

BLOOD VESSEL SEGMENTATION IN RETINAL IMAGES USING CONVOLUTIONAL NEURAL NETWORK VV-NET METHOD

Sinta Bella Agustina¹, Erwin^{*2}, Anita Desiani³, Tommy Saputra⁴

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

²Departement of Computer Engineering, Universitas Sriwijaya, Indonesia

³Departement of Mathematics, Universitas Sriwijaya, Indonesia

⁴USS Artificial Intelligence Research Group, Departement of Computer Science, Universitas Sumatera Selatan, Indonesia

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

(Article received: January 12, 2024; Revision: January 16, 2024; published: February 13, 2024)

Abstract

The retina is susceptible to various diseases that can be fatal if not treated quickly. Image processing is currently very helpful for doctors to detect retinal diseases faster so that retinal diseases can be treated immediately. The first step in image processing is to improve the quality of retinal images affected by noise, aiming to increase accuracy in the process of segmentation and image extraction. accurate segmentation of retinal blood vessels is the first step in disease detection. The process of segmentation and analysis of retinal blood vessels has an important role in assisting medical professionals in identifying the severity of a disease. Image quality improvement steps in preprocessing use grayscale, median filter (denoising), and clahe. The method used for blood vessel segmentation is CNN VV-Net. Evaluation of the results of applying image quality enhancement and segmentation techniques using the VV-Net method was performed on the DRIVE, STARE, and CHASEDB_1 datasets at both stages, training and testing. The measurement results of blood vessel segmentation using the CNN VV-Net method on the DRIVE dataset (accuracy 96.27%, sensitivity 84.38%, precision 75.95%, and jaccard score 66.28%), STARE dataset (accuracy 96.58%, sensitivity 82.78%, precision 76.73%, and jaccard score 65.38%), and CHASEDB_1 dataset (accuracy 97.04%, sensitivity 83.55%, precision 76.72%, and jaccard score 66.40%). From the three datasets used, the CHASEDB_1 dataset obtained better results than the DRIVE and STARE datasets.

Keywords: Clahe, Convolutional Neural Network, grayscale, median filter, segmentation blood vessels, VV-net.

SEGMENTASI PEMBULUH DARAH PADA CITRA RETINA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK VV-NET

Abstrak

Retina rentan terhadap berbagai penyakit yang dapat berakibat fatal apabila tanpa penanganan yang cepat. Penggunaan citra saat ini sangat membantu para dokter untuk mendeteksi penyakit retina lebih cepat sehingga penyakit retina bisa segera diobati. Langkah awal dalam pengolahan citra adalah meningkatkan kualitas citra retina yang terpengaruh oleh noise. Dalam segmentasi yang akurat pada pembuluh darah retina menjadi langkah awal dalam mendeteksi penyakit. Proses segmentasi dan analisis pembuluh darah retina memiliki peran penting dalam membantu profesional medis untuk mengidentifikasi tingkat keparahan suatu penyakit. Langkah-langkah meningkatkan kualitas citra pada preprocessing melibatkan grayscale, median filter (denoising), dan clahe. Metode yang digunakan untuk segmentasi pembuluh darah adalah CNN VV-Net. Evaluasi hasil dari penerapan teknik peningkatan kualitas citra dan segmentasi menggunakan metode VV-Net dilakukan pada dataset DRIVE, STARE, dan CHASEDB_1 dengan kedua tahapan yaitu pelatihan dan pengujian. Hasil pengukuran dari segmentasi pembuluh darah menggunakan metode CNN VV-Net pada dataset DRIVE (accuracy 96,27%, sensitivity 84,38%, precision 75,95%, dan jaccard score 66,28%), dataset STARE (accuracy 96,58%, sensitivity 82,78%, precision 76,73%, dan jaccard score 65,38%), dan dataset CHASEDB_1 (accuracy 97,04%, sensitivity 83,55%, precision 76,72%, dan jaccard score 66,40%). Dari ketiga dataset yang digunakan dataset CHASEDB_1 memperoleh hasil yang lebih baik dibandingkan dataset DRIVE dan STARE.

Kata kunci: Clahe Convolutional Neural Network, grayscale, median filter, segmentasi pembuluh darah, VV-Net.

1. PENDAHULUAN

Retina rentan terhadap berbagai penyakit yang dapat berakibat fatal apabila tanpa penanganan yang cepat, contohnya seperti penyakit retinopati diabetik (RD), degenerasi makula terkait usia, dan glaukoma[1]. Untuk menganalisis penyakit tersebut, biasanya dokter spesialis mata melakukan segmentasi pada retina secara manual, suatu tugas yang menantang dan memerlukan waktu[2]. Teknologi pencitraan retina sangat penting untuk mendiagnosis dan menyaring penyakit-penyakit tersebut dengan memeriksa kebocoran darah dari pembuluh darah retina, membantu dokter menentukan kondisi patologis[3]. Sehingga sangat membantu dokter dalam mendeteksi penyakit retina dengan lebih cepat serta memungkinkan penanganan yang lebih cepat dan efisien.

Segmentasi citra adalah proses memisahkan antara latar depan dan latar belakang citra, memungkinkan penggunaan hasil pemisahan atau segmentasi tersebut dalam proses lanjutan. Banyak penelitian sebelumnya telah dilakukan pada segmentasi citra retina, terutama pada pembuluh darah. Meskipun demikian, hasil segmentasi yang diperoleh seringkali kurang akurat dan masih terdapat *noise*. Tantangan ini menjadi fokus bagi peneliti lain untuk menyelesaikan permasalahan tersebut dan mencapai hasil segmentasi yang lebih baik.

Sebelum melakukan segmentasi pembuluh darah pada citra retina, dataset citra retina harus menjalani proses *preprocessing* untuk menghasilkan citra yang lebih baik. Proses *preprocessing* pada citra retina dalam penelitian ini mencakup metode *grayscale*, *denoising* dengan *median filter*, dan *CLAHE*. Beberapa penelitian sebelumnya telah mengimplementasikan teknik *denoising* dalam proses segmentasi pembuluh darah, namun metode yang digunakan belum melibatkan *deep learning* diantaranya : Feng Tian[4], Khuram Naveed[5], dan Oscar Ramos-Soto[6]. Adapun hasil yang didapat oleh peneliti tersebut masih belum unggul bila dibandingkan dengan penelitian ini yang menggunakan metode *deep learning*.

Arsitektur *deep learning* terbaru semakin diperluas ke bidang penglihatan komputer, terutama untuk tugas seperti segmentasi pembuluh darah retina pada citra fundus retina, hal ini tentunya menarik minat peneliti untuk terus mengembangkan solusi terhadap permasalahan ini dalam beberapa waktu terakhir[7]. Arsitektur *deep learning* terbentuk dari serangkaian lapisan yang disusun secara hierarkis untuk mengubah informasi masukan menjadi hasil yang memiliki makna[8]. Penelitian sebelumnya oleh Beaudelaire Saha Tchinda dan rekan-rekannya[9] menggunakan metode *deep learning* dengan menerapkan teknik *denoising Laplacian of Gaussian filter* pada segmentasi pembuluh darah. Namun, hasil yang diperoleh masih belum mengungguli temuan pada penelitian ini. Selain itu, penelitian Buket

Toptas[10] juga melakukan segmentasi pembuluh darah retina dengan metode *deep learning*, namun tanpa menerapkan teknik *denoising* pada proses *pre-processing*. Dalam penelitian tersebut, hasil pengukuran parameter yang dicapai masih belum sebanding dengan hasil yang diperoleh oleh penelitian ini.

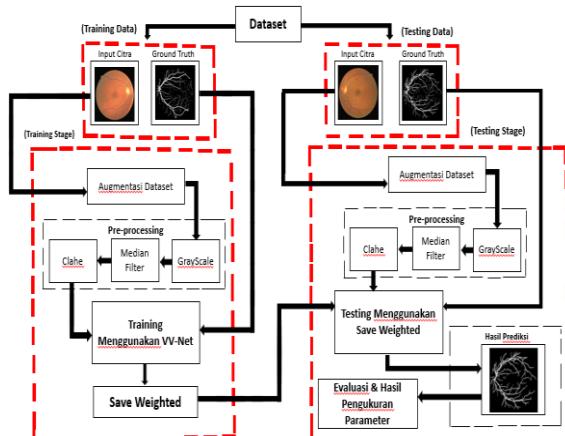
Tipe *Deep learning* yang digunakan pada penelitian ini ialah *Convolutional Neural Network* (CNN). CNN mampu menciptakan representasi fitur tingkat tinggi yang krusial untuk menyelesaikan tugas akhir dengan memadukan informasi dari lapangan lokal melalui operasi konvolusi bertahap[11]. Beberapa penelitian sebelumnya telah melakukan segmentasi pembuluh darah pada citra retina menggunakan metode CNN, namun tidak menerapkan metode *denoising* dalam proses *pre-processing* diantaranya Lukman Hakim[12] dan Yuhui Ma[13]. Meskipun demikian, hasil yang diperoleh dari penelitian-penelitian tersebut belum mengungguli hasil yang diperoleh pada penelitian ini.

CNN memiliki berbagai jenis arsitektur, dan pada penelitian ini, digunakan arsitektur VV-Net. VV-Net merupakan modifikasi dari arsitektur U-Net. Pada umumnya, arsitektur U-Net terdiri dari bagian *encoder*, *bridge*, dan *decoder*. Namun, pada VV-Net, dilakukan modifikasi dengan menghilangkan bagian *bridge* sehingga hanya menyisakan bagian *encoder* dan *decoder*. Inovasi ini menghasilkan arsitektur V-Net. Selanjutnya, arsitektur V-Net dilatih dua kali, sehingga membentuk arsitektur VV-Net pada penelitian ini. Dalam penelitian Alan Reyes-Figueroa[14], dilakukan segmentasi pembuluh darah pada citra retina menggunakan metode V-Net. Namun, keduanya belum menerapkan teknik denoising pada proses *preprocessing*.

Segmentasi pembuluh darah citra retina sebelumnya telah dilakukan oleh peneliti bersama Anita Desiani dan tim[15] pada dataset DRIVE. Metode yang digunakan melibatkan *Convolutional Neural Network* U-Net dan LadderNet. Meski demikian, diperlukan pengembangan lebih lanjut untuk meningkatkan hasil evaluasi proses segmentasi pembuluh darah. Oleh karena itu, untuk memperbaiki penelitian sebelumnya dan meningkatkan nilai evaluasi, pembahasan ini akan melakukan segmentasi pembuluh darah citra retina pada dataset DRIVE, STARE, dan CHASEDB_1. Metode yang diterapkan melibatkan *Grayscale*, *denoising* dengan *Median Filter*, dan *CLAHE* pada proses *preprocessing*, serta *Convolutional Neural Network* VV-Net untuk melakukan segmentasi pembuluh darah. Hasil penelitian ini diharapkan akan lebih baik dibandingkan hasil penelitian sebelumnya dan memperoleh hasil terbaik dari 3 dataset yang digunakan.

2. METODE PENELITIAN

Tahapan penelitian yang digunakan akan ditampilkan dalam flowchart pada gambar 1. flowchart pada gambar 1 menunjukkan 5 tahapan yang dilakukan yaitu *input* citra, augmentasi dataset, *preprocessing*, segmentasi pembuluh darah menggunakan metode CNN VV-Net, dan evaluasi & hasil pengukuran parameter.



Gambar 1. Flowchart tahapan pengolahan citra pada segmentasi pembuluh darah

2.1. Input citra

Input citra dataset yang digunakan adalah dataset *Digital Retinal Image for Vessel Extraction* (DRIVE), dataset *Structured Analysis of the Retina* (STARE), dan dataset CHASE_DB1. Ketiga dataset yang digunakan merupakan sumber data yang seringkali digunakan dalam penelitian dan dapat diunduh dengan gratis. Dataset DRIVE diperoleh dari program *screening retinopati diabetik* di Belanda, dengan ukurannya dimensi 564x584 piksel dan mempunyai format *Tagged Image File* (.tif)[16]. Dataset STARE disediakan oleh Shiley Eye Center di Universitas California, San Diego, dan oleh Veterans Administration Medical Center di San Diego. Dataset STARE mempunyai ukuran dimensi 700x605 piksel dengan format *Portable Pixmap File* (.PPM). Terakhir, dataset CHASEDB_1 merupakan kumpulan citra retina anak-anak multi-etnik dari dataset *Child Heart and Health Study in England* (CHASE), dengan ukuran dimensi 999x960 piksel dan mempunyai format *Joint Photographic Group* (.jpg).

2.2. Augmentasi dataset

Tahap ini digunakan untuk mengolah data yang mana data tersebut dimanipulasi tanpa menghilangkan inti atau esensi data tersebut. Augmentasi dataset merupakan teknik regulasi yang meningkatkan kemampuan generalisasi model yang telah dilatih[7]. Pada penelitian ini augmentasi yang digunakan adalah *flip horizontal*, *flip vertical*, dan *Grid Distorsi*.

Pada augmentasi pertama *flip horizontal*, augmentasi ini membuat objek augmentasi dengan transformasi *flip horizontal* dengan nilai ‘*p*=1.0’. Augmentasi kedua *flip vertical*, augmentasi ini membuat objek augmentasi dengan transformasi *flip vertical* dengan nilai ‘*p*=1.0’. Pada augmentasi *Grid Distorsi*, augmentasi ini menggunakan transformasi *grid* yang memberikan *distorsi* pada citra. Dengan nilai ‘*p*=1’.

Proses augmentasi dataset ini akan diterapkan pada tiga dataset citra retina yang digunakan yaitu DRIVE, STARE, dan CHASE_DB1. Sehingga menghasilkan 80 citra *training* dan 20 citra *testing* pada dataset DRIVE, 64 citra *training* dan 16 citra *testing* pada dataset STARE, dan 21 citra *training* dan 84 citra *testing* pada dataset CHASEDB_1.

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 awal *preprocessing* yang digunakan adalah metode *grayscale*. *Grayscale* merupakan teknik *enhancement* pada citra retina yang mengubah skala warna citra menjadi citra keabu-abuan. Citra grayscale menampilkan variasi warna abu-abu di setiap pikselnya, dengan setiap piksel menggunakan representasi 8-bit dan memiliki nilai kecerahan dalam rentang 0 hingga 255[17]. Jadi, jika 0 maka citra bewarna hitam dan jika 255 maka citra bewarna putih. Dalam citra digital mempunyai skala keabua-abuan 8 bit yang artinya $2^8 = 256$ kemungkinan warnanya (dari 0 sampai 255). Selanjutnya dilakukan perbaikan citra menggunakan teknik *denoising* dengan metode *median filter*.

Metode *median filter* adalah metode *enhancement* citra yang mengolah citra pada *domain spasial* yang tujuannya untuk memperbaiki kualitas citra yang buruk dan juga mengurangi *noise* yang terdapat dalam citra tersebut. Nilai *noise* pada citra digital atau urutan digital digantikan oleh nilai median dari lingkungan (*masker*)[18]. Piksel pada *masker* akan diurutkan berdasarkan tingkatan keabuan, dan nilai median dari kelompok tersebut diambil untuk menggantikan nilai *noise*. *Output median filter* akan ditunjukkan pada persamaan (1).

$$g(x, y) = \text{med}\{f(x - i, y - i), i, j \in W\} \quad (1)$$

$F(x, y)$ adalah original citra, $g(x, y)$ adalah *output* citra dan W adalah *masker* 2 dimensi yang memiliki ukuran $n \times n$ (dimana n pada umumnya merupakan bilangan ganjil) seperti 3×3 , 5×5 , dan seterusnya.

Proses *preprocessing* terakhir adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE) merupakan salah satu metode *enhancement* yang berfungsi untuk memperbaiki kualitas suatu citra serta menghilangkan *noise*. Pada persamaan (2) akan

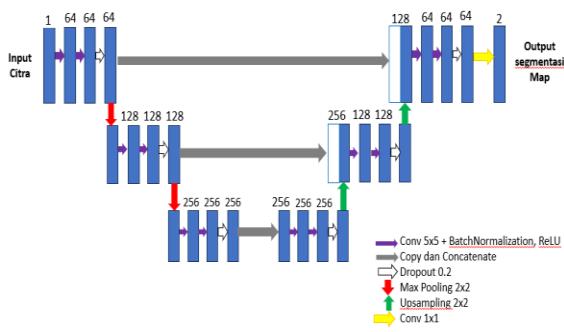
menampilkan rumus *histogram equalization* yang dapat digunakan pada CLAHE.

$$S_k = T(r_k) = (L - 1) \sum_{j=0}^k p_r(r_j) = \frac{(L-1)}{MN} \quad (2)$$

S_k adalah nilai probabilitas komulatif k dikali dengan nilai K_{\max} , r_k adalah skala keabu-abuan, L adalah jumlah Tingkat abu-abu, n_j adalah jumlah piksel dalam citra yang memiliki intensitas j, $P_r(r_j)$ adalah jumlah piksel input citra dengan intensitas r_j dan $M \times N$ adalah total jumlah piksel.

2.4. Segmentasi pembuluh darah retina menggunakan metode CNN VV-Net

Arsitektur VV-Net merupakan arsitektur modifikasi dari arsitektur U-Net. Pada arsitektur U-Net biasanya terdapat tiga bagian yaitu bagian *encoder*, *bridge*, dan *decoder*. Modifikasi dilakukan dengan menghilangkan bagian *bridge* pada arsitektur U-Net sehingga hanya tersisa bagian *encoder* dan *decoder* dan dinamakan dengan arsitektur V-Net seperti yang terlihat pada gambar 2. Arsitektur V-Net tersebut ditraining sebanyak dua kali sehingga disebut dengan arsitektur VV-Net.



Gambar 2. Arsitektur V-Net

Proses *training* arsitektur V-Net pertama, yang terlihat pada gambar 2 menunjukkan bahwa setiap proses itu membentuk 2 lapisan konvolisional serta *batch normalization* dan 1 *dropout*. Layer pertama *encoder*, jumlah saluran input citra adalah 1. Lalu terjadi perubahan jumlah saluran dari 1 ke 64 karena meningkatnya kedalam citra dalam proses konvolusi dan *batch normalization*, fungsi aktivasi yang digunakan ReLU dan kernel size 5x5. *Dropout* yang digunakan yaitu 0.2 (20%) yang ditunjukkan dengan panah putih berfungsi untuk mengurangi *overfitting*. Selanjutnya dilakukan penggabungan maksimal yang mana membagi ukuran citra menjadi sepatuh ditunjukkan oleh panah merah.

Pada proses layer kedua *encoder*, setelah dilakukan proses penggabungan maksimal. Jumlah saluran berubah dari 64 menjadi 128 karena meningkatnya kedalam citra dalam proses konvolusi dan *batch normalization*, dengan menggunakan fungsi aktivasi ReLU dan kernel size 5x5. *Dropout* yang digunakan yaitu 0.2 (20%). Selanjutnya dilakukan penggabungan maksimal yang ditunjukkan oleh tanda panah warna hijau.

Pada proses layer ketiga *encoder*, setelah dilakukan proses penggabungan maksimal. Jumlah saluran berubah dari 128 menjadi 256 karena meningkatnya kedalam citra dalam proses konvolusi dan *batch normalization*, fungsi aktivasi yang digunakan ReLU dan kernel size 5x5. *Dropout* yang digunakan 0.2 (20%). Selanjutnya *output* dari layer ketiga *encoder* dijadikan *input* pada layer pertama *decoder* yang ditunjukkan oleh tanda panah warna abu-abu.

Pada layer pertama *decoder*, setelah dilakukan proses *input* dari hasil *output* layer ketiga *encoder*. Jumlah saluran tetap 256 dengan fungsi aktivasi ReLU dan kernel size 5x5. *Dropout* yang digunakan 0.2 (20%). Selanjutnya dilakukan teknik *upsampling* untuk memperbesar citra keukuran aslinya dengan mengalidukan ukuran citra tersebut yang ditunjukkan oleh tanda panah warna hijau.

Pada layer kedua *decoder*, setelah dilakukan teknik *upsampling*, dilakukan penggabungan citra dengan layer kedua *encoder*. Alasannya ialah untuk menggabungkan informasi dari layer sebelumnya sehingga mendapatkan hasil peridksi yang lebih tepat. Kemudian jumlah saluran berubah dari 256 menjadi 128 dengan menggunakan fungsi aktivasi ReLU dan kernel size 5x5. *Dropout* yang digunakan 0.2 (20%). Selanjutnya dilakukan teknik *upsampling* yang ditunjukkan oleh tanda panah warna hijau.

Pada layer ketiga *decoder*, setelah dilakukan teknik *upsampling*, dilakukan proses penggabungan citra dengan layer pertama *encoder*. Jumlah saluran berubah dari 128 menjadi 64 dengan menggunakan fungsi aktivasi ReLU dan kernel size 5x5. *Dropout* yang digunakan 0.2 (20%).

Selanjutnya dilakukan proses *training* pada arsitektur V-Net kedua dengan *input* saluran pertama ialah 64 (diambil dari *output* layer ketiga *dekompor* arsitektur V-Net pertama) dan dilakukan proses seperti *training* pada arsitektur V-Net pertama diatas sampai menghasilkan *output* segmentasi map dengan jumlah saluran 2 dengan fungsi aktivasi yang digunakan sigmoid dan kernel 1x1.

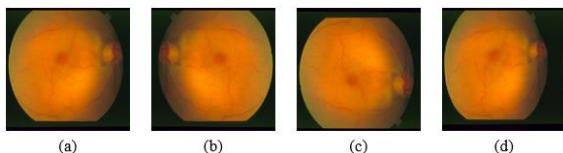
2.5. Evaluasi & hasil pengukuran parameter

Setelah dilakukan tahapan segmentasi atau pemisahan objek citra pada objek lainnya. Langkah selanjutnya ialah evaluasi hasil kinerja dari segmentasi pembuluh darah menggunakan arsitektur VV-Net dengan menggunakan *confusion metrik* untuk mengukur *accuracy*, *sensitivitas*, *precision*, dan *Jaccard Score*.

3. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini adalah dataset DRIVE 40 citra yang terdiri dari 20 citra *train* dan 20 citra *test*, dataset STARE 20 citra yang terdiri dari 16 citra *train* dan 4 citra *test*, dan dataset CHASEDB_1 28 citra yang terdiri dari 21 citra *train* dan 7 citra *test*.

Augmentasi digunakan pada 3 dataset yang digunakan yaitu *flip horizontal*, *flip vertikal* dan *grid distorsi* sehingga jumlah dataset pun berubah. Dataset DRIVE setelah augmentasi menjadi 80 citra *train* dan 20 citra *test*. Dataset STARE setelah augmentasi menjadi 64 citra *train* dan 16 citra *test*. Dataset CHASEDB_1 setelah augmentasi menjadi 84 citra *train* dan 21 citra *test*. Contoh citra hasil augmentasi dapat dilihat pada gambar 3. setelah dilakukan augmentasi, persentase pembagian citra yang digunakan pada penelitian ini adalah 80% *train* dan 20% *test*.

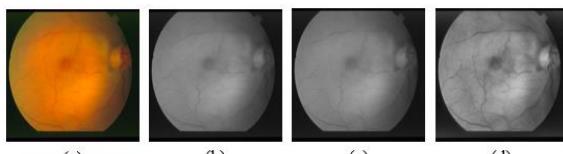


Gambar 3. Augmentasi dataset, (a) citra asli, (b) flip horizontal, (c) flip vertical, dan (d) grid distorsi

Setelah augmentasi dilakukan proses *preprocessing* pada dataset yang digunakan. Metode *preprocessing* yang pertama digunakan adalah *grayscale*. Metode *grayscale* yang digunakan mengubah skala citra retina menjadi citra keabuan, hasil *preprocessing* menggunakan metode *grayscale* dapat dilihat pada gambar 4(b).

Selanjutnya metode *preprocessing* yang digunakan adalah *median filter*. *Median filter* merupakan salah satu teknik *denosing* yang digunakan untuk mengelola citra pada *domain spasial* dengan tujuan untuk memperbaiki kualitas citra dan mengurangi noise tanpa memberikan efek smoothing yang berlebihan. Kernel size yang digunakan pada *median filter* adalah 3x3, hasil citra *median filter* ditampilkan pada gambar 4(c).

Proses *preprocessing* terakhir adalah CLAHE. Metode CLAHE digunakan untuk memperbaiki kualitas citra yang memiliki kontras rendah serta menghilangkan *noise*, dengan tile size yang digunakan 8x8. hasil *preprocessing* menggunakan CLAHE dapat dilihat pada gambar 4(d).



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

Setelah dilakukan proses *preprocessing*, selanjutnya dilakukan segmentasi pembuluh darah menggunakan metode CNN dengan arsitektur VV-Net pada tiga dataset yang digunakan. Adapun *hyperparameter* yang digunakan pada proses *training* arsitektur VV-Net adalah sebagai berikut:

Batch size yang digunakan 2. *Learning Rate* yang digunakan 0.0001. *Epoch* yang digunakan 30. *Loss function* yang digunakan DiceBCELoss.

Hasil pengujian citra pada segmentasi pembuluh darah dengan menggunakan metode CNN VV-Net akan ditampilkan pada tabel 1.

Tabel 1. Hasil pengujian segmentasi pembuluh darah menggunakan metode CNN VV-Net

dataset	citra asli	Segmentasi CNN VV-Net
DRIVE		
STARE		
CHASE DB_1		

Selain hasil pengujian pada tabel 1, terdapat hasil evaluasi pengukuran parameter yang didapatkan dari pengujian segmentasi pembuluh darah pada citra retina dengan menggunakan metode CNN VV-net dapat dilihat pada tabel 2.

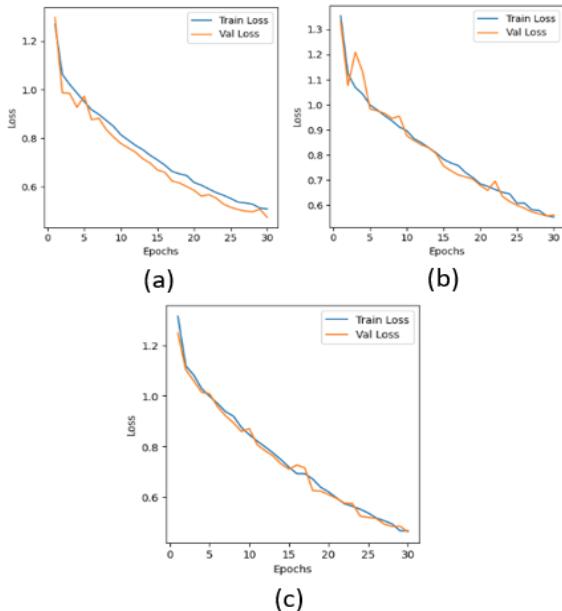
Tabel 2. Hasil pengukuran parameter dari metode CNN VV-Net

Dataset	Accuracy	Sensitivity	Precision	Jaccard Score
DRIVE	96,27%	84,38%	75,95%	66,28%
STARE	96,58%	82,78%	76,73%	65,38%
CHASE DB_1	97,04%	83,55%	76,72%	66,40%

Berdasarkan hasil pengukuran parameter pada tabel 2, untuk segmentasi pembuluh darah menggunakan metode CNN VV-Net pada dataset DRIVE mendapatkan nilai accuracy 96,27%, sensitivity 84,38%, precision 75,95% dan jaccard score 66,28%. Dataset stare mendapatkan nilai accuracy 96,58%, sensitivity 82,78%, precision 76,73%, dan jaccard score 65,38%. Dan terakhir dataset ChaseDB_1 mendapatkan nilai accuracy 97,04%, sensitivity 83,55%, precision 76,72%, dan jaccard score 66,40%.

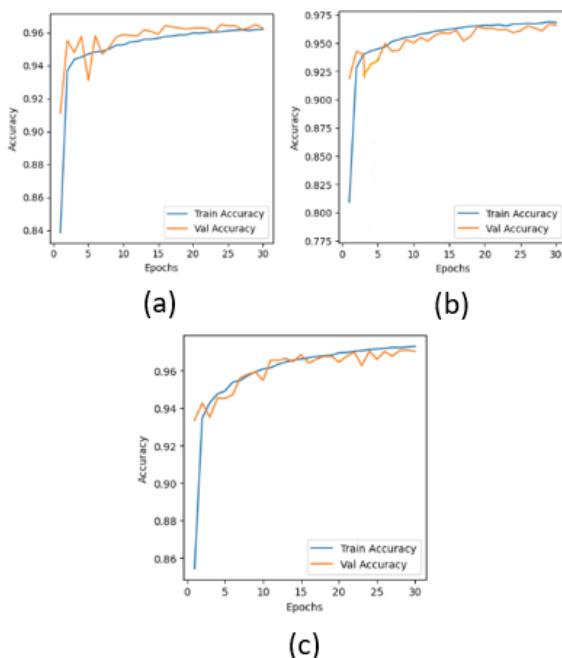
Dari tiga hasil pada tabel 2, hasil terbaik diperoleh oleh dataset CHASEDB_1 dimana hasil accuracy dan jaccard score lebih tinggi bila dibandingkan dengan dataset DRIVE dan STARE.

Selain mendapat hasil pengukuran parameter pada tabel 2, terdapat juga *curve training loss* dan *validation loss* dari tiga dataset yang digunakan. Pada *curve training loss* dan *validation loss* gambar 5 menunjukkan hasil yang baik dimana tidak terjadi overfitting pada model.



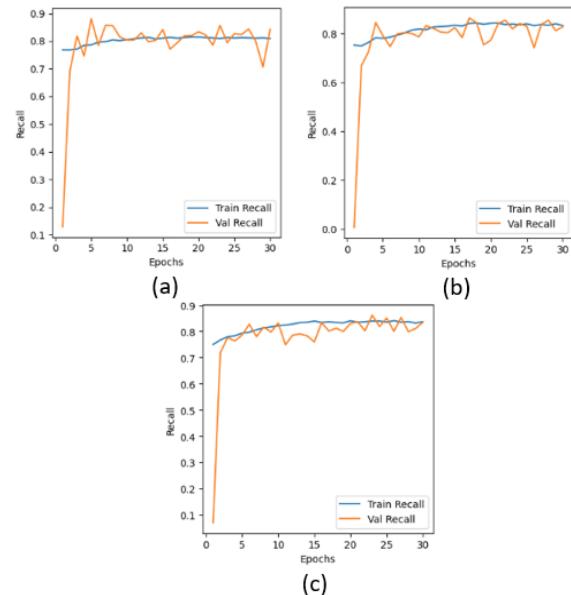
Gambar 5. Curve training loss dan validation loss, (a) DRIVE, (b) STARE, dan (c) CHASEDB_1

Curve training accuracy dan *validation accuracy* pada gambar 6 yang didapat dalam proses segmentasi pembuluh darah menggunakan metode CNN VV-Net menunjukkan hasil yang baik dimana tidak terjadi overfitting pada model.



Gambar 6. Curve training accuracy dan validation accuracy, (a) DRIVE, (b) STARE, dan (c) CHASEDB_1

Curve terakhir yang didapatkan dari proses segmentasi pembuluh darah menggunakan metode CNN VV-Net yang ditampilkan pada gambar 7 adalah *curve training recall* dan *valisation recall* menunjukkan hasil yang baik juga dimana tidak terdapat overfitting pada model.



Gambar 7. Curve training recall dan validation recall, (a) DRIVE, (b) STARE, dan (c) CHASEDB_1

4. DISKUSI

Pada proses *preprocessing* menggunakan metode *grayscale*, *median filter*, dan *CLAHE* yang digunakan mampu meningkatkan kualitas citra sehingga dapat membantu dalam proses segmentasi pembuluh darah menggunakan metode CNN VV-Net.

Proses segmentasi pembuluh darah menggunakan metode CNN VV-Net pada dataset DRIVE yang disajikan tabel 3 menunjukkan bahwa metode CNN VV-Net mampu menandingi metode penelitian lain yaitu LEA U-Net, GDF-Net, Adaptive hysteresis threshold, Bridge-net, AWSFCM, CRAUNet, VG-DropDnet, Otsu threshold, ES-BM3D (frangi), CFNN, ANN, WA-Net, W-Net, EEA U-Net, U-Net, dan LadderNet. Hal ini ditunjukkan dengan hasil accuracy, sensitivity, precision, dan jaccard score yang dihasilkan lebih tinggi dibandingkan dengan hasil yang didapat menggunakan metode tersebut.

Tabel 3. Perbandingan hasil evaluasi DRIVE dengan metode penelitian lain

Metode	Accuracy	Sensitivity	Precision	Jaccard Score
LEA U-Net[19]	95,63%	-	-	-
GDF-Net[20]	96,22%	82,91%	-	-
Adaptive hysteresis threshold[21]	95,97%	67,45%	-	-
Bridge-net[22]	95,65%	78,53%	-	-
AWSFCM[23]	96,05%	70,20%	-	-
CRAUNet[24]	95,86%	79,54%	-	-
VG-DropDNet[25]	95,36%	79,74%	-	-
Otsu Threshold[4]	95,54%	69,42%	-	-
ES-BM3D (Frangi)[5]	95,70%	76,87%	-	-
CFNN[9]	94,80%	73,52%	-	-
ANN[10]	96,18%	84%	-	61,48%
WA-Net[26]	95,75%	79,66%	-	-

W-Net[14]	95,15%	84%	-	-
EEA Unet[27]	95,77%	79,18%	-	-
U-Net[28]	95,47%	-	-	-
U-Net[15]	95,46%	74,20%	-	-
LadderNet[15]	95,47%	75,19%	-	-
Proposal	96,27%	84,38%	75,95%	66,28%

Hasil evaluasi pada dataset STARE yang terlihat pada tabel 4 yang didapatkan dari proses segmentasi pembuluh darah menggunakan metode CNN VV-Net juga mampu menandingi hasil dari metode penelitian sebelumnya yaitu GDF-Net, AWSFCM, Otsu threshold, ES-BM3D (frangi), MCET-HHO, CFNN, U-Net, EEA Unet, ANN, dan EC L_{MISO}. Hal ini ditunjukkan dengan nilai accuracy, sensitivity, precision dan jaccard score yang dihasilkan oleh metode CNN VV-Net lebih tinggi bila dibandingkan dengan hasil yang didapatkan oleh metode penelitian sebelumnya.

Tabel 4. Perbandingan hasil evaluasi STARE dengan metode penelitian lain

Metode	Accuracy	Sensitivity	Precision	Jaccard Score
GDF-Net[20]	96,53%	76,16%	-	-
AWSFCM[23]	96,01%	68,46%	-	-
Otsu threshold[4]	94,92%	70,19%	-	-
ES-BM3D (Frangi)[5]	95,26%	80,56%	-	-
MCET-HHO[6]	95,80%	74,74%	-	-
CFNN[9]	95,48%	72,65%	-	-
U-Net[29]	95,55%	66,1%	-	-
EEA Unet[27]	94,45%	80,21%	-	-
ANN[10]	94,56%	63,08%	-	52,96%
EC L _{MISO} [12]	94,03%	74,01%	-	-
Proposal	96,58%	82,78%	76,73%	65,38%

Dan terakhir, hasil evaluasi dataset CHASEDB_1 pada proses segmentasi pembuluh darah menggunakan metode CNN VV-Net yang disajikan pada tabel 5 menunjukkan bahwa metode yang digunakan mampu menandingi metode penelitian sebelumnya diantaranya metode Bridge-net, GDF-Net, CRAUNet, AWSFCM, ES-BM3D (frangi), CFNN, WA-Net, U-Net, EEA Unet, U-net, dan EC L_{MISO}. Hal ini dibuktikan dengan hasil accuracy, sensitivity, precision dan jaccard score yang dihasilkan metode CNN VV-Net lebih tinggi dibandingkan dengan metode penelitian sebelumnya.

Tabel 5. Perbandingan hasil evaluasi CHASEDB_1 dengan metode penelitian lain

Metode	Accuracy	Sensitivity	Precision	Jaccard Score
Bridge-net[22]	96,67%	81,32%	-	-
GDF-Net[20]	96,60%	78,56%	-	-
CRAUNet[24]	96,59%	82,59%	-	-
AWSFCM[23]	95,78%	65,81%	-	-
ES-BM3D (Frangi)[5]	95,31%	82,03%	-	-
CFNN[9]	94,52%	72,79%	-	-
WA-Net[26]	96,53%	80,42%	-	-
U-Net[29]	96,17%	56,75%	-	-
EEA Unet[27]	93,40%	64,57%	-	-
U-Net[28]	96,63%	-	-	-
EC L _{MISO} [12]	95,33%	60,80%	-	-
Proposal	97,04%	83,55%	76,72%	66,40%

5. KESIMPULAN

Peningkatan citra pada langkah preprocessing dengan menerapkan metode *grayscale*, teknik *denoising* menggunakan *median filter* dan CLAHE terbukti bermanfaat dalam meningkatkan kualitas citra. Hal ini terutama berguna dalam proses segmentasi pembuluh darah menggunakan metode CNN VV-Net.

Segmentasi pembuluh darah menggunakan metode CNN VV-Net pada dataset DRIVE memperoleh accuracy 96,27%, sensitivity 84,38%, precision 75,95%, dan jaccard score 66,28%.

Segmentasi pembuluh darah menggunakan metode CNN VV-Net pada dataset STARE memperoleh accuracy 96,58%, sensitivity 82,78%, precision 76,73%, dan jaccard score 65,38%.

Segmentasi pembuluh darah menggunakan metode CNN VV-Net pada dataset CHASEDB_1 memperoleh accuracy 97,045, sensitivity 83,55%, precision 76,72%, dan jaccard score 66,04%.

Dari ketiga dataset yang digunakan hasil dataset CHASEDB_1 lebih baik bila dibandingkan dengan hasil dari dataset DRIVE dan STARE. Hasil evaluasi yang didapatkan juga lebih baik dibandingkan hasil evaluasi yang didapatkan peneliti sebelumnya bersama Anita desiani dan tim[15] dengan menggunakan metode U-Net dan LadderNet.

Rencana kedepannya adalah mengembangkan lebih lanjut pendekatan yang diajukan, dengan fokus untuk meningkatkan hasil evaluasi dari proses segmentasi pembuluh darah.

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: 10.1016/j.media.2023.102929.
- [2] A. K. Shukla, R. K. Pandey, and R. B. Pachori, “A fractional filter based efficient algorithm for retinal blood vessel segmentation,” *Biomed. Signal Process. Control*, vol. 59, p. 101883, 2020, doi: 10.1016/j.bspc.2020.101883.
- [3] X. Deng and J. Ye, “A retinal blood vessel segmentation based on improved D-MNet and pulse-coupled neural network,” *Biomed. Signal Process. Control*, vol. 73, no. October 2021, p. 103467, 2022, doi: 10.1016/j.bspc.2021.103467.
- [4] F. Tian, “Blood Vessel Segmentation of Fundus Retinal Images Based on Improved Frangi and Mathematical Morphology,” *Comput. Math. Methods Med.*, vol. 2021, p. 4761517, 2021, doi: 10.1155/2021/4761517.
- [5] K. Naveed, F. Abdullah, H. A. Madni, M. A. U. Khan, T. M. Khan, and S. S. Naqvi,

- “Towards automated eye diagnosis: An improved retinal vessel segmentation framework using ensemble block matching 3d filter,” *Diagnostics*, vol. 11, no. 1, pp. 1–27, 2021, doi: 10.3390/diagnostics11010114.
- [6] O. Ramos-Soto *et al.*, “An efficient retinal blood vessel segmentation in eye fundus images by using optimized top-hat and homomorphic filtering,” *Comput. Methods Programs Biomed.*, vol. 201, p. 105949, 2021, doi: 10.1016/j.cmpb.2021.105949.
- [7] 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.
- [8] 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.
- [9] B. Saha Tchinda, D. Tchiotsop, M. Noubom, V. Louis-Dorr, and D. Wolf, “Retinal blood vessels segmentation using classical edge detection filters and the neural network,” *Informatics Med. Unlocked*, vol. 23, p. 100521, 2021, doi: 10.1016/j.imu.2021.100521.
- [10] B. Toptaş and D. Hanbay, “Retinal blood vessel segmentation using pixel-based feature vector,” *Biomed. Signal Process. Control*, vol. 70, p. 103053, 2021, doi: <https://doi.org/10.1016/j.bspc.2021.103053>.
- [11] Q. Qin and Y. Chen, “A review of retinal vessel segmentation for fundus image analysis,” *Eng. Appl. Artif. Intell.*, vol. 128, no. November 2023, p. 107454, 2024, doi: 10.1016/j.engappai.2023.107454.
- [12] L. Hakim, M. S. Kavitha, N. Yudistira, and T. Kurita, “Regularizer based on Euler characteristic for retinal blood vessel segmentation,” *Pattern Recognit. Lett.*, vol. 149, pp. 83–90, 2021, doi: <https://doi.org/10.1016/j.patrec.2021.05.023>.
- [13] Y. Ma *et al.*, “ROSE: A Retinal OCT-Angiography Vessel Segmentation Dataset and New Model,” *IEEE Trans. Med. Imaging*, vol. 40, no. 3, pp. 928–939, 2021, doi: 10.1109/TMI.2020.3042802.
- [14] A. Reyes-Figueroa and M. Rivera, “W–net: A Convolutional Neural Network for Retinal Vessel Segmentation,” in *Pattern Recognition*, 2021, pp. 355–368. doi: 10.1007/978-3-030-77004-4_34.
- [15] 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/S101623722500193.
- [16] 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.
- [17] A. Abdulrahman and S. Varol, “A Review of Image Segmentation Using MATLAB Environment,” *8th Int. Symp. Digit. Forensics Secur. ISDFS 2020*, pp. 8–12, 2020, doi: 10.1109/ISDFS49300.2020.9116191.
- [18] Y. Zhu and C. Huang, “An Improved Median Filtering Algorithm for Image Noise Reduction,” *Phys. Procedia*, vol. 25, pp. 609–616, 2012, doi: 10.1016/j.phpro.2012.03.133.
- [19] 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.
- [20] 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.
- [21] H. Du *et al.*, “Retinal blood vessel segmentation by using the MS-LSDNet network and geometric skeleton reconnection method,” *Comput. Biol. Med.*, vol. 153, p. 106416, 2023, doi: 10.1016/j.combiomed.2022.106416.
- [22] Y. Zhang, M. He, Z. Chen, K. Hu, X. Li, and X. Gao, “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: <https://doi.org/10.1016/j.eswa.2022.116526>.
- [23] S. Mahapatra, S. Agrawal, P. K. Mishro, and R. B. Pachori, “A novel framework for retinal vessel segmentation using optimal improved frangi filter and adaptive weighted spatial FCM,” *Comput. Biol. Med.*, vol. 147, no. June, p. 105770, 2022, doi: 10.1016/j.combiomed.2022.105770.
- [24] 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.

- [25] A. Desiani, Erwin, B. Suprihatin, F. Efriliyanti, M. Arhami, and E. Setyaningsih, “VG-DropDNet A Robust Architecture for Blood Vessels Segmentation on Retinal Image,” *IEEE Access*, vol. 10, no. September, pp. 1–1, 2022, doi: 10.1109/access.2022.3202890.
- [26] 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.
- [27] V. Sathananthavathi and G. Indumathi, “Encoder Enhanced Atrous (EEA) Unet architecture for Retinal Blood vessel segmentation,” *Cogn. Syst. Res.*, vol. 67, pp. 84–95, 2021, doi: 10.1016/j.cogsys.2021.01.003.
- [28] M. E. Gegundez-Arias, D. Marin-Santos, I. Perez-Borrero, and M. J. Vasallo-Vazquez, “A new deep learning method for blood vessel segmentation in retinal images based on convolutional kernels and modified U-Net model,” *Comput. Methods Programs Biomed.*, vol. 205, p. 106081, 2021, doi: 10.1016/j.cmpb.2021.106081.
- [29] 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.