

BLOOD VESSEL SEGMENTATION IN RETINAL IMAGES USING RESVNET ARCHITECTURE

Syafira Dian Ramadhani^{*1}, Erwin², Anita Desiani³, Sinta Bella Agustina⁴

¹Master of Computer Science, Departement of Computer Science, Universitas Sriwijaya, Indonesia

²Departement of Computer Science, Universitas Sriwijaya, Indonesia

³Departement of Mathematics, Universitas Sriwijaya, Indonesia

⁴Master of Computer Science, Departement of Computer Science, Universitas Sriwijaya, Indonesia

Email: ¹syafiradian@gmail.com, ²erwin@unsri.ac.id, ³anita_desiani@unsri.ac.id, ⁴sintaba9@gmail.com

(Article received: August 09, 2024; Revision: August 19, 2024; published: August 31, 2024)

Abstract

The U-Net architecture is often used in medical blood vessel segmentation due to its ability to produce good segmentation. However, U-Net has high complexity due to the presence of the bridge part, which increases the parameters and training time. To overcome this, this research modifies U-Net by removing the bridge part, resulting in V-Net architecture. V-Net architecture faces challenges in capturing deep and complex features. This research proposes modifying V-Net with ResNet architecture in the encoder part, resulting in ResVNet architecture. ResNet, with residual connections, enables the training of very deep networks with more stability and effectiveness in capturing complex features. At the encoder, ResNet is used for more effective training of deep networks and capturing complex features. While at the decoder, U-Net is used to preserve the high resolution and spatial information of the image in segmentation. This study aims to determine the performance evaluation results of the ResVNet architecture. The evaluation measures used are accuracy, sensitivity, precision and Jaccard score. Tests were conducted on the DRIVE and STARE datasets. The measurement results of blood vessel segmentation using ResVNet on the DRIVE dataset resulted in accuracy 96.57%, sensitivity 82.28%, precision 79.57%, and Jaccard score 67.61%. On the STARE dataset, the accuracy results are 96.71%, sensitivity 79.44%, precision 79.44%, and Jaccard score 65.05%. The sensitivity results on the STARE dataset as well as the precision and Jaccard score values on the two datasets produced are still low, in the future this research will make improvements to the ResVNet architecture used.

Keywords: *blood vessel, CLAHE, gaussian blur, grayscale, ResVNet, segmentation.*

SEGMENTASI PEMBULUH DARAH PADA CITRA RETINA MENGGUNAKAN ARSITEKTUR RESVNET

Abstrak

Arsitektur U-Net sering digunakan dalam segmentasi pembuluh darah medis karena kemampuannya menghasilkan segmentasi yang baik. Namun, U-Net memiliki kompleksitas tinggi karena adanya bagian bridge, yang meningkatkan parameter dan waktu pelatihan. Untuk mengatasi hal ini, penelitian ini memodifikasi U-Net dengan menghilangkan bagian bridge, menghasilkan arsitektur V-Net. arsitektur V-Net menghadapi tantangan dalam menangkap fitur mendalam dan kompleks. Penelitian ini mengusulkan modifikasi V-Net dengan arsitektur ResNet pada bagian encoder, menghasilkan arsitektur ResVNet. ResNet, dengan residual connections, memungkinkan pelatihan jaringan yang sangat dalam dengan lebih stabil dan efektif dalam menangkap fitur kompleks. Pada bagian encoder, ResNet digunakan untuk pelatihan jaringan dalam yang lebih efektif dan menangkap fitur kompleks. Sedangkan pada decoder, U-Net digunakan untuk mempertahankan resolusi tinggi dan informasi spasial citra dalam segmentasi. Penelitian ini bertujuan untuk mengetahui hasil evaluasi kinerja dari arsitektur ResVNet. Ukuran evaluasi yang digunakan adalah accuracy, sensitivity, precision dan Jaccard score. Pengujian dilakukan pada dataset DRIVE dan STARE. Hasil pengukuran dari segmentasi pembuluh darah menggunakan ResVNet pada dataset DRIVE menghasilkan accuracy 96,57%, sensitivity 82,28%, precision 79,57%, dan Jaccard score 67,61%. Pada dataset STARE, mendapatkan hasil accuracy 96,71%, sensitivity 79,44%, precision 79,44%, dan Jaccard score 65,05%. Hasil sensitivity pada dataset STARE serta nilai precision dan jaccard score pada kedua dataset yang dihasilkan masih rendah, kedepannya penelitian ini akan melakukan perbaikan pada arsitektur ResVNet yang digunakan.

Kata kunci: CLAHE, grayscale, gaussian blur, pembuluh darah, ResVNet, segmentasi.

1. PENDAHULUAN

Jurnal Retina rentan terhadap berbagai penyakit yang dapat berakibat fatal jika tidak segera ditangani[1]. Penggunaan citra saat ini sangat membantu para dokter untuk mendeteksi penyakit retina lebih cepat sehingga penyakit retina bisa segera diobati. Citra fundus merupakan salah satu komponen yang digunakan untuk mendiagnosis suatu penyakit seperti retinopati diabetik (DR), glaukoma, hipertensi, dan penyakit lain yang berhubungan dengan mata[2]. Di dalam fundus terdapat pembuluh darah yang dapat mendiagnosis penyakit[3]. Perubahan karakteristik pembuluh darah retina merupakan indikator penting apakah seseorang menderita DR, glaukoma, hipertensi, atau lainnya[4]. Pemrosesan citra ialah suatu cara untuk menyelesaikan masalah citra, citra diolah menggunakan suatu metode untuk mendapatkan hasil yang diinginkan[5]. Untuk mengatasi masalah tersebut, dilakukanlah proses segmentasi otomatis untuk membantu sistem *computer- aided diagnostic* (CAD) dalam melakukan diagnosis otomatis.

Arsitektur U-Net merupakan salah satu arsitektur yang paling sering digunakan serta merupakan arsitektur yang baik dalam menghasilkan segmentasi pembuluh darah dalam bidang medis[6],[7],[8]. Arsitektur U-Net terdiri dari tiga bagian yaitu encoder, bridge, dan decoder[6],[9]. Segmentasi pembuluh darah telah banyak dilakukan penelitian diantaranya Eman dkk[10] menggunakan arsitektur U-Net, adapun hasil accuracy yang didapatkan sebesar 95,55% sedangkan nilai sensitivity masih rendah yaitu 66,1%. Penelitian Olunbunmi dkk[8] menggunakan arsitektur U-Net dengan menambahkan setiap lapisan konvolusi encoding untuk mengeksplorasi informasi, adapun hasil sensitivity yang didapat masih rendah 70,92% pada dataset DRIVE.

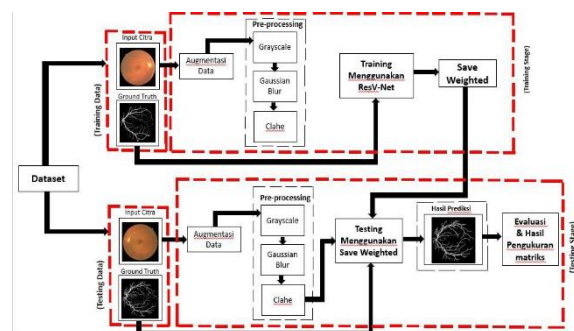
Meskipun U-Net sangat efektif dalam segmentasi gambar, arsitektur ini memiliki banyak parameter yang membuatnya lebih rentan terhadap overfitting, terutama ketika digunakan pada dataset yang lebih kecil[11]. Bagian bridge pada arsitektur U-net menambah kompleksitas dan jumlah parameter jaringan, sehingga meningkatkan kebutuhan komputasi dan memori serta waktu pelatihan yang lebih lama[12]. Terdapat penelitian yang melakukan modifikasi terhadap U-Net untuk mengurangi kompleksitas yang ada pada U-Net, salah satunya ialah menghilangkan bagian bridge pada U-Net. Penghilangan bridge pada bagian U-Net dikenal dengan arsitektur V-Net. Alan Reyes-Figueroa dan Mariano Rivera[13] menerapkan arsitektur V-Net pada pengolahan segmentasi citra retina pada dataset DRIVE. Penelitian ini menghasilkan akurasi yang sangat baik di atas 95%, namun tidak mengukur kinerja lainnya. Meskipun penghilangan bridge dapat

membuat U-Net lebih ringan, namun kehilangan bridge memiliki resiko terjadinya kehilangan kemampuan mengolah informasi fitur mendalam dan kompleks, mengurangi kemampuan generalisasi, dan kesulitan menangkap fitur abstrak, yang berdampak negatif pada akurasi segmentasi[14]. Untuk mengatasi masalah tersebut, Diperlukan suatu pendekatan modifikasi dari V-Net agar arsitektur V-Net mampu mempelajari fitur lebih detail dan akurat meskipun bagian bridgenya dihilangkan .

Pada penelitian ini, diusulkan arsitektur modifikasi V-Net dengan menggunakan arsitektur ResNet pada bagian encoder. Arsitektur ResNet adalah arsitektur dibuat untuk mengatasi masalah vanishing gradient yang kerap muncul saat melatih jaringan neural yang sangat dalam[15],[16],[17]. ResNet menggunakan residual connections yang memungkinkan sinyal (baik input maupun gradien) untuk melewati satu atau lebih lapisan di jaringan neural [15]. ResNet, atau Residual Network, memiliki kelebihan seperti pelatihan jaringan yang jauh lebih dalam dan stabil[18] . Dengan pendekatan residual, ResNet mampu melatih jaringan yang sangat dalam, sehingga dapat menangkap fitur yang lebih kompleks dan abstrak, mengatasi keterbatasan V-Net dalam mengambil fitur yang lebih mendalam dan kompleks dari citra[19]. Penerapan arsitektur ResNet dan arsitektur V-Net disebut dengan ResVNet. Pada bagian encoder, ResNet digunakan untuk mengatasi masalah pelatihan jaringan yang sangat dalam dengan lebih efektif dan untuk menangkap fitur yang lebih kompleks dan abstrak. Sementara itu, pada bagian decoder, U-Net digunakan untuk memastikan bahwa resolusi citra yang dihasilkan tetap tinggi dan informasi spasial dari citra dipertahankan dengan baik dalam proses segmentasi citra.

Untuk mengevaluasi kinerja arsitektur ResVNet dalam penelitian ini, arsitektur ResVNet akan diuji pada dua dataset yaitu DRIVE dan STARE. Kinerja keberhasilan arsitektur ResVNet dalam segmentasi pembuluh darah pada citra retina akan diukur menggunakan metrik seperti accuracy, sensitivity, precision, dan Jaccard score.

2. METODE PENELITIAN



Gambar 1. Flowchart Tahapan Pengolahan Citra Pada Segmentasi Pembuluh Darah

Tahapan penelitian yang ditampilkan dalam Gambar 1 yang terdiri dari lima langkah utama: input citra, augmentasi dataset, *preprocessing*, segmentasi pembuluh darah menggunakan arsitektur ResVNet, serta evaluasi dan pengukuran parameter hasil.

2.1. Input citra

Input citra dataset yang digunakan adalah dataset *Digital Retinal Image for Vessel Extraction* (DRIVE) dan dataset *Structured Analysis of the Retina* (STARE). Kedua dataset yang digunakan merupakan sumber data yang seringkali digunakan dalam penelitian dan dapat diunduh dengan gratis.

Dari Dataset DRIVE diperoleh dari program screening retinopati diabetik di Belanda yang terdiri dari 400 subyek diabetes antara 25-90 tahun[20]. Dari 40 citra yang digunakan, 20 citra digunakan untuk test dan 20 citra digunakan untuk train. Kemudian citra dataset DRIVE diatur ukuran dimensinya dari 565x584 pixel menjadi 512x512 pixel. Selanjutnya, dataset tersebut diubah formatnya dari .tif (Tagged Image File) menjadi .jpg (Joint Photographig Group).

Dataset STARE (Structured Analysis of the Retina) disediakan oleh Shiley Eye Center di University of California, San Diego, dan oleh Veterans Administration Medical Center di San Diego[21]. Dataset STARE yang digunakan dalam proses segmentasi pembuluh darah ini terdiri dari 20 citra. Dari jumlah tersebut, 4 citra digunakan untuk pengujian (test) dan 16 citra digunakan untuk pelatihan (train). Ukuran dimensi citra dalam dataset STARE diubah dari 700x605 piksel menjadi 512x512 piksel. Selain itu, format citra dalam dataset juga diubah dari format .PPM (Portable Pixmap File) menjadi .jpg (Joint Photographic Group)..

2.2. Augmentasi dataset

Teknik augmentasi merupakan teknik yang dibuat meningkatkan jumlah data memodifikasi citra tanpa menghilangkan informasi penting dari citra tersebut, sehingga komputer mengenali data tersebut sebagai entitas yang berbeda. Dalam penelitian ini, teknik augmentasi yang digunakan meliputi flip horizontal, flip vertikal, dan grid distortion.

Penelitian ini menerapkan teknik flip horizontal dalam augmentasi dataset, di mana citra dihasilkan dengan menciptakan versi cermin horizontal dari citra asli. Selanjutnya, teknik augmentasi menggunakan flip vertikal melibatkan penciptaan versi terbalik vertikal dari citra asli. Terakhir augmentasi menggunakan grid distortion merupakan teknik augmentasi yang melibatkan distorsi atau deformasi dari grid yang digunakan untuk merepresentasikan gambar.

Proses augmentasi dataset ini akan diterapkan pada DRIVE dan STARE. Sehingga menghasilkan 80 citra *training* dan 20 citra *testing* pada dataset DRIVE, serta 64 citra *training* dan 16 citra *testing* pada dataset STARE.

2.3. Preprocessing

Tahap *preprocessing* merupakan tahap *enhancement* yang bertujuan untuk memperbaiki kualitas citra sehingga pada proses selanjutnya citra tersebut sudah lebih bagus dan memudahkan dalam prosesnya.

Tahap pertama *preprocessing* yang digunakan ialah metode grayscale. Metode grayscale merupakan metode mengubah citra menjadi skala keabu-abuan. Citra grayscale merupakan citra yang intensitasnya diwakili oleh nilai keabuan tiap-tiap piksel dan memiliki nilai dengan kisaran 0 sampai 255. Nilai 0 merupakan nilai terendah dengan warna hitam, sementara nilai 255 merupakan nilai tertinggi dengan warna putih[22]. Dalam melakukan konversi citra RGB ke citra grayscale, dapat menggunakan rumus yang akan ditampilkan pada persamaan (1)[23].

$$Y(i, j) = (0,299 * R) + (0,587 * G) + (0,114 * B) \quad (1)$$

$Y(i, j)$ adalah nilai skala piksel pada posisi (i, j) dalam citra grayscale yang dihasilkan. i dan j adalah koordinat skala dalam citra berwarna (atau citra RGB) yang sedang diproses. i adalah koordinat horizontal (kolom) dan j adalah koordinat vertikal (baris). R, G, B adalah saluran warna merah, hijau, dan biru pada citra asli. Selanjutnya dilakukan perbaikan citra menggunakan teknik *denoising* dengan metode *Gaussian Blur*.

Operasi Gaussian blur digunakan untuk meredam citra dengan menerapkan fungsi Gaussian, yang secara efektif mengurangi detail dan kebisingan yang tidak diinginkan. Untuk mengonversi citra grayscale ke gaussian blur dapat menggunakan rumus persamaan (2)[24].

$$Y(i, j) = \frac{1}{2\pi\sigma^2} e^{-\frac{i^2+j^2}{2\sigma^2}} \quad (2)$$

Dimana $Y(i, j)$ elemen matriks gaussian di posisi (i, j) , $n = 22/7$, $e = 2.71828182846$, σ ialah nilai standar deviasi (sigma) = 1.

Proses *preprocessing* terakhir adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE). CLAHE adalah metode peningkatan citra yang digunakan untuk memperbaiki kualitas dan menghilangkan noise, dengan menggunakan clip limit sebagai pengendali kontras untuk meningkatkan kualitas citra. Clip limit digunakan untuk menetapkan batas maksimum histogram, dengan piksel yang terpotong kemudian didistribusikan kembali secara merata dalam area lokal pada histogram[25]. Jumlah piksel pada setiap tingkat keabuan dibagi secara merata, seperti ditunjukkan dalam persamaan (3)[26].

$$Y_{avg} = \frac{Y_{CR-IP} * Y_{CR-JP}}{Y_{gray}} \quad (3)$$

Dimana Y_{avg} adalah jumlah rata-rata *pixel*, Y_{gray} adalah jumlah tingkat keabuan dalam *tile*, Y_{CR-IP} adalah jumlah *pixel* pada sumbu i *tile*, dan Y_{CR-JP}


adalah jumlah *pixel* pada sumbu j *tile*. Untuk menghitung *clip limit* dapat menggunakan persamaan (4)[26].

$$Y_{CL} = Y_{CLIP} - Y_{avg} \quad (4)$$

Dimana, Y_{CL} adalah *clip limit* dan Y_{CLIP} adalah nilai acak *input clip limit* dengan rentang dari 0 sampai 1.

2.4. Segmentasi pembuluh darah retina menggunakan arsitektur ResVNet

Arsitektur ResVNet adalah modifikasi dari arsitektur ResNet dan U-Net. Biasanya, arsitektur U-



Gambar 2. Arsitektur ResVNet

Pada Gambar 2, proses training arsitektur ResVNet menggunakan ResNet pada bagian encoder. Awalnya, layer encoder pertama memiliki satu saluran input, yang kemudian meningkat menjadi 64 melalui konvolusi pertama, diikuti oleh batch normalization (BN) dan fungsi aktivasi ReLU. Konvolusi kedua mempertahankan jumlah saluran 64 dengan batch normalization. Shortcut connection digunakan untuk mengatasi vanishing gradient dan mempercepat konvergensi, diikuti oleh penambahan hasil konvolusi kedua dan penerapan fungsi ReLU lagi. Proses ini diakhiri dengan max pooling, yang mengurangi ukuran citra menjadi separuh.

Pada layer kedua encoder, setelah max pooling, jumlah saluran input adalah 64 dan meningkat menjadi 128 setelah konvolusi pertama. Konvolusi ini diikuti oleh batch normalization dan fungsi aktivasi ReLU. Konvolusi kedua mempertahankan jumlah saluran 128 dengan batch normalization, dan shortcut connection digunakan untuk mengatasi vanishing gradient serta mempercepat konvergensi. Hasilnya ditambahkan ke konvolusi kedua, diikuti dengan aktivasi ReLU lagi, dan diakhiri dengan max pooling yang mengurangi ukuran citra menjadi separuh.

Pada layer ketiga encoder, setelah penggabungan maksimal, jumlah saluran input adalah 128. Dalam konvolusi pertama (panah ungu), saluran meningkat menjadi 256, diikuti oleh batch normalization (BN) dan aktivasi ReLU. Konvolusi kedua (panah oranye) mempertahankan 256 saluran dengan BN. Shortcut connection (panah hitam) mengatasi vanishing gradient dan mempercepat konvergensi, hasilnya ditambahkan ke konvolusi kedua sebelum aktivasi ReLU (panah putih). Output

Net terdiri dari tiga bagian: encoder, bridge, dan decoder. Modifikasi pertama dilakukan dengan menghilangkan bagian bridge pada arsitektur U-Net, sehingga hanya tersisa bagian encoder dan decoder, yang menghasilkan arsitektur yang disebut V-Net. Arsitektur V-Net kemudian dimodifikasi dengan mengganti bagian encodernya menggunakan arsitektur ResNet, sehingga arsitektur tersebut dinamakan dengan arsitektur ResVNet. Adapun arsitektur ResVNet yang digunakan akan ditampilkan pada gambar 2.

dari layer ini menjadi input untuk layer pertama decoder (panah abu-abu).

Pada training decoder dengan arsitektur U-Net, setiap proses melibatkan 2 lapisan konvolusional, batch normalization, dan 1 dropout. Pada layer pertama decoder, input dari layer ketiga encoder diproses dengan 256 saluran dan fungsi aktivasi ReLU. Dropout 20% (panah merah muda) digunakan untuk mengurangi overfitting. Teknik upsampling (panah hijau) memperbesar citra ke ukuran aslinya.

Pada layer kedua decoder, setelah upsampling, citra digabungkan dengan layer kedua encoder untuk meningkatkan akurasi prediksi. Saluran berubah dari 256 menjadi 128 dengan fungsi aktivasi ReLU. Dropout 20% (panah merah muda) digunakan untuk mengurangi overfitting. Teknik upsampling (panah hijau) memperbesar citra ke ukuran aslinya.

Pada layer ketiga decoder, setelah upsampling, citra digabungkan dengan layer pertama encoder. Saluran berubah dari 128 menjadi 64 dengan fungsi aktivasi ReLU dan dropout 20% (panah merah muda) untuk mengurangi overfitting. Saluran 64 kemudian diubah menjadi 2 untuk output segmentasi dengan fungsi aktivasi sigmoid (panah kuning)..

2.5. Evaluasi & hasil pengukuran parameter


Setelah dilakukan tahapan segmentasi pembuluh darah pada citra retina dengan menggunakan arsitektur ResVNet. Langkah selanjutnya ialah evaluasi hasil kinerja dari segmentasi pembuluh darah menggunakan arsitektur ResVNet. Evaluasi dilakukan dengan menggunakan confusion matriks yang terdiri dari True Positif (TP), False Positif (FP), False Negatif (FN) dan True

Negatif (TN). Empat bagian confusion matriks tadi digunakan untuk menghitung accuracy, sensitivity, precision, dan Jaccard score.

3. HASIL DAN PEMBAHASAN

3.1. Augmentasi dataset


Sebelum memasuki tahap preprocessing dengan menggunakan metode Grayscale, Gaussian Blur, dan CLAHE, dataset harus melalui tahap augmentasi data terlebih dahulu. Penelitian ini menggunakan dua dataset yaitu DRIVE dan STARE. Dataset DRIVE terdiri dari 40 citra dengan 20 citra untuk pelatihan dan 20 citra untuk pengujian. Dataset STARE memiliki 20 citra, terdiri dari 16 citra pelatihan dan 4 citra pengujian. Setelah melakukan augmentasi menggunakan flip horizontal, flip vertikal, dan grid distortion, jumlah citra berubah sebagai berikut: DRIVE menjadi 80 citra training dan 20 citra testing, STARE menjadi 64 citra training dan 16 citra pengujian. Sehingga jika dipersentasekan jumlah dataset yang digunakan ialah 80% training dan 20% testing. Contoh citra hasil augmentasi dapat dilihat pada gambar 3.



Gambar 3. Augmentasi dataset, (a) citra asli, (b) flip horizontal, (c) flip vertical, dan (d) grid distorsi

3.2. Preprocessing

Setelah augmentasi, dataset melalui beberapa tahap preprocessing. Pertama, citra diubah ke dalam format grayscale, yang mengubah citra retina menjadi skala abu-abu, sebagaimana ditunjukkan pada Gambar 4(b). Berikutnya, diterapkan gaussian blur, sebuah teknik yang digunakan untuk menghilangkan noise dan detail kecil yang terdapat dalam citra tersebut dengan cara menghaluskan perubahan intensitas diseluruh citra hasilnya ditampilkan pada Gambar 4(c). Tahap preprocessing terakhir adalah CLAHE, yang digunakan untuk meningkatkan kualitas citra dengan kontras rendah dan mengurangi noise, seperti terlihat pada Gambar 4(d).



Gambar 4. Preprocessing, (a) citra asli, (b) grayscale, (c) gaussian blur, dan (d) CLAHE

3.3. Segmentasi citra retina pada pembuluh darah menggunakan arsitektur ResVNet

Setelah dilakukan tahap preprocessing, citra retina tersebut kemudian dilakukan segmentasi

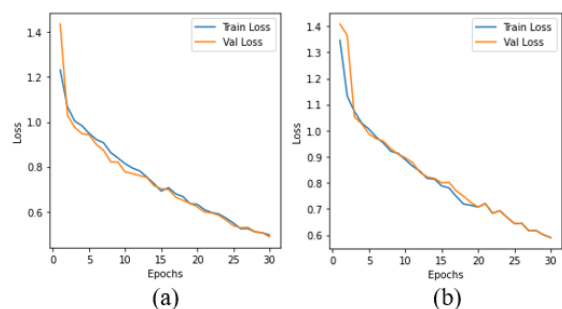
pembuluh darah dengan menggunakan arsitektur ResVNet. Adapun Hyperparameter yang digunakan pada proses training dengan arsitektur ResVNet meliputi batch size sebesar 2, learning rate sebesar 0.0001 (1e-4), epoch sebanyak 30, dan loss function DiceBCELoss. Setelah melalui proses training, hasil pengujian citra untuk segmentasi pembuluh darah pada dataset DRIVE dan STARE diperoleh. Contoh hasil pengujian segmentasi pembuluh darah menggunakan arsitektur ResVNet akan ditampilkan pada tabel 1.

Tabel 1. Hasil pengujian segmentasi pembuluh darah menggunakan arsitektur ResVNet

Dataset	Citra asli	Segmentasi ResVNet
DRIVE		
STARE		

3.4. Evaluasi dan hasil pengukuran kinerja matriks


Pada tahap pelatihan, bobot dihasilkan untuk pengujian dengan menggunakan 30 epoch dan batch size 2 pada arsitektur ResVNet. Nilai bobot diinisialisasi setiap epoch, dan nilai loss dihitung untuk menentukan apakah bobot harus disimpan atau diperbarui berdasarkan error data validasi. Grafik training loss dan validation loss ditampilkan pada Gambar 5.



Gambar 5. Grafik training loss dan validation loss, (a) DRIVE dan (b) STARE

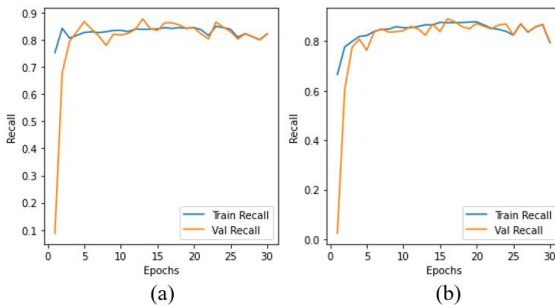
Pada Gambar 5(a), grafik menunjukkan bahwa training loss dan validation loss pada arsitektur ResVNet untuk dataset DRIVE menurun hingga mendekati 0,4 tanpa menunjukkan overfitting atau underfitting, menandakan kemampuan model yang baik dalam mengenali data baru. Gambar 5(b) menunjukkan bahwa pada dataset STARE, training loss dan validation loss juga menurun hingga mendekati 0,6, dengan hasil yang menunjukkan tidak adanya overfitting atau underfitting. Grafik training accuracy dan validation accuracy, yang

menggambarkan performa model, akan ditampilkan pada gambar 6.



Gambar 6. Grafik training accuracy dan validation accuracy, (a) DRIVE dan (b) STARE

Grafik training accuracy dan validation accuracy untuk dataset DRIVE dan STARE, yang ditampilkan pada gambar 6, menunjukkan peningkatan accuracy hingga mencapai epoch ke-30 tanpa adanya overfitting atau underfitting. Untuk dataset DRIVE yang ditampilkan pada gambar 6(a), accuracy di atas 96% pada data pelatihan dan validasi menunjukkan kinerja arsitektur ResVNet yang sangat baik dalam segmentasi pembuluh darah retina. Hasil serupa juga terlihat pada dataset STARE yang ditampilkan pada gambar 6(b), dengan accuracy di atas 96% dan tanpa indikasi overfitting atau underfitting. Grafik training recall dan validation recall, yang menggambarkan nilai recall selama pelatihan dan evaluasi, dapat dilihat pada Gambar 7.



Gambar 7. Grafik training recall dan validation recall, (a) DRIVE dan (b) STARE

Pada gambar 7(a), grafik training recall dan validation recall untuk dataset DRIVE menunjukkan tidak adanya overfitting atau underfitting, dengan ResVNet yang efektif dalam belajar dari data pelatihan dan menggeneralisasi pada data validasi. Peningkatan recall mengindikasikan kemampuan arsitektur ResVNet dalam mengidentifikasi pembuluh darah retina. Hasil serupa terlihat pada gambar 7(b) untuk dataset STARE, di mana tidak ada overfitting atau underfitting, dan peningkatan recall menunjukkan efektivitas ResVNet dalam identifikasi pembuluh darah retina.

Setelah mendapat hasil training, didapatkan juga hasil evaluasi pengujian matrik dari proses segmentasi pembuluh darah pada citra retina menggunakan arsitektur ResVNet. Adapun hasil

pengukuran kinerja matriks yang didapatkan akan ditampilkan pada tabel 2.

Tabel 2. Hasil pengukuran kinerja matriks dari arsitektur ResVNet

Dataset	Accuracy (%)	Sensitivity (%)	Precision (%)	Jaccard Score (%)
DRIVE	96,57	82,28	79,57	67,61
STARE	96,71	79,44	79,44	65,05

Pada tabel 2, arsitektur ResVNet menunjukkan performa yang baik dalam segmentasi pembuluh darah untuk dataset DRIVE dan STARE. Untuk dataset DRIVE, arsitektur ResVNet mencapai akurasi 96,57%, masuk dalam kategori sangat baik, serta sensitivitas 82,28% yang termasuk kategori baik. Precision sebesar 79,57% berada dalam kategori cukup, dan Jaccard score 67,61% dikategorikan kurang baik. Ini menunjukkan kemampuan yang baik dalam segmentasi namun masih ada kekurangan dalam mendeteksi kesesuaian antara ground truth dan prediksi. Untuk dataset STARE, akurasi mencapai 96,71% dan sensitivitas 79,44%, keduanya termasuk kategori sangat baik dan cukup, masing-masing. Precision juga 79,44%, dalam kategori cukup, sementara Jaccard score 65,05% termasuk kategori kurang baik. Secara keseluruhan, arsitektur ResVNet menunjukkan performa yang sangat baik dalam akurasi segmentasi, dengan beberapa kekurangan pada Jaccard score.

4. DISKUSI

Dalam penelitian ini, arsitektur ResVNet digunakan untuk melakukan segmentasi pembuluh darah pada citra retina. Confusion matrix digunakan untuk menghitung kinerja arsitektur berdasarkan accuracy, sensitivity, precision, dan Jaccard score. Perbandingan hasil segmentasi pembuluh darah pada citra retina dengan menggunakan arsitektur ResVNet dengan arsitektur dari penelitian lain pada dataset DRIVE akan ditampilkan dalam tabel 3.

Tabel 3. Perbandingan hasil evaluasi arsitektur ResVNet pada dataset DRIVE dengan arsitektur penelitian lain

Arsitektur	Accuracy (%)	Sensitivity (%)	Precision (%)	Jaccard Score (%)
LEA U-Net[27]	95,46	-	-	-
Bridge-Net[28]	95,65	78,53	-	-
CRAUNet[29]	95,86	79,54	-	-
WA-Net[30]	95,75	79,66	-	-
U-Net[10]	95,55	66,1	-	-
EEA U-Net[8]	95,77	79,18	-	-
U-Net[31]	94,77	70,92	-	-
U-Net[8]	95,47	-	-	-
AA-U-Net[32]	95,58	-	-	-
U-Net[33]	95,46	74,20	-	-
LadderNet[33]	95,47	75,19	-	-
IterNet[34]	95,74	77,91	-	-
Di-U-Net[35]	95,54	81,60	-	-
ResWnet[36]	95,54	81,60	-	-
Proposal	96,57	82,28	79,57	67,61

Pada tabel 3 menunjukkan bahwa arsitektur ResVNet dalam penelitian ini mencapai akurasi tertinggi dan sangat baik untuk segmentasi pembuluh darah pada dataset DRIVE, mengungguli penelitian lain. Selain itu, ResVNet juga menunjukkan performa sensitivitas yang lebih baik dibandingkan penelitian lainnya. Penelitian ini juga menghitung precision dan Jaccard score, yang tidak diperhitungkan dalam penelitian lain. Precision menunjukkan kemampuan yang cukup baik dalam identifikasi piksel positif, sementara Jaccard score masih kurang baik dalam mendeteksi kesesuaian antara ground truth dan prediksi. Perbandingan hasil performa arsitektur ResVNet dengan arsitektur penelitian lain pada dataset STARE akan ditampilkan di Tabel 4.

Tabel 4. Perbandingan hasil evaluasi arsitektur ResVNet pada dataset STARE dengan arsitektur penelitian lain

Arsitektur	Accuracy (%)	Sensitivity (%)	Precision (%)	Jaccard Score (%)
WA-NET[30]	96,65	77,67	-	-
U-NET[10]	95,55	66,1	-	-
GDF-NET[37]	96,53	76,16	-	-
AA-U-NET[32]	96,40	-	-	-
Proposal	96,71	79,44	79,44	65,05

Pada tabel 4 menunjukkan bahwa arsitektur ResVNet mencapai akurasi tertinggi dan sangat baik untuk segmentasi pembuluh darah pada dataset STARE, serta menunjukkan sensitivitas yang lebih baik dibandingkan arsitektur penelitian lain. Selain itu, penelitian ini juga menghitung precision dan Jaccard score, dengan precision yang menunjukkan kinerja cukup baik dalam identifikasi piksel positif, sementara Jaccard score mengindikasikan kemampuan yang kurang baik dalam mendeteksi kesamaan antara ground truth dan prediksi.

5. KESIMPULAN

Berdasarkan hasil dan diskusi, dapat disimpulkan bahwa, Arsitektur ResVNet menunjukkan performa yang sangat baik dalam segmentasi pembuluh darah pada citra retina, dengan tingkat akurasi lebih dari 90% pada dataset DRIVE dan STARE. Sensitivitas yang dicapai pada dataset DRIVE melebihi 80%, sementara pada dataset STARE masih di bawah 80%. Precision yang diperoleh lebih dari 70%, namun Jaccard score masih di bawah 70%, mengindikasikan adanya ruang untuk perbaikan dalam mendeteksi wilayah pembuluh darah yang samar.

Grafik yang menunjukkan training loss, validation loss, accuracy, dan recall memperlihatkan bahwa arsitektur ResVNet tidak mengalami overfitting maupun underfitting. Peningkatan nilai akurasi dan recall sepanjang epoch menunjukkan kemampuan adaptasi yang baik terhadap data pelatihan dan validasi.

Dibandingkan dengan penelitian lain pada dataset DRIVE dan STARE, arsitektur ResVNet

konsisten unggul dalam hal akurasi, sensitivitas, precision, dan Jaccard score. Hal ini menunjukkan potensi besar arsitektur ini untuk diterapkan dalam aplikasi medis dan analisis citra, terutama dalam segmentasi pembuluh darah pada citra retina.

Hasil sensitivity pada dataset STARE serta nilai precision dan jaccard score pada kedua dataset yang dihasilkan masih rendah, kedepannya penelitian ini akan melakukan perbaikan pada arsitektur yang digunakan untuk meningkatkan hasil sensitivity, precision dan jaccard score. Penelitian ini juga belum sampai klasifikasi, kedepannya penelitian ini dapat dilanjutkan untuk berfokus pada klasifikasi penyakit retina.

DAFTAR PUSTAKA

- [1] J. Lin, X. Huang, H. Zhou, Y. Wang, and Q. Zhang, "Stimulus-guided adaptive transformer network for retinal blood vessel segmentation in fundus images," *Med. Image Anal.*, vol. 89, p. 102929, 2023, doi: <https://doi.org/10.1016/j.media.2023.102929>
- [2] S. P. Singh, P. Gupta, and R. Dung, "Diabetic retinopathy detection by fundus images using fine tuned deep learning model," *Multimed. Tools Appl.*, 2024, doi: 10.1007/s11042-024-19687-7.
- [3] J. Sanghavi and M. Kurhekar, "Ocular disease detection systems based on fundus images: a survey," *Multimed. Tools Appl.*, vol. 83, no. 7, pp. 21471–21496, 2024, doi: 10.1007/s11042-023-16366-x.
- [4] M. M. Butt, D. N. F. A. Iskandar, S. E. Abdelhamid, G. Latif, and R. Alghazo, "Diabetic Retinopathy Detection from Fundus Images of the Eye Using Hybrid Deep Learning Features," *Diagnostics*, vol. 12, no. 7, 2022, doi: 10.3390/diagnostics12071607.
- [5] A. Wijayanti and S. Suryono, "Pengenalan Retina Menggunakan Alihragam Gelombang Singkat dengan Pengukuran Jarak Euclidean Ternormalisasi," *J. Sist. Inf. Bisnis*, vol. 4, no. 2, pp. 116–120, 2014, doi: 10.21456/vol4iss2pp116-120.
- [6] V. Popat, "GA-based U-Net architecture optimization applied to retina blood vessel segmentation," *IJCCI 2020 - Proceedings of the 12th International Joint Conference on Computational Intelligence*. pp. 192–199, 2020. [Online]. Available: https://api.elsevier.com/content/abstract/scopus_id/85103844037
- [7] C. Chen, J. H. Chuah, R. Ali, and Y. Wang, "Retinal vessel segmentation using deep learning: A review," *IEEE Access*, vol. 9, pp. 111985–112004, 2021, doi: 10.1109/ACCESS.2021.3102176.

- [8] O. O. Sule, "A Survey of Deep Learning for Retinal Blood Vessel Segmentation Methods: Taxonomy, Trends, Challenges and Future Directions," *IEEE Access*, vol. 10, no. mild, pp. 38202–38236, 2022, doi: 10.1109/ACCESS.2022.3163247.
- [9] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation BT - Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015," 2015, pp. 234–241.
- [10] E. Abdelmaksoud, S. El-Sappagh, S. Barakat, T. Abuhmed, and M. Elmogy, "Automatic Diabetic Retinopathy Grading System Based on Detecting Multiple Retinal Lesions," *IEEE Access*, vol. 9, no. VI, pp. 15939–15960, 2021, doi: 10.1109/ACCESS.2021.3052870.
- [11] Ö. Çiçek, A. Abdulkadir, S. S. Lienkamp, T. Brox, and O. Ronneberger, "3D U-net: Learning dense volumetric segmentation from sparse annotation," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9901 LNCS, pp. 424–432, 2016, doi: 10.1007/978-3-319-46723-8_49.
- [12] W. Weng and X. Zhu, "INet: Convolutional Networks for Biomedical Image Segmentation," *IEEE Access*, vol. 9, pp. 16591–16603, 2021, doi: 10.1109/ACCESS.2021.3053408.
- [13] A. Reyes-Figueroa, V. H. Flores, and M. Rivera, "Deep neural network for fringe pattern filtering and normalization," *Appl. Opt.*, vol. 60, no. 7, p. 2022, 2021, doi: 10.1364/ao.413404.
- [14] L.-C. Chen, G. Papandreou, F. Schroff, and H. Adam, "Rethinking Atrous Convolution for Semantic Image Segmentation," 2017.
- [15] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Identity Mappings in Deep Residual Networks," *Lect. Notes Comput. Sci.*, vol. 9914 LNCS, p. V, 2016, doi: 10.1007/978-3-319-46493-0.
- [17] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, "Inception-v4, inception-ResNet and the impact of residual connections on learning," *31st AAAI Conf. Artif. Intell. AAAI 2017*, pp. 4278–4284, 2017, doi: 10.1609/aaai.v31i1.11231.
- [18] N. Komodakis, "Wide Residual Networks," 2016.
- [19] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual networks," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9908 LNCS, pp. 630–645, 2016, doi: 10.1007/978-3-319-46493-0_38.
- [20] S. Panchal *et al.*, "Retinal Fundus Multi-Disease Image Dataset (RFMiD) 2.0: A Dataset of Frequently and Rarely Identified Diseases," *Data*, vol. 8, no. 2, pp. 1–16, 2023, doi: 10.3390/data8020029.
- [21] A. Imran, J. Li, Y. Pei, J. J. Yang, and Q. Wang, "Comparative Analysis of Vessel Segmentation Techniques in Retinal Images," *IEEE Access*, vol. 7, pp. 114862–114887, 2019, doi: 10.1109/ACCESS.2019.2935912.
- [22] Susila, "Implementasi Edge Detection Pada Citra Grayscale Dengan Metode Operator," *Inf. Sci. Knowl.*, vol. 12, pp. 235–240, 2017.
- [23] Dahliyusmanto, D. W. Anggara, M. S. M. Rahim, and A. W. Ismail, "The Comparison Of Grayscale Image Enhancement Techniques For Improving The Quality Of Marker In Augmented Reality," *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 11, no. 5, pp. 2104–2111, 2021, doi: 10.18517/IJASEIT.11.5.10990.
- [24] T. Ohtani, Y. Kanai, and N. V. Kantartzis, "A 4-D subgrid scheme for the NS-FDTD technique using the CNS-FDTD algorithm with the shepard method and a gaussian smoothing filter," *IEEE Trans. Magn.*, vol. 51, no. 3, pp. 3–6, 2015, doi: 10.1109/TMAG.2014.2360841.
- [25] R. S. C. Boss, K. Thangavel, and D. A. P. Daniel, "Automatic Mammogram image Breast Region Extraction and Removal of Pectoral Muscle," vol. 4, no. 5, 2013, [Online]. Available: <http://arxiv.org/abs/1307.7474>
- [26] G. Yadav, S. Maheshwari, and A. Agarwal, "Contrast limited adaptive histogram equalization based enhancement for real time video system," *Proc. 2014 Int. Conf. Adv. Comput. Commun. Informatics, ICACCI 2014*, pp. 2392–2397, 2014, doi: 10.1109/ICACCI.2014.6968381.
- [27] J. Ouyang, S. Liu, H. Peng, H. Garg, and D. N. H. Thanh, "LEA U-Net: a U-Net-based deep learning framework with local feature enhancement and attention for retinal vessel segmentation," *Complex Intell. Syst.*, 2023, doi: 10.1007/s40747-023-01095-3.
- [28] Y. Zhang, "Bridge-Net: Context-involved U-net with patch-based loss weight mapping for retinal blood vessel segmentation," *Expert Syst. Appl.*, vol. 195, p. 116526, 2022, doi:

- 10.1016/j.eswa.2022.116526.
- [29] F. Dong, D. Wu, C. Guo, S. Zhang, B. Yang, and X. Gong, "CRAUNet: A cascaded residual attention U-Net for retinal vessel segmentation," *Comput. Biol. Med.*, vol. 147, no. February, p. 105651, 2022, doi: 10.1016/j.combiomed.2022.105651.
- [30] D. E. Alvarado-Carrillo and O. S. Dalmau-Cedeño, "Width Attention based Convolutional Neural Network for Retinal Vessel Segmentation," *Expert Syst. Appl.*, vol. 209, p. 118313, 2022, doi: 10.1016/j.eswa.2022.118313.
- [31] J. Zhang, Y. Zhang, Y. Jin, J. Xu, and X. Xu, "MDU-Net: multi-scale densely connected U-Net for biomedical image segmentation," *Heal. Inf. Sci. Syst.*, vol. 11, no. 1, pp. 1–10, 2023, doi: 10.1007/s13755-022-00204-9.
- [32] Y. Lv, H. Ma, J. Li, and S. Liu, "Attention Guided U-Net with Atrous Convolution for Accurate Retinal Vessels Segmentation," *IEEE Access*, vol. 8, pp. 32826–32839, 2020, doi: 10.1109/ACCESS.2020.2974027.
- [33] A. Desiani, Erwin, B. Suprihatin, and S. B. Agustina, "a Robust Techniques of Enhancement and Segmentation Blood Vessels in Retinal Image Using Deep Learning," *Biomed. Eng. - Appl. Basis Commun.*, vol. 34, no. 4, pp. 1–9, 2022, doi: 10.4015/S1016237222500193.
- [34] L. Li, M. Verma, Y. Nakashima, H. Nagahara, and R. Kawasaki, "IterNet: Retinal image segmentation utilizing structural redundancy in vessel networks," *Proc. - 2020 IEEE Winter Conf. Appl. Comput. Vision, WACV 2020*, pp. 3645–3654, 2020, doi: 10.1109/WACV45572.2020.9093621.
- [35] Q. Xu, Z. Ma, N. HE, and W. Duan, "DCSAU-Net: A deeper and more compact split-attention U-Net for medical image segmentation," *Comput. Biol. Med.*, vol. 154, no. September 2022, 2023, doi: 10.1016/j.combiomed.2023.106626.
- [36] Y. Tang, Z. Rui, C. Yan, J. Li, and J. Hu, "RESwNet for retinal small vessel segmentation," *IEEE Access*, vol. 8, pp. 198265–198274, 2020, doi: 10.1109/ACCESS.2020.3032453.
- [37] J. Li, G. Gao, L. Yang, and Y. Liu, "GDF-Net: A multi-task symmetrical network for retinal vessel segmentation," *Biomed. Signal Process. Control*, vol. 81, no. August 2022, p. 104426, 2023, doi: 10.1016/j.bspc.2022.104426.