi arsitektur *U-Net* untuk segmentasi pembuluh darah arteri dan vena pada citra retina. Arsitektur yang diusulkan merupakan modifikasi *U-Net* menggunakan VGG pada *encoder* dan *attention gate* pada *decoder*. Penggunaan VGG pada bagian *encoder* ditujukan untuk mempelajari citra yang lebih kompleks. Pada bagian *decoder* *U-Net* disisipkan *attention gate*

ditujukan untuk memfokuskan model pada fitur-fitur yang relevan. *Dropout* diterapkan setelah lapisan konvolusi di setiap blok konvolusi pada bagian *encoder*. *Dropout* diterapkan pada arsitektur ini bertujuan untuk mengurangi risiko *overfitting* akibat kompleksitas jaringan yang tinggi selama pelatihan model. Penelitian ini melakukan segmentasi semantik pada pembuluh darah retina dengan memisahkan arteri dan vena sebagai *foreground* dari *background*. Untuk mengukur kinerja arsitektur yang diusulkan dalam segmentasi arteri dan vena secara semantik digunakan metrik kinerja berdasarkan nilai akurasi, sensitivitas, spesifisitas, IoU dan F1-score.

1.2 Rumusan Masalah

Rumusan masalah dari penelitian ini adalah bagaimana kinerja dari hasil penerapan kombinasi arsitektur *U-Net* dan VGG-19 dengan *Attention Gate* pada segmentasi semantik pembuluh darah arteri dan vena pada citra retina.

1.3 Tujuan

Tujuan dari penelitian ini adalah untuk mengukur evaluasi kinerja segmentasi semantik yang dihasilkan dari penerapan kombinasi arsitektur *U-Net* dan VGG-19 dengan *Attention Gate* pada segmentasi semantik pembuluh darah arteri dan vena pada citra retina.

1.4 Batasan Masalah

Batasan masalah yang diterapkan pada penelitian ini adalah

1. Data yang digunakan dalam penelitian ini berasal dari dataset RITE (*Retinal Images vessel Tree Extraction*).
2. Data yang digunakan pada penelitian ini terdiri dari 3 label.
3. Ukuran evaluasi kinerja pada segmentasi semantik ini menggunakan akurasi, IoU, F1-score, sensitivitas, dan spesifisitas.

1.5 Manfaat

Manfaat dari hasil penelitian ini adalah:

1. Dapat memperoleh hasil segmentasi semantik yang mampu membedakan antara pembuluh darah arteri dan vena pada citra retina.
2. Dapat digunakan sebagai referensi dalam pengembangan segmentasi pembuluh darah arteri dan vena secara otomatis untuk diagnosis medis, mengurangi ketergantungan pada metode manual yang memakan waktu dan biaya.

DAFTAR PUSTAKA

- Al Qurri, A., & Almekkawy, M. (2023). Improved unet with attention for medical image segmentation. *Sensors (Basel, Switzerland)*, 23(20), 1–17. <https://doi.org/10.3390/s23208589>
- Alqadi, Z., Khrisat, M., Hindi, A., Omar Dwairi, M., & Khrisat, M. S. (2020). Features analysis of RGB color image based on wavelet packet information. *International Journal of Computer Science and Mobile Computing*, 9(3), 149–156. <https://doi.org/10.47760/ijcsmc.2022.v9i3.021>
- Alshomrani, S., Arif, M., & Al Ghamdi, M. A. (2023). SAA-UNet: Spatial attention and attention gate UNet for covid-19 pneumonia segmentation from computed tomography. *Diagnostics*, 13(9), 1–26. <https://doi.org/10.3390%2Fdiagnostics13091658>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 1–74. <https://doi.org/10.1186/s40537-021-00444-8>
- Anene, I. L., & Li, Y. (2023). Segmentation of retinal blood vessels using deep learning. *ArXiv Preprint ArXiv:2303.09679*, 1–12. <https://doi.org/10.48550/arXiv.2303.09679>
- Bjorck, J., Gomes, C., Selman, B., & Weinberger, K. Q. (2018). Understanding batch normalization. *Advances in Neural Information Processing Systems*, 1–12. <https://doi.org/10.48550/arXiv.1806.02375>
- Chen, Z. (2023). Medical image segmentation based on u-net. *Journal of Physics: Conference Series*, 2547(1), 1–7. <https://doi.org/10.1088/1742-6596/2547/1/012010>
- Costa, R. F. da, Hayashi Yelisetty, S. M., Marques, J. C., & Tasinaffo, P. M. (2019). A brief didactic theoretical review on convolutional neural networks, deep belief networks and stacked auto-encoders. *International Journal of Engineering and Technical Research (IJETR)*, 9(12), 5–12. <https://doi.org/10.31873/ijetr.9.12.35>
- Desiani, A., Erwin, Suprihatin, B., Efriliyanti, F., Arhami, M., & Setyaningsih, E. (2022). VG-DropDNet a robust architecture for blood vessels segmentation on retinal image. *IEEE Access*, 10(6), 92067–92083. <https://doi.org/10.1109/ACCESS.2022.3202890>
- Desiani, A., Erwin, Suprihatin, B., Wahyudi, Y., Cahyono, E. S., & Arhami, M. (2022). BVU-Net: A u-net modification by VGG-batch normalization for retinal blood vessel segmentation. *International Journal of Intelligent Engineering and Systems*, 15(6), 303–314. <https://doi.org/10.22266/ijies2022.1231.29>

- Dharmawan, D. A., & Listyalina, L. (2019). Retinal blood vessel segmentation as a tool to detect diabetic retinopathy. *Universitas Respati Yogyakarta Jalan Laksda Adisucipto Km, 3(2)*, 44–49. <https://doi.org/10.18196/jet.3253>
- Fernandez-moral, E., Martins, R., Wolf, D., & Rives, P. (2018). A new metric for evaluating semantic segmentation : leveraging global and contour accuracy. *IEEE Intelligent Vehicles Symposium, Proceedings, 4*, 1051–1056. <https://doi.org/10.1109/IVS.2018.8500497>
- Fu, W., Breininger, K., Pan, Z., & Maier, A. (2020). Degenerating u-net on retinal vessel segmentation: What do we really need? *Informatik Aktuell, 33–38*. https://doi.org/10.1007/978-3-658-29267-6_7
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). Fundamental concepts of convolutional neural network. In *Intelligent Systems Reference Library* (Vol. 172, Issue 6). https://doi.org/10.1007/978-3-030-32644-9_36
- Guo, C., Szemenyei, M., Pei, Y., Yi, Y., & Zhou, W. (2019). SD-Unet: A structured dropout u-net for retinal vessel segmentation. *Proceedings - 2019 IEEE 19th International Conference on Bioinformatics and Bioengineering, BIBE 2019, 439–444*. <https://doi.org/10.1109/BIBE.2019.00085>
- Hashemi, M. (2019). Enlarging smaller images before inputting into convolutional neural network: zero-padding vs. interpolation. *Journal of Big Data, 6(1)*, 1–13. <https://doi.org/10.1186/s40537-019-0263-7>
- Hemelings, R., Elen, B., Stalmans, I., Van Keer, K., De Boever, P., & Blaschko, M. B. (2019). Artery–vein segmentation in fundus images using a fully convolutional network. *Computerized Medical Imaging and Graphics, 76*, 1–12. <https://doi.org/10.1016/j.compmedimag.2019.05.004>
- Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports, 12(1)*, 1–9. <https://doi.org/10.1038/s41598-022-09954-8>
- Huang, H., Lin, L., Tong, R., Hu, H., Zhang, Q., Iwamoto, Y., Han, X., Chen, Y. W., & Wu, J. (2020). UNet 3+: A full-scale connected unet for medical image segmentation. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings, 1055–1059*. <https://doi.org/10.1109/ICASSP40776.2020.9053405>
- Hyun, J., Seong, H., & Kim, E. (2021). Universal pooling – a new pooling method for convolutional neural networks. *Expert Systems With Applications, 180(11)*, 1–16. <https://doi.org/10.1016/j.eswa.2021.115084>
- Kesidis, A. L., Krassanakis, V., Misthos, L. M., & Merlemis, N. (2022). patchIT: A multipurpose patch creation tool for image processing applications. *Multimodal Technologies and Interaction, 6(12)*, 1–21. <https://doi.org/10.3390/mti6120111>

- Khan, A., Sohail, A., Zahoor, U., & Saeed, A. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 1–70. <https://doi.org/10.1007/s10462-020-09825-6>
- Kingma, D. P., & Ba, J. L. (2015). ADAM: A method for stochastic optimization. In *ICLR 2015 - Conference Track Proceedings*, 1–15. <https://doi.org/10.48550/arXiv.1412.6980>
- Kiruthika, M., Swapna, T. R., Santhosh, K. C., & Peeyush, K. P. (2019). Artery and vein classification for hypertensive retinopathy. In *Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019*, 244–248. <https://doi.org/10.1109/ICOEI.2019.8862719>
- Li, D., Dharmawan, D. A., Ng, B. P., & Rahardja, S. (2019). Residual u-net for retinal vessel segmentation. In *2019 IEEE International Conference on Image Processing (ICIP)*, 1425–1429. <https://doi.org/10.1109/ICIP.2019.8803101>
- Li, K., Yao, Z., Luo, Y., Qi, X., Liu, P., & Wang, Z. (2020). Retinal blood vessel segmentation via attention gate network. In *ACM International Conference Proceeding Series*, 247–251. <https://doi.org/10.1145/3429889.3429936>
- Li, Q., Xu, Y., Chen, Z., Liu, D., Feng, S. T., Law, M., Ye, Y., & Huang, B. (2018). Tumor segmentation in contrast-enhanced magnetic resonance imaging for nasopharyngeal carcinoma: Deep learning with convolutional neural network. In *BioMed Research International*, 2018, 1–7. <https://doi.org/10.1155/2018/9128527>
- Li, R., Li, M., & Li, J. (2019). Connection sensitive attention u-net for accurate retinal vessel segmentation. *ArXiv Preprint ArXiv:1903.05558*, 1–10. <https://doi.org/10.48550/arXiv.1903.05558>
- Liu, X., Ono, K., & Bise, R. (2024). A data augmentation approach that ensures the reliability of foregrounds in medical image segmentation. *Image and Vision Computing*, 147, 1–9. <https://doi.org/10.1016/j.imavis.2024.105056>
- Liu, Z. (2018). Retinal vessel segmentation based on Fully Convolutional Neural Networks. *Expert Systems with Applications*, 112, 229–242. <https://doi.org/10.1016/j.eswa.2018.06.034>
- Maji, D., Sigedar, P., & Singh, M. (2022). Attention res-unet with guided decoder for semantic segmentation of brain tumors. *Biomedical Signal Processing and Control*, 71, 1–9. <https://doi.org/10.1016/j.bspc.2021.103077>
- Markkandeyan, S., Gupta, S., Narayanan, G. V., Reddy, M. J., Al-khasawneh, M. A., Ishrat, M., Kiran, A., Markkandeyan, S., & Al-khasawneh, M. A. (2023). CCC Publications deep learning based semantic segmentation approach for automatic detection of brain tumor. *International Journal of Computers Communications & Control*, 18(4), 1–4. <https://doi.org/10.15837/ijccc.2023.4.5186>
- Militante, S. V., Dionisio, N. V., & Sibbaluca, B. G. (2020). Pneumonia detection

- through adaptive deep learning models of convolutional neural networks. *2020 11th IEEE Control and System Graduate Research Colloquium, ICSGRC 2020 - Proceedings*, 88–93. <https://doi.org/10.1109/ICSGRC49013.2020.9232613>
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D. (2022). Image segmentation using deep learning: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(7), 3523–3542. <https://doi.org/10.1109/TPAMI.2021.3059968>
- Momeni Pour, A., Seyedarabi, H., Abbasi Jahromi, S. H., & Javadzadeh, A. (2020). Automatic detection and monitoring of diabetic retinopathy using efficient convolutional neural networks and contrast limited adaptive histogram equalization. *IEEE Access*, 8, 1–6. <https://doi.org/10.1109/ACCESS.2020.3005044>
- Morano, J., Hervella, Á. S., Novo, J., & Rouco, J. (2021). Simultaneous segmentation and classification of the retinal arteries and veins from color fundus images. *Artificial Intelligence in Medicine*, 118, 1–17. <https://doi.org/10.1016/j.artmed.2021.102116>
- Nethaji, V., & Shanmugasundaram, A. P. (2020). The analysis and manipulation of a digitized image processing. *ACCENTS Transactions on Image Processing and Computer Vision*, 6(18), 17–22. <https://doi.org/10.19101/TIPCV.2020.618015>
- Oktay, O., Schlemper, J., Folgoc, L. Le, Lee, M., Heinrich, M., Misawa, K., Mori, K., Mcdonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B., & Rueckert, D. (2018). Attention u-net: Learning where to look for the pancreas. *Medical Imaging with Deep Learning*, 3, 1–10. <https://doi.org/10.48550/arXiv.1804.03999>
- Oliveira, A., Pereira, S., & Silva, C. A. (2018). Retinal vessel segmentation based on fully convolutional neural networks. *Expert Systems with Applications*, 112, 229–242. <https://doi.org/10.1016/j.eswa.2018.06.034>
- Ozdemir, C. (2023). Avg-topk : A new pooling method for convolutional neural networks. *Expert Systems With Applications*, 223(12), 1–14. <https://doi.org/10.1016/j.eswa.2023.119892>
- Pratiwi, H., Windarto, A. P., Susliansyah, S., Aria, R. R., Susilowati, S., Rahayu, L. K., Fitriani, Y., Merdekawati, A., & Rahadjeng, I. R. (2020). Sigmoid activation function in selecting the best model of artificial neural networks. *Journal of Physics: Conference Series*, 1471(1), 1–7. <https://doi.org/10.1088/1742-6596/1471/1/012010>
- Qian, L., Hu, L., Zhao, L., Wang, T., & Jiang, R. (2020). Sequence-dropout block for reducing overfitting problem in image classification. *IEEE Access*, 8, 1–12. <https://doi.org/10.1109/ACCESS.2020.2983774>
- Qin, Q., & Chen, Y. (2024). A review of retinal vessel segmentation for fundus

- image analysis. *Engineering Applications of Artificial Intelligence*, 128, 1–17. <https://doi.org/10.1016/j.engappai.2023.107454>
- Ren, K., Chang, L., Wan, M., Gu, G., & Chen, Q. (2022). An improved u-net based retinal vessel image segmentation method. *Heliyon*, 8(10), e11187. <https://doi.org/10.1016/j.heliyon.2022.e11187>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
- Sharma, S., Sharma, S., & Anidhya, A. (2020). Understanding activation functions in neural networks. *International Journal of Engineering Applied Sciences and Technology*, 4(12), 310–316. <https://doi.org/10.33564/IJEAST.2020.v04i12.054>
- Sidhu, R. K., Sachdeva, J., & Katoch, D. (2023). Segmentation of retinal blood vessels by a novel hybrid technique- principal component analysis (PCA) and contrast limited adaptive histogram equalization (CLAHE). *Microvascular Research*, 148(12), 1–19. <https://doi.org/10.1016/j.mvr.2023.104477>
- Sudha, V., & Ganeshbabu, T. R. (2021). A convolutional neural network classifier VGG-19 architecture for lesion detection and grading in diabetic retinopathy based on deep learning. *Computers, Materials and Continua*, 66(1), 827–842. <https://doi.org/10.32604/cmc.2020.012008>
- Teymoori, R., Nabizadeh, Z., Karimi, N., & Samavi, S. (2020). An abstraction of semantic segmentation algorithms. *Iranian Conference on Machine Vision and Image Processing, MVIP*, 1–6. <https://doi.org/10.1109/MVIP49855.2020.9116916>
- Tian, Y. (2020). Artificial intelligence image recognition method based on convolutional neural network algorithm. *IEEE Access*, 8, 125731–125744. <https://doi.org/10.1109/ACCESS.2020.3006097>
- Tyagi, V. (2018). Understanding digital image processing. *Understanding Digital Image Processing*, 1–12. <https://doi.org/10.1201/9781315123905>
- Wang, C., Gan, M., Zhang, M., & Li, D. (2020). Adversarial convolutional network for esophageal tissue segmentation on OCT images. *Biomedical Optics Express*, 11(6), 3095–3110. <https://doi.org/10.1364/BOE.394715>
- Wang, C., Sun, J., Xu, W., & Chen, X. (2019). Depth learning standard deviation loss function depth learning standard deviation loss function. *Journal of Physics: Conference Series*, 1176(3), 1–7. <https://doi.org/10.1088/1742-6596/1176/3/032050>
- Wang, C., Zhao, Z., & Yu, Y. (2021). Fine retinal vessel segmentation by combining nest u-net and patch-learning. *Soft Computing*, 25(7), 5519–5532. <https://doi.org/10.1007/s00500-020-05552-w>

- Wang, S., Hou, X., & Zhao, X. (2020). Automatic building extraction from high-resolution aerial imagery via fully convolutional encoder-decoder network with non-local block. *IEEE Access*, 8, 7313–7322. <https://doi.org/10.1109/ACCESS.2020.2964043>
- Wang, Z., Lin, J., Wang, R., & Zheng, W. (2019). Retinal artery/vein classification via rotation augmentation and deeply supervised u-net segmentation. *ACM International Conference Proceeding Series*, 71–76. <https://doi.org/10.1145/3354031.3354050>
- Xu, X., Tan, T., & Xu, F. (2018). An improved u-net architecture for simultaneous arteriole and venule segmentation in fundus image. In *Communications in Computer and Information Science* (Vol. 894). Springer International Publishing. https://doi.org/10.1007/978-3-319-95921-4_31
- Yang, H., Wu, P., Yao, X., Wu, Y., & Wang, B. (2018). Building extraction in very high resolution imagery by dense-attention networks. *Remote Sensing*, 10(11), 1–16. <https://doi.org/10.3390/rs10111768>
- Yeung, M., Sala, E., Schonlieb, C.-B., & Rundo, L. (2022). Unified focal loss : generalising dice and cross entropy-based losses to handle class imbalanced medical image segmentation. *Computerized Medical Imaging and Graphics*, 95(11 2021), 1–13. <https://doi.org/10.1016/j.compmedimag.2021.102026>
- Yin, X. X., Irshad, S., & Zhang, Y. (2019). Artery / vein classification of retinal vessels using classifiers fusion. *Health Information Science and Systems*, 7(1), 1–14. <https://doi.org/10.1007/s13755-019-0090-4>
- Ying, W., Li, J., Wu, Y., Zheng, K., Deng, Y., & Li, J. (2020). U-Net with dense encoder, residual decoder and depth-wise skip connections. *Proceedings of the International Joint Conference on Neural Networks*, 1–5. <https://doi.org/10.1109/IJCNN48605.2020.9207371>
- Zhang, M., Li, X., Xu, M., & Li, Q. (2020). Automated semantic segmentation of red blood cells for sickle cell disease. *IEEE Journal of Biomedical and Health Informatics*, 24(11), 3095–3102. <https://doi.org/10.1109/JBHI.2020.3000484>
- Zhao, T., Guan, Y., Tu, D., Yuan, L., & Lu, G. (2023). Neighbored-attention u-net (NAU-net) for diabetic retinopathy image segmentation. *Frontiers in Medicine*, 10, 1–12. <https://doi.org/10.3389/fmed.2023.1309795>
- Zhu, Q., He, Z., Zhang, T., & Cui, W. (2020). Improving classification performance of softmax loss function based on scalable batch-normalization. *Applied Sciences (Switzerland)*, 10(8), 1–8. <https://doi.org/10.3390/APP10082950>