

**SEGMENTASI PEMBULUH DARAH PADA CITRA RETINA  
MENGGUNAKAN KOMBINASI ARSITEKTUR *U-NET*,  
*RESNET*, DAN *BIDIRECTIONAL CONVOLUTIONAL LONG  
SHORT TERM MEMORY***

**SKRIPSI**

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

**Oleh :**

**AJENG ISLAMIA PUTRI**

**08011181722002**



**JURUSAN MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS SRIWIJAYA  
2021**

## HALAMAN PENGESAHAN

### SEGMENTASI PEMBULUH DARAH PADA CITRA RETINA MENGGUNAKAN KOMBINASI ARSITEKTUR *U-NET, RESNET, DAN* *BIDIRECTIONAL CONVOLUTIONAL LONG SHORT TERM MEMORY*

#### SKRIPSI

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

Oleh

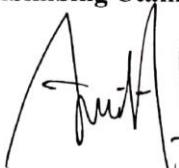
AJENG ISLAMIA PUTRI  
NIM. 08011181722002

Pembimbing Kedua



Irmeilyana, M.Si  
NIP.197405171999032003

Indralaya, September 2021  
Pembimbing Utama



Anita Desiani, M.Kom  
NIP. 19771211 2003122002

Mengetahui,  
Ketua Jurusan Matematika



Drs. Sugandi Yahdin, M.M  
NIP. 195802271986031003

## **HALAMAN PERSEMBAHAN**

*Kupersembahkan skripsi ini untuk :*

*Allah SWT*

*Ayah dan Ibuku Tercinta*

*Kakak-kakak dan Keponakanku Tersayang*

*Seluruh Keluarga Besarku*

*Sahabat-sahabatku Tersayang*

*Seluruh Dosen dan Guruku*

*Almamater Kebanggaanku,*

*Dan pada seseorang yang menjadi pendamping hidupku kelak*

### **Motto**

*“Bersemangatlah untuk meraih hal-hal yang bermanfaat bagimu, dan mintalah*

*pertolongan kepada Allah”*

*(HR. Muslim no 2664)*

*“Barang siapa ysng keluar untuk mencari ilmu, maka ia berada di jalan Allah*

*hingga ia pulang”*

*(HR. Tirmidzi)*

## KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakakatuh

Dengan mengucapkan Alhamdulillah, segala puji bagi Allah *Subhanahu Wa Ta'ala* atas limpahan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul "**SEGMENTASI PEMBULUH DARAH PADA CITRA RETINA MENGGUNAKAN KOMBINASI ARSITEKTUR U-NET, RESNET, DAN BIDIRECTIONAL CONVOLUTIONAL LONG SHORT TERM MEMORY**" ini dapat berjalan dengan baik dan sebagai salah satu syarat memperoleh gelar Sarjana Sains Bidang Studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Dengan segala hormat dan kerendahan hati penulis mengucapkan terima kasih yang sebesar-besarnya dan perhargaan yang tulus penulis sampaikan kepada kedua orang tua tercinta, yaitu **Bapak Sugiman** dan **Ibu Lisa Wati** yang telah menuntun, mendidik, mengajari, menasehati, memberi semangat, dan tidak pernah lelah berdoa yang tebaik untuk anaknya. Penulis juga menyampaikan ucapan terima kasih dan perhargaan kepada :

1. Bapak **Drs. Sugandi Yahdin, M.M**, selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya yang telah membimbing dan mengarahkan usrusan akademik kepada penulis selama belajar di Jurusan Matematika FMIPA Universitas Sriwijaya.
2. Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Sekretaris Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas

Sriwijaya yang telah membimbing dan mengarahkan urusan akademik kepada penulis selama belajar di Jurusan Matematika FMIPA Universitas Sriwijaya.

3. Ibu **Anita Desiani, M.Kom** selaku Dosen Pembimbing Utama yang telah bersedia meluangkan waktu, tenaga, pikiran untuk memberikan bimbingan dan pengarahan dengan penuh perhatian, pengertian, dan kesabaran sehingga skripsi ini dapat diselesaikan.
4. Ibu **Irmeilyana, M.Si** selaku Dosen Pembimbing Kedua yang telah bersedia meluangkan waktu, tenaga, pikiran untuk memberikan bimbingan dan pengarahan dengan penuh perhatian, pengertian, dan kesabaran sehingga skripsi ini dapat diselesaikan.
5. Ibu **Dr. Herlina Hanum, M.Si**, ibu **Dra. Ning Eliyati, M.Pd**, dan ibu **Sisca Octarina, M.Sc** selaku Dosen Pembahas dan Penguji yang telah memberikan tanggapan, kritik, dan saran yang sangat bermanfaat untuk perbaikan dan penyelesaian skripsi ini.
6. Ibu **Dr. Herlina Hanum, M.Si**, selaku Dosen Pembimbing Akademik yang sangat baik telah memberikan saran, membimbing, membantu, dan mengarahkan urusan akademik penulis setiap semester.
7. **Seluruh Dosen di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam** yang telah memberikan ilmu yang bermanfaat, nasehat serta bimbingan selama penulis menjalani perkuliahan.
8. Bapak **Irwansyah** selaku admin dan Ibu **Hamidah** selaku Pegawai tata usaha Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam yang telah membantu penulis selama perkuliahan.

9. Kakak dan Adikku **Andre Oktora** dan **Mawarni**, sepupuku **Athaya**, serta keluarga besarku terima kasih untuk kasih sayang, motivasi, dukungan, perhatian, dan do'a yang selalu dipanjatkan selama ini untuk keberhasilanku.
10. Sahabat-sahabatku dibangku SMA **Layli**, **Purnama**, **Ditya**, **Risty**, **Wanda**, **Rizka**, dan **Tika** yang telah memberi dukungan, semangat, dan meluangkan waktu untuk mendengarkan curhatan baik tentang skripsi maupun yang lainnya.
11. Sahabatku selama perkuliahan **Calista**, **Filda**, **Elsa**, **Enyta**, **Ranil**, **Weli**, **Feni**, **Ayu**, **Tesya**, **April**, **Ona**, **Yogi**, dan **Anabil** yang telah menjadi *moodbooster* selama perkuliahan, serta canda tawa, suka duka dan kebersamaan yang telah dilalui bersama, semangat, nasehat, dukungan, dan batuan yang telah diberikan selama perkuliahan.
12. Tim bimbingan skripsi **Kak Fatur**, **Kak Ilham**, **Gibrان**, dan **Zaim** atas bantuan dan kerjasamanya selama penyusunan skripsi ini.
13. Keluarga **KKN Tematik Penyandingan** (**Ona**, **Anabil**, **Calis**, **Enyta**, **Kahfi**, **Ojik**, **Susanto**, **Udin**, **Bowok**, **Tari**, **Ipul**, **Siddiq**, dan **Juli**) atas kebersamaan yang telah dilalui bersama, do'a, serta telah memberikan semangat.
14. Kakak-kakak tingkat angkatan **2015**, **2016**, dan seluruh teman-teman angkatan **2017**, serta adik-adik tingkat angkatan **2018**, **2019**, dan **2020** atas bantuan selama perkuliahan.
15. Semua pihak yang tidak dapat penulis sebutkan satu persatu yang telah memberikan bantuan dalam menyelesaikan skripsi ini hanya ucapan terima

kasih yang dapat penulis berikan. Semoga segala kebaikan yang diberikan mendapatkan balasan dari Allah *Subhanahu Wa Ta'ala*.

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

Wassalamu'alaikum warahmatullahi wabarakatuh.

Indralaya, September 2021

Penulis

**SEGMENTATION BLOOD VESSELS IN RETINA IMAGES USING A  
COMBINATION ARCHITECTURES OF U-NET, RESNET, AND  
BIDIRECTIONAL CONVOLUTIONAL LONG SHORT TERM MEMORY**

By:

**Ajeng Islamia Putri  
080111181722002**

**ABSTRACT**

The addition of layers to the U-Net architecture can cause more parameters and redundant computation. The use of skip connection in the ResNet architecture can solve this problem, but it can cause the loss of important features from the previous layer. Bi-directional Convolutional Long Short Term Memory (Bi-ConvLSTM) can store previous and current information for a long time so that the missing features of the ResNet architecture can be overcome. The purpose of this study was to determine the performance evaluation results of combination architectures of U-Net, ResNet, and Bi-ConvLSTM on retinal blood vessels segmentation. The evaluation measures used were accuracy, sensitivity, specificity, F1-Score, and IoU. The data used in this study is the DRIVE dataset which is divided into 20 training data and 20 test data. The methods used in this study are data collection, data pre-processing, architecture implementation, training, testing, and evaluation. The values of accuracy, sensitivity, specificity, F1-Score, and IoU obtained were 95.56%, 79.24%, 97.22%, 76.69%, and 62.18%, respectively. Based on these results, we can conclude that the proposed architecture has been successfully performed segmentation of retinal blood vessels and predicts background pixels very well, indicated by the accuracy and specificity values above 90%. In addition, it is well enough in predicting retinal blood vessels and the harmonization between the sensitivity and specificity values indicated by the sensitivity and F1-Score values above 70%, but the similarity between the image segmentation results and ground truth is still not good, which is below 70%.

Keywords : Retinal blood vessels, Segmentation, U-Net, ResNet, Bi-ConvLSTM

**SEGMENTASI PEMBULUH DARAH PADA CITRA RETINA  
MENGGUNAKAN KOMBINASI ARSITEKTUR *U-NET*, *RESNET*, DAN  
*BIDIRECTIONAL CONVOLUTIONAL LONG SHORT TERM MEMORY***

Oleh:

**Ajeng Islamia Putri  
08011181722002**

**ABSTRAK**

Penambahan lapisan pada arsitektur *U-Net* dapat menyebabkan parameter semakin banyak dan perhitungan komputasi yang berlebihan. Penggunaan *skip connection* pada arsitektur *ResNet* dapat mengatasi permasalahan tersebut, namun dapat menyebabkan hilangnya fitur-fitur penting dari lapisan sebelumnya. *Bi-directional Convolutional Long Short Term Memory* (*Bi-ConvLSTM*) dapat menyimpan informasi sebelumnya dan saat ini dalam jangka waktu yang lama, sehingga fitur-fitur yang hilang dari arsitektur *ResNet* dapat teratasi. Tujuan penelitian ini adalah untuk mengetahui hasil evaluasi kinerja dari kombinasi arsitektur *U-Net*, *ResNet*, dan *Bi-ConvLSTM* pada segmentasi pembuluh darah retina. Ukuran evaluasi yang digunakan adalah akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *IoU*. Data yang digunakan pada penelitian ini adalah dataset DRIVE yang dibagi menjadi 20 data latih dan 20 data uji. Adapun metode yang dilakukan pada penelitian ini adalah pengumpulan data, *pre-procesing* data, implementasi arsitektur, *training*, *testing*, dan evaluasi. Nilai akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *IoU* yang diperoleh secara berturut-turut sebesar 95,56%, 79,24%, 97,22%, 76,69%, dan 62,18%. Berdasarkan hasil tersebut, dapat disimpulkan bahwa arsitektur yang diusulkan telah berhasil melakukan segmentasi pembuluh darah retina dan memprediksi piksel *background* dengan sangat baik, ditunjukkan oleh nilai akurasi dan spesifisitas diatas 90%. Selain itu juga, cukup baik dalam memprediksi pembuluh darah retina dan harmonisasi antara nilai sensitivitas dan spesifisitas yang ditunjukkan oleh nilai sensitivitas dan *F1-Score* diatas 70%, tetapi kemiripan antara citra hasil segmentasi dan *ground truth* masih kurang baik yaitu dibawah 70%.

Kata Kunci: Pembuluh darah retina, Segmentasi, *U-Net*, *ResNet*, *Bi-ConvLSTM*

## DAFTAR ISI

<b>HALAMAN PENGESAHAN .....</b>	Error! Bookmark not defined.
<b>HALAMAN PERSEMBAHAN .....</b>	iii
<b>KATA PENGANTAR.....</b>	iv
<b>ABSTRACT .....</b>	viii
<b>ABSTRAK .....</b>	ix
<b>DAFTAR ISI.....</b>	x
<b>DAFTAR TABEL .....</b>	xii
<b>DAFTAR GAMBAR.....</b>	xiii
<b>BAB I PENDAHULUAN.....</b>	1
1.1 Latar Belakang .....	1
1.2 Perumusan Masalah .....	5
1.3 Pembatasan Masalah.....	5
1.4 Tujuan .....	5
1.5 Manfaat .....	5
<b>BAB II TINJAUAN PUSTAKA.....</b>	6
2.1 Citra Digital .....	6
2.2 <i>Pre-processing</i> Citra .....	8
2.3 <i>Diabetic Retinopathy</i> (DR) .....	10
2.4 Segmentasi Citra .....	10
2.5 <i>Convolutional Neural Networks</i> (CNN) .....	10
2.5.1 <i>Convolution Layer</i> .....	11
2.5.2 <i>Batch Normalization</i> .....	13
2.5.3 <i>Max Pooling</i> .....	14
2.5.4 <i>Concatenate Layer</i> .....	15
2.5.5 <i>Upsampling</i> .....	15
2.5.6 Fungsi Aktivasi .....	16
2.5.7 <i>Loss Function: Binary Cross Entropy</i> .....	17
2.6 <i>U-Net</i> .....	18
2.7 <i>Residual Neural Network (ResNet)</i> .....	19
2.8 <i>Convolution Long Short Term Memory (ConvLSTM)</i> .....	20
2.9 <i>Bidirectional Convolutional Long Short Term Memory (Bi-ConvLSTM)</i> .....	23
2.10 <i>Confusion Matrix</i> .....	24
<b>BAB III METODOLOGI PENELITIAN .....</b>	28
3.1 Tempat .....	28
3.2 Waktu.....	28
3.3 Alat.....	28
3.4 Metode Penelitian .....	29
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	33
4.1 Deskripsi Data.....	33
4.2 <i>Pre-processing</i> Data .....	35
4.3 Segmentasi Citra .....	36

4.4	Implementasi Kombinasi Arsitektur <i>U-Net</i> , <i>ResNet</i> dan <i>Bi-ConvLSTM</i> pada Data Penelitian .....	74
4.5	<i>Training</i> .....	78
4.6	<i>Testing</i> .....	81
4.7	Evaluasi.....	85
4.8	Analisis dan Interpretasi Hasil.....	88
<b>BAB V</b>	<b>KESIMPULAN DAN SARAN .....</b>	<b>90</b>
5.1	Kesimpulan .....	90
5.2	Saran .....	90
	<b>DAFTAR PUSTAKA .....</b>	<b>91</b>

## **DAFTAR TABEL**

Tabel 2.1 <i>Confusion Matrix</i> .....	25
Tabel 2.2 Kategori nilai kinerja arsitektur .....	27
Tabel 4.1 Data latih dan data uji pada dataset DRIVE .....	33
Tabel 4.2 Perbandingan 20 citra data uji, <i>ground truth</i> , dan hasil segmentasi .....	82
Tabel 4.3 Hasil <i>confusion matrix</i> dari tahapan <i>testing</i> .....	84
Tabel 4.4 Hasil evaluasi kinerja model arsitektur untuk setiap data uji.....	87
Tabel 4.5 Perbandingan metode yang diusulkan dengan penelitian lain .....	88

## DAFTAR GAMBAR

Gambar 2.1 Representasi citra digital .....	6
Gambar 2.2 Representasi model warna RGB .....	7
Gambar 2.3 Struktur morfologi citra retina.....	8
Gambar 2.4 Proses <i>convolution layer</i> .....	12
Gambar 2.5 Ilustrasi <i>max pooling</i> $2 \times 2$ dan <i>stride</i> 2 .....	14
Gambar 2.6 Ilustrasi <i>upsampling</i> $2 \times 2$ dan <i>stride</i> 2 .....	15
Gambar 2.7 Grafik fungsi aktivasi .....	17
Gambar 2.8 Arsitektur <i>U-Net</i> .....	18
Gambar 2.9 <i>Residual block</i> pada arsitektur <i>ResNet</i> .....	20
Gambar 2.10 Struktur <i>ConvLSTM</i> .....	21
Gambar 2.11 Arsitektur <i>Bi-ConvLSTM</i> .....	23
Gambar 3.1 Diagram alir tahapan penelitian .....	32
Gambar 4.1 Hasil <i>pre-processing</i> citra .....	35
Gambar 4.2 Proses mempartisi matriks <i>input</i> ke beberapa submatriks .....	46
Gambar 4.3 Ilustrasi proses penggabungan dengan <i>concatenate</i> .....	48
Gambar 4.4 Arsitektur <i>BCResU-Net</i> .....	75
Gambar 4.5 Grafik nilai akurasi pada proses <i>training</i> model <i>BCResU-Net</i> .....	80
Gambar 4.6 Grafik nilai <i>loss</i> pada proses <i>training</i> model <i>BCResU-Net</i> .....	81

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Dalam beberapa tahun terakhir, pembelajaran fitur menggunakan *Deep Learning* (DL) telah terbukti memberikan kinerja yang baik dalam segmentasi citra, klasifikasi citra, dan lainnya (Alom *et al.*, 2019). Metode ini mampu mendekripsi pola dari data yang diberikan kepada model secara otomatis, seperti membuat keputusan atau prediksi berdasarkan data (Soomro *et al.*, 2019). Penerapan DL telah banyak digunakan dalam dunia kesehatan untuk membantu mendekripsi suatu penyakit, salah satunya penyakit *Diabetic Retinopathy* (DR) (Wu, Zou and Zhan, 2019). DR menyebabkan kerusakan pada pembuluh darah retina seperti terjadinya kebocoran dan pertumbuhan pembuluh darah yang abnormal (Gayathri, Gopi and Palanisamy, 2020). Deteksi kelainan pada pembuluh darah retina dapat dilakukan melalui segmentasi pembuluh darah pada citra retina yang dihasilkan dari kamera fundus (Ngo and Han, 2017). Berbagai dataset citra retina telah tersedia dan dapat diakses secara gratis untuk berbagai keperluan, salah satunya dataset *Digital Retinal Images for Vessel Extraction* (DRIVE) (Aslani and Sarnel, 2016). Dataset DRIVE berjumlah 40 data citra retina yang diambil secara acak dari 400 penderita diabetes yang berusia 25 sampai 90 tahun di Belanda yang dapat diakses melalui laman <https://drive.grand-challenge.org/> (Soomro *et al.*, 2019).

Salah satu metode DL yang dapat menangani *input* data yang betipe  $m \times n$  seperti data citra retina adalah *Convolutional Neural Network* (CNN) (Haque and

Neubert, 2020; Desiani *et al.*, 2021). Metode CNN memiliki arsitektur yang sering digunakan untuk segmentasi pembuluh darah pada citra retina yaitu arsitekturnya *U-Net* (Soomro *et al.*, 2018; Wu, Zou and Zhan, 2019). *U-Net* merupakan arsitektur CNN yang sangat popular karena keakuratannya dalam analisis citra medis dan meningkatkan akurasi untuk mendiagnosis suatu penyakit (Du *et al.*, 2020).

Terdapat beberapa ukuran evaluasi kinerja arsitektur yang biasanya digunakan dalam segmentasi pembuluh darah retina diantaranya akurasi, sensitivitas, spesifisitas, *F1-score*, dan *IoU* (Al-masni and Kim, 2021). Akurasi merupakan ukuran untuk melihat keakuratan arsitektur dalam melakukan segmentasi pembuluh darah retina, sensitivitas merupakan ukuran untuk melihat kemampuan arsitektur dalam memprediksi piksel pembuluh darah retina dengan benar, spesifisitas merupakan ukuran untuk melihat kemampuan arsitektur dalam memprediksi piksel bukan pembuluh darah retina dengan benar, *F1-Score* merupakan harmonisasi antara nilai sensitivitas dan spesifisitas, dan *IoU* adalah ukuran kemiripan antara hasil segmentasi yang diprediksi dengan *ground truth* (Haque and Neubert, 2020).

Terdapat beberapa penelitian yang menerapkan arsitektur *U-Net* untuk segmentasi pembuluh darah retina menggunakan dataset DRIVE diantaranya Soomro *et al.* (2018) menerapkan modifikasi arsitektur *U-Net* dengan *Variational Auto-Encoder* (VAE) menghasilkan akurasi 94,8%, sensitivitas 73,9%, dan spesifisitas 95,6%. Soomro *et al.* (2017) menerapkan arsitektur *U-Net* dan PCA menghasilkan nilai akurasi 94,2%, sensitivitas 73,8%, dan spesifisitas 91,2%.

Popat *et al.* (2020) mengkombinasikan arsitektur *U-Net* dan *Genetic Algorithm* (GA) memperoleh nilai akurasi 95%, sensitivitas 75,06%, dan spesifisitas 98,5%. Al-masni and Kim (2021) mengkombinasikan *U-Net* dengan *Inversion Recovery* (IR) menghasilkan nilai akurasi 94,11%, sensitivitas 53,98%, spesifisitas 97,90%, *F1-Score* 61,27% dan *IoU* 44,17%. Namun, nilai sensitivitas yang dihasilkan dari keempat penelitian tersebut masih rendah yaitu kurang dari 76%, serta beberapa penelitian tidak memaparkan nilai *F1-Score* dan *IoU*.

Arsitektur *U-Net* memiliki kelemahan dalam jumlah lapisannya yang sedikit sehingga tidak cukup memperoleh peningkatan kinerja yang lebih baik dari lapisan yang ada (Zhang *et al.*, 2020). Penambahan lapisan secara langsung pada arsitektur *U-Net* dapat membuat parameter yang digunakan semakin banyak dan perhitungan komputasi yang berlebihan, sehingga waktu eksekusi selama proses *training* sangat lama (Bi *et al.*, 2017).

Salah satu arsitektur yang memiliki jaringan yang dalam serta waktu eksekusi yang lebih cepat adalah *Residual Neural Network (ResNet)* (He *et al.*, 2016). Namun, arsitektur ini banyak digunakan dalam masalah klasifikasi citra bukan segmentasi. Arsitektur *ResNet* memanfaatkan *skip connection* sebagai pemetaan identitas yang secara signifikan meminimalkan waktu eksekusi pada saat *training* dan perhitungan komputasi yang lebih ringan, serta meningkatkan akurasi (He *et al.*, 2016). Beberapa penelitian telah menunjukkan hasil kinerja yang sangat baik pada klasifikasi citra menggunakan *ResNet*, diantaranya Celik *et al.* (2020) menerapkan *ResNet* untuk klasifikasi kanker payudara karsinoma duktal invasif dengan akurasi, sensitivitas, spesifisitas, dan *F1-Score* masing-masing sebesar

91,96%, 93,64%, 88,28%, dan 94,11%. Wan, Liang and Zhang (2018) menerapkan *ResNet* untuk mengklasifikasikan penyakit DR menghasilkan akurasi sebesar 90,40%, sensitivitas sebesar 88,78%, dan spesifisitas sebesar 95,56%. Penggunaan *skip connection* pada arsitektur *ResNet* mengakibatkan banyak fitur-fitur yang penting dari lapisan sebelumnya terlewatkan atau hilang (Wu, Zhang and Xie, 2020).

Adapun arsitektur lain yaitu *Bi-directional Convolutional Long Short Term Memory (Bi-ConvLSTM)* yang diajukan oleh Liu *et al.* (2017). Arsitektur ini memiliki kemampuan untuk menyimpan informasi spasial sebelumnya dan saat ini dalam jangka waktu yang lama, sehingga dapat mempelajari lebih banyak fitur (Hanson *et al.*, 2019). Untuk itu, *Bi-ConvLSTM* dapat mengatasi kekurangan dari arsitektur *ResNet*. Penerapan *Bi-ConvLSTM* telah dilakukan oleh Khan and Anwar (2021) untuk segmentasi *optic disc* pada citra retina dengan hasil akurasi dan *F1-score* sebesar 98,99% dan 92%.

Berdasarkan kelebihan dari masing-masing arsitektur *U-Net*, *ResNet* dan *Bi-ConvLSTM*, maka pada penelitian ini mengkombinasikan arsitektur *U-Net*, *ResNet*, dan *Bi-ConvLSTM* untuk memperoleh arsitektur baru yang dapat menghasilkan segmentasi pembuluh darah retina yang lebih baik dengan melihat hasil evaluasi kinerja arsitektur berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *IoU*. Pada penelitian ini arsitektur yang diusulkan diuji menggunakan dataset DRIVE.

## 1.2 Perumusan Masalah

Masalah yang dibahas pada penelitian ini adalah bagaimana hasil evaluasi kinerja dari penerapan kombinasi arsitektur *U-Net*, *ResNet* dan *Bi-ConvLSTM* pada segmentasi pembuluh darah retina.

## 1.3 Pembatasan Masalah

Pembahasan masalah dalam penelitian ini yaitu hanya akan membahas hasil segmentasi pembuluh darah retina menggunakan arsitektur yang diusulkan dan tidak membahas tahapan perbaikan citra awal maupun proses klasifikasi.

## 1.4 Tujuan

Tujuan dari penelitian ini adalah untuk mengetahui hasil evaluasi kinerja dari penerapan kombinasi arsitektur *U-Net*, *ResNet*, dan *Bi-ConvLSTM* pada segmentasi pembuluh darah retina.

## 1.5 Manfaat

1. Dapat diperoleh hasil segmentasi pembuluh darah retina yang lebih akurat dengan menggunakan kombinasi arsitektur *U-Net*, *ResNet* dan *Bi-ConvLSTM*.
2. Dapat digunakan sebagai referensi bagi pihak yang akan melakukan penelitian mengenai segmentasi pembuluh darah retina.
3. Dapat memberikan input yang akurat untuk proses klasifikasi gangguan penyakit DR.

## DAFTAR PUSTAKA

- Al-masni, M. A. and Kim, D. H. (2021) ‘CMM-Net: Contextual Multi-Scale Multi-Level Network for Efficient Biomedical Image Segmentation’, *Scientific Reports*. Nature Publishing Group UK, 11(1), pp. 1–18. doi: 10.1038/s41598-021-89686-3.
- Alom, M. Z. *et al.* (2019) ‘Recurrent Residual U-Net for Medical Image Segmentation’, *Journal of Medical Imaging*, 6(01), p. 1. doi: 10.1117/1.jmi.6.1.014006.
- Aslani, S. and Sarnel, H. (2016) ‘A New Supervised Retinal Vessel Segmentation Method based on Robust Hybrid Features’, *Biomedical Signal Processing and Control*. Elsevier Ltd, 30, pp. 1–12. doi: 10.1016/j.bspc.2016.05.006.
- Azad, R. *et al.* (2019) ‘Bi-Directional ConvLSTM U-Net with Densley Connected Convolutions’, in *Proceedings - 2019 International Conference on Computer Vision Workshop, ICCVW 2019*, pp. 406–415. doi: 10.1109/ICCVW.2019.00052.
- Bali, A. and Singh, S. N. (2015) ‘A Review on The Strategies and Techniques of Image Segmentation’, in *International Conference on Advanced Computing and Communication Technologies*, ACCT, pp. 113–120. doi: 10.1109/ACCT.2015.63.
- Bi, L. *et al.* (2017) ‘Stacked Fully Convolutional Networks with Multi-Channel Learning: Application to Medical Image Segmentation’, *Visual Computer*. Springer Berlin Heidelberg, 33(6–8), pp. 1061–1071. doi: 10.1007/s00371-017-1379-4.
- Celik, Y. *et al.* (2020) ‘Automated Invasive Ductal Carcinoma Detection Based Using Deep Transfer Learning with Whole-Slide Images’, *Pattern Recognition Letters*. Elsevier B.V., 133, pp. 232–239. doi: 10.1016/j.patrec.2020.03.011.
- Chang, Y. and Luo, B. (2019) ‘Bidirectional Convolutional LSTM Neural Network for Remote Sensing Image Super-Resolution’, *Remote Sensing*, 11(20), pp. 1–18. doi: 10.3390/rs11202333.
- Desiani, A. *et al.* (2019) ‘Naive Bayes Classifier for Infant Weight Prediction of Hypertension Mother’, *Journal of Physics: Conference Series*, 1282(1). doi: 10.1088/1742-6596/1282/1/012005.
- Desiani, A. *et al.* (2021) ‘Bi-path Architecture of CNN Segmentation and Classification Method for Cervical Cancer Disorders Based on Pap - smear

- Images', *IAENG International Journal of Computer Science*, 48(3).
- Desiani, A. et al. (2021) 'Handling The Imbalanced Data with Missing Value Elimination Smote in The Classification of The Relevance Education Background with Graduates employment', *IAES International Journal of Artificial Intelligence*, 10(2), pp. 346–354. doi: 10.11591/ijai.v10.i2.pp346-354.
- Desiani, A. et al. (2021) 'Variasi Thresholding untuk Segmentasi Pembuluh Darah Citra Retina', 7(2), pp. 255–262.
- Ding, B., Qian, H. and Zhou, J. (2018) 'Activation Functions and Their Characteristics in Deep Neural Networks', in *The 30th Chinese Control and Decision Conference (2018 CCDC)*, pp. 1836–1841.
- Du, G. et al. (2020) 'Medical Image Segmentation based on U-Net: A Review', *Journal of Imaging Science and Technology*, 64(2), pp. 1–12. doi: 10.2352/J.ImagingSci.Techol.2020.64.2.020508.
- Gayathri, S., Gopi, V. P. and Palanisamy, P. (2020) 'Automated Classification of Diabetic Retinopathy Through Reliable Feature Selection', *Physical and Engineering Sciences in Medicine*. Springer International Publishing, 43(3), pp. 927–945. doi: 10.1007/s13246-020-00890-3.
- Gonzalez, R. C. and Woods, R. E. (2008) *Digital Image Processing (Third Edition)*. United States: Prentice Hall.
- Gonzalez, R. C., Woods, R. E. and Eddins, S. L. (2009) *Digital Image Processing Using Matlab (Second Edition)*. USA: Gatesmark Publishing.
- Guo, T., Dong, J. and Li, H. (2017) 'Simple Convolutional Neural Network on Image Classification', in *IEEE International Conference on Big Data Analysis*, pp. 721–724.
- Hanson, A. et al. (2019) 'Bidirectional convolutional LSTM for the detection of violence in videos', *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11130 LNCS, pp. 280–295. doi: 10.1007/978-3-030-11012-3\_24.
- Haque, I. R. I. and Neubert, J. (2020) 'Deep Learning Approaches to Biomedical Image Segmentation', *Informatics in Medicine Unlocked*. Elsevier Ltd, 18, p. 100297. doi: 10.1016/j.imu.2020.100297.
- He, K. et al. (2016) 'Deep Residual Learning for Image Recognition', in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.

- 770–778. doi: 10.1109/CVPR.2016.90.
- Jiang, Z. *et al.* (2017) ‘Fast, Accurate and Robust Retinal Vessel Segmentation System’, *Biocybernetics and Biomedical Engineering*. Nalecz Institute of Biocybernetics and Biomedical Engineering of the Polish Academy of Sciences, 37(3), pp. 412–421. doi: 10.1016/j.bbe.2017.04.001.
- Kandhasamy, J. P. *et al.* (2020) ‘Diagnosis of Diabetic Retinopathy Using Multi Level Set Segmentation Algorithm with Feature Extraction Using SVM with Selective Features’, *Multimedia Tools and Applications*. Multimedia Tools and Applications, 79(15–16), pp. 10581–10596. doi: 10.1007/s11042-019-7485-8.
- Khan, A. *et al.* (2020) *A Survey of The Recent Architectures of Deep Convolutional Neural Networks, Artificial Intelligence Review*. Springer Netherlands. doi: 10.1007/s10462-020-09825-6.
- Khan, M. K. and Anwar, S. M. (2021) ‘M-Net with Bidirectional ConvLSTM for Cup and Disc Segmentation in Fundus Images’, in *Proceedings - 2020 IEEE EMBS Conference on Biomedical Engineering and Sciences, IECBES 2020*, pp. 472–476. doi: 10.1109/IECBES48179.2021.9398745.
- Kim, K. S. *et al.* (2020) ‘Prediction of Ocean Weather based on Denoising Autoencoder and Convolutional LSTM’, *Journal of Marine Science and Engineering*, 8(10), pp. 1–24. doi: 10.3390/jmse8100805.
- Köse, C. and Ikibaşs, C. (2011) ‘A Personal Identification System Using Retinal Vasculature in Retinal Fundus Images’, *Expert Systems with Applications*, 38(11), pp. 13670–13681. doi: 10.1016/j.eswa.2011.04.141.
- Li, Q. *et al.* (2014) ‘Medical Image Classification with Convolutional Neural Network’, in *2014 13th International Conference on Control Automation Robotics & Vision (ICARCV)*, pp. 10–12.
- Li, Y. *et al.* (2020) ‘Attention based CNN-ConvLstm for Pedestrian Attribute Recognition’, *Sensors*, 20(3), pp. 1–14. doi: 10.3390/s20030811.
- Lian, S. *et al.* (2019) ‘A Global and Local Enhanced Residual U-Net for Accurate Retinal Vessel Segmentation’, *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. IEEE, 14(8), pp. 1–10. doi: 10.1109/tcbb.2019.2917188.
- Liu, Q. *et al.* (2017) ‘Bidirectional-Convolutional LSTM Based Spectral-Spatial Feature Learning for Hyperspectral Image Classification’, *Remote Sensing*, 9(12), pp. 1–18. doi: 10.3390/rs9121330.

- Loffe, S. and Szegedy, C. (2015) ‘Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift’, in *Proceedings of the 32nd International Conference on Machine Learning*, pp. 448–456. doi: 10.1101/17512786.2015.1058180.
- Luque, A. *et al.* (2019) ‘The Impact of Class Imbalance in Classification Performance Metrics based on The Binary Confusion Matrix’, *Pattern Recognition*. Elsevier Ltd, 91, pp. 216–231. doi: 10.1016/j.patcog.2019.02.023.
- Mishra, S. *et al.* (2016) ‘Regularized Discriminant Analysis for Multi-Densor Decision Fusion and Damage Detection with Lamb Waves’, *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016*, 9803(March), p. 98032H. doi: 10.1117/12.2217959.
- Ngo, L. and Han, J. H. (2017) ‘Multi-Level Deep Neural Network for Efficient Segmentation of Blood Vessels in Fundus Images’, *Electronic Letters*, 53(16), pp. 1096–1098. doi: 10.1038/nature16961.
- Orlando, J. I., Prokofyeva, E. and Blaschko, M. B. (2017) ‘A Discriminatively Trained Fully Connected Conditional Random Field Model for Blood Vessel Segmentation in Fundus Images’, *IEEE Transactions on Biomedical Engineering*, 64(1), pp. 16–27. doi: 10.1109/TBME.2016.2535311.
- Paredes, B. R.- and Torr, P. H. S. (2016) ‘Recurrent Instance Segmentation’, in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, pp. 312–329. doi: 10.1007/978-3-319-46466-4\_19.
- Popat, V. *et al.* (2020) ‘GA-based U-Net Architecture Optimization Applied to Retina Blood Vessel Segmentation’, *12th International Joint Conference on Computational Intelligence (IJCCI 2020)*, (Ijcci), pp. 192–199. doi: 10.5220/0010112201920199.
- Ramella, G. and Di Baja, G. S. (2013) ‘A New Technique for Color Quantization based on Histogram Analysis and Clustering’, *International Journal of Pattern Recognition and Artificial Intelligence*, 27(3), pp. 1–17. doi: 10.1142/S0218001413600069.
- Ronneberger, O., Fischer, P. and Brox, T. (2015) ‘U-net: Convolutional networks for biomedical image segmentation’, in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, pp. 234–241. doi: 10.1007/978-3-319-24574-4\_28.
- Shaik, K. B. *et al.* (2015) ‘Comparative Study of Skin Color Detection and

- Segmentation in HSV and YCbCr Color Space', in *Procedia Computer Science*. Elsevier Masson SAS, pp. 41–48. doi: 10.1016/j.procs.2015.07.362.
- Shi, J. *et al.* (2021) 'Improvement of Damage Segmentation Based on Pixel-Level Data Balance Using VGG-Unet', *Applied Sciences (Switzerland)*, 11(2), pp. 1–17. doi: 10.3390/app11020518.
- Shi, X. *et al.* (2015) 'Convolutional LSTM network: A machine learning approach for precipitation nowcasting', *Advances in Neural Information Processing Systems*, pp. 802–810.
- Sonali *et al.* (2019) 'An approach for de-noising and contrast enhancement of retinal fundus image using CLAHE', *Optics and Laser Technology*. Elsevier Ltd, 110, pp. 87–98. doi: 10.1016/j.optlastec.2018.06.061.
- Soomro, T. A. *et al.* (2017) 'Boosting Sensitivity of a Retinal Vessel Segmentation Algorithm with Convolutional Neural Network', *DICTA 2017 - 2017 International Conference on Digital Image Computing: Techniques and Applications*, 2017-Decem, pp. 1–8. doi: 10.1109/DICTA.2017.8227413.
- Soomro, T. A. *et al.* (2018) 'Strided U-Net Model: Retinal Vessels Segmentation using Dice Loss', in *2018 International Conference on Digital Image Computing: Techniques and Applications*, DICTA 2018. IEEE, pp. 1–8. doi: 10.1109/DICTA.2018.8615770.
- Soomro, T. A. *et al.* (2019) 'Deep Learning Models for Retinal Blood Vessels Segmentation: A Review', *IEEE Access*. IEEE, 7, pp. 71696–71717. doi: 10.1109/ACCESS.2019.2920616.
- Wan, S., Liang, Y. and Zhang, Y. (2018) 'Deep Convolutional Neural Networks for Diabetic Retinopathy Detection by Image Classification', *Computers and Electrical Engineering*. Elsevier Ltd, 72, pp. 274–282. doi: 10.1016/j.compeleceng.2018.07.042.
- Wang, S. H. *et al.* (2018) 'Multiple sclerosis identification by 14-layer convolutional neural network with batch normalization, dropout, and stochastic pooling', *Frontiers in Neuroscience*, 12(NOV), pp. 1–11. doi: 10.3389/fnins.2018.00818.
- Wu, C., Zou, Y. and Zhan, J. (2019) 'DA-U-Net: Densely Connected Convolutional Networks and Decoder with Attention Gate for Retinal Vessel Segmentation', *IOP Conference Series: Materials Science and Engineering*, 533(1), pp. 1–7. doi: 10.1088/1757-899X/533/1/012053.

- Wu, K., Zhang, S. and Xie, Z. (2020) ‘Monocular Depth Prediction with Residual DenseASPP Network’, *IEEE Access*, 8(1), pp. 129899–129910. doi: 10.1109/ACCESS.2020.3006704.
- Yahdin, S. *et al.* (2019) ‘Pattern Recognition for Study Period of Student in Mathematics Department with C4.5 Algorithm Data Mining Technique at The Faculty of Mathematics and Natural Science Universitas Sriwijaya’, *Journal of Physics: Conference Series*, 1282(1). doi: 10.1088/1742-6596/1282/1/012014.
- Yahdin, S. *et al.* (2021) ‘Application of the Relief-f Algorithm for Feature Selection in the Prediction of the Relevance Education Background with the Graduate Employment of the Universitas Sriwijaya’, *Computer Engineering and Applications (Comengapp)*, 10(2), pp. 71–80.
- Yamashita, R. *et al.* (2018) ‘Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition’, *Insights into Imaging. Insights into Imaging*, 9(4), pp. 21–30. doi: 10.1007/978-981-15-7078-0\_3.
- Zhang, Z. *et al.* (2020) ‘DENSE-INception U-Net for Medical Image Segmentation’, *Computer Methods and Programs in Biomedicine*. Elsevier B.V., 192, p. 105395. doi: 10.1016/j.cmpb.2020.105395.
- Zhang, Z., Liu, Q. and Wang, Y. (2018) ‘Road Extraction by Deep Residual U-Net’, *IEEE Geoscience and Remote Sensing Letters*, 15(5), pp. 749–753. doi: 10.1109/LGRS.2018.2802944.
- Zhao, G. *et al.* (2019) ‘Multiple Convolutional Layers Fusion Framework for Hyperspectral Image Classification’, *Neurocomputing*. Elsevier B.V., 339, pp. 149–160. doi: 10.1016/j.neucom.2019.02.019.