

**KOMBINASI ARSITEKTUR VGG DAN
DENSE CONNECTED (DENSENET) PADA MODEL
CONVOLUTIONAL NEURAL NETWORK UNTUK
SEGMENTASI PEMBULUH DARAH CITRA RETINA**

SKRIPSI

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

Oleh:

FILDA EFRILIYANTI

08011181722068



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

2021

HALAMAN PENGESAHAN

KOMBINASI ARSITEKTUR VGG DAN *DENSE CONNECTED*
(*DENSENET*) PADA MODEL *CONVOLUTIONAL NEURAL NETWORK*
UNTUK SEGMENTASI PEMBULUH DARAH CITRA RETINA

SKRIPSI

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

Oleh

FILDA EFRILIYANTI

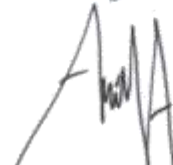
08011181722068

Pembimbing Pembantu



Drs. Sugandi Yahdin, M.M
NIP. 195807271986031003

Indralaya, September 2021
Pembimbing Utama



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

Mengetahui,
Ketua Jurusan Matematika



Drs. Sugandi Yahdin, M.M
NIP. 195807271986031003

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk :

Yang MahaKuasa Allah SubhanahuWaTa'ala

Kedua Orangtuaku Tersayang

Adik-adikku Tercinta,

Keluarga Besarku Tersayang

Semua Guru dan Dosenku

Sahabat-sahabatku Tercinta

Almamaterku

Motto

“Berpikirlah positif, tidak peduli seberapa keras kehidupanmu”

Ali bin Abi Thalib

KATA PENGANTAR

Assalamu'alaikum Wr. Wb.

Segala puji dan syukur kehadirat Tuhan Yang Maha Esa atas segala rahmat dan karunia-Nya yang senantiasa dilimpahkan kepada penulis, sehingga dapat menyelesaikan skripsi ini dengan judul “**KOMBINASI ARSITEKTUR VGG DAN DENSE CONNECTED (DENSENET) MODEL ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK UNTUK SEGMENTASI PEMBULUH DARAH CITRA RETINA**“.

Dengan segala hormat dan kerendahan hati mengucapkan terima kasih yang sedalam-dalamnya kepada Orang Tua, yaitu Bapak **Kusno** dan Ibu **Hayuni** yang telah merawat dan mendidik penulis dengan penuh rasa cinta dan kasih sayang, doa dan perhatiannya untuk penulis selama ini. Skripsi ini dapat selesai tidak terlepas dari bantuan berbagai pihak, baik secara langsung maupun tidak langsung. Untuk itu penulis menyampaikan ucapan terima kasih dan penghargaan kepada :

1. Bapak **Drs. Sugandi Yahdin, M.M** selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya, Pembimbing Pembantu, serta Pembimbing Akademik yang bersedia membimbing, memberi nasihat dan mengarahkan urusan akademik kepada penulis selama belajar di Jurusan Matematika FMIPA Universitas Sriwijaya
2. Ibu **Anita Desiani, M.Kom** selaku Dosen Pembimbing Utama yang bersedia membimbing, nasihat, saran, dan meluangkan waktu di tengah kesibukannya.
3. 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.

4. Bapak **Drs. Endro Setyo Cahyono, M.Si**, Bapak **Dr. Bambang Suprihatin, M.Si**, dan Ibu **Sri Indra Maiyanti, M.Si**, selaku dosen pembahas skripsi yang telah bersedia meluangkan waktu dalam memberikan tanggapan dan saran yang bermanfaat dalam perbaikan skripsi.
5. Seluruh Dosen di Jurusan Matematika Fakultas Matematika Dan Ilmu Pengetahuan Alam Universitas Sriwijaya, dan seluruh pendidik yang telah memberikan ilmu yang sangat bermanfaat kepada penulis selama menempuh pendidikan.
6. **Ibu Hamidah** dan **Pak Irwan** di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya, terima kasih atas bantuannya yang telah diberikan kepada penulis.
7. Kakakku yang selalu mendukung, **Mas Candra, Mbak Ani, Mbak Iin, Bang Ayup** dan **Mas Dika** atas kasih sayang nya.
8. **Keluarga Besarku** terima kasih untuk segala dukungan dan semangat yang telah diberikan kepada penulis.
9. Sahabat sekolah ku dari SMA **Afnania, Ayu Yasifa, Ananda Thalia** yang telah memberi dukungan, semangat dan meluangkan waktu untuk mendengarkan curhatan baik tentang skripsi maupun yang lainnya.
10. Sahabatku dibangku perkuliahan **Ajeng, Elsa, Enyta, Ranil, Calista, Tesya, Ayu, Weli, Feni, Dwi, Muflika, Mila, Momon, Ona** dan **April** atas

kebersamaanya, suka dukanya, canda tawa, nasehat, motivasi, dukungan dan bantuan selama diperkuliahan

11. Kakak-kakak rantauku **Kak Muti, Kak Aka, dan Kak Winda** atas dukungan dan semangat yang diberi kepada penulis
12. Tim bimbingan skripsi **Kak Fatur, Kak Ilham, Yogi, Gibran, dan Zaim** atas bantuan dan kerjasamanya selama penyusunan skripsi
13. Teman, Kakak, dan Adik **Asisten Laboratorium Komputuasi Tahun 2018-2020, BPH Himastik Tahun 2018-2019, BPH LDF KOSMIC Tahun 2018-2019, dan BPH Himastik Tahun 2019-2020** atas pengalaman, dukungan serta canda dan tawa yang diberikan selama berada dalam lingkungan organisasi.
14. Teman-teman satu angkatan **2017**, Kakak-kakak tingkat angkatan **2015, 2016** dan adik-adik tingkat angkatan **2018, 2019, 2020**.
15. Semua pihak yang tidak dapat penulis sebutkan satu persatu yang telah memberikan bantuan dalam menyelesaikan skripsi ini. Semoga semua kebaikan yang diberikan mendapatkan balasan dari Tuhan Yang Maha Esa.

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

Wassalamua'alaikum Wr.Wb

Indralaya, September 2021

Penulis

**COMBINATION OF VGG AND DENSE CONNECTED (DENSENET)
MODEL IN CONVOLUTIONAL NEURAL NETWORK ARSITEKTUR
FOR SEGMENTATION OF BLOOD VESSELS ON RETINAL IMAGES**

By:

**FILDA EFRILIYANTI
08011181722068**

ABSTRACT

The addition of layers to the U-Net architecture will cause more parameters and increase network complexity. The Visual Geometry Group (VGG) architecture has the ability to overcome these problems by using a small convolution filter. To overcome excessive feature learning in VGG, Dense Connected (DenseNet) can be used by directly connecting each layer using input from the previous feature map. In this study, we will combine the advantages of VGG and DenseNet in overcoming the shortcomings of the U-Net architecture for segmenting retinal blood vessels. The results of this study obtained an accuracy value of 95.23%, sensitivity of 79.54%, specificity of 97.52%, F1 Score of 80.95%, and Intersection over Union (IoU) of 68% using the DRIVE dataset. From these results it can be concluded that the proposed architecture has succeeded in segmenting retinal blood vessels and predicting the background very well, indicated by the accuracy and specificity values above 90%. In addition, it can predict retinal blood vessels quite well, seen from the sensitivity value above 70%, and the balance between the sensitivity and specificity values is good, seen from the F1 Score value above 80%, but the similarity between the image segmentation results and ground truth is still not good seen from the IoU value below 70%.

Keywords: Segmentation, Retinal Blood Vessels, U-Net, VGG, DenseNet

**KOMBINASI ARSITEKTUR VGG DAN DENSE CONNECTED
(DENSENET) PADA MODEL CONVOLUTIONAL NEURAL NETWORK
UNTUK SEGMENTASI PEMBULUH DARAH CITRA RETINA**

Oleh:

**FILDA EFRILIYANTI
08011181722068**

ABSTRAK

Penambahan lapisan pada arsitektur *U-Net* akan menyebabkan parameter yang semakin banyak dan meningkatnya kompleksitas jaringan. Arsitektur *Visual Geometry Group* (VGG) memiliki kemampuan mengatasi permasalahan tersebut dengan menggunakan filter konvolusi berukuran kecil. Untuk mengatasi pembelajaran fitur berlebihan pada VGG dapat digunakan *Dense Connected* (*DenseNet*) dengan cara menghubungkan secara langsung setiap lapisannya dengan menggunakan *input* dari peta fitur sebelumnya. Dalam penelitian ini akan mengkombinasikan kelebihan VGG dan *DenseNet* dalam mengatasi kekurangan dari arsitektur *U-Net* untuk melakukan segmentasi pembuluh darah retina. Hasil dari penelitian tersebut diperoleh nilai akurasi sebesar 95,23%, sensitivitas sebesar 79,54%, spesifitas sebesar 97,52%, *F1 Score* sebesar 80,95%, dan *Intersection over Union* (IoU) sebesar 68% dengan menggunakan dataset DRIVE. Dari hasil tersebut dapat disimpulkan bahwa arsitektur yang diajukan telah berhasil melakukan segmentasi pembuluh darah retina dan memprediksi *background* dengan sangat baik ditunjukkan oleh nilai akurasi dan spesifitas diatas 90%. Selain itu juga dapat memprediksi pembuluh darah retina dengan cukup baik dilihat dari nilai sensitivitas diatas 70%, dan keseimbangan antara nilai sensitivitas dan spesifitas sudah baik dilihat dari nilai *F1 Score* diatas 80%, akan tetapi kemiripan antara citra hasil segmentasi dan *ground truth* masih kurang baik dilihat dari nilai IoU dibawah 70%.

Kata Kunci: Segmentasi, Pembuluh Darah Citra Retina, *U-Net*, VGG, *DenseNet*

DAFTAR ISI

HALAMAN PENGESAHAN	ii
HALAMAN PERSEMBAHAN	iii
KATA PENGANTAR	iv
ABSTRACT	vii
ABSTRAK	viii
DAFTAR ISI	ix
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	5
1.3 Pembatasan Masalah.....	5
1.4 Tujuan	6
1.5 Manfaat	6
BAB II TINJAUAN PUSTAKA	7
2.1 Retina	7
2.2 Citra Digital	8
a. Citra Retina	9
b. Citra RGB	9
c. <i>Grayscale</i>	10
2.3 <i>Pre-processing</i> Citra	10
a. <i>Gamma Correction</i>	10
b. <i>Contrast Limited Adaptive Histogram Equalization</i>	11
c. <i>Transformasi Bottom Hat</i>	11
2.4 Segmentasi Citra	11
2.5 <i>Convolutional Neural Network</i>	12
2.5.1 Fungsi Aktivasi	12
2.5.2 <i>Convolution Layer</i>	14
2.5.3 <i>Pooling Layer</i>	16
2.5.4 <i>Batch Normalization</i>	17
2.5.5 <i>Dropout</i>	18
2.5.6 <i>Transposed Convolution</i>	19
2.5.7 <i>Concatenate</i>	20

2.6 <i>U-Net</i>	21
2.7 <i>DenseNet</i>	23
2.8 VGG.....	24
2.9 <i>Binary Cross Entropy</i>	25
2.10 <i>Confusion Matrix</i>	25
BAB III METODOLOGI PENELITIAN	29
3.1 Tempat	29
3.2 Waktu.....	29
3.3 Alat	29
3.4 Metode Penelitian	30
1. Pengumpulan Data	30
2. <i>Pre-processing</i>	30
3. Implementasi Kombinasi VGG dan <i>DenseNet</i> dalam Arsitektur <i>U-Net</i> pada Data Penelitian.....	31
4. <i>Training</i>	31
5. <i>Testing</i>	32
6. Evaluasi.....	32
7. Analisis Hasil Berdasarkan Evaluasi	32
BAB IV HASIL DAN PEMBAHASAN	33
4.1 Diskripsi Data	33
4.2 <i>Pre-processing</i>	35
4.3 Segmentasi Citra.....	36
1. <i>Padding Same</i>	36
2. Operasi Konvolusi.....	37
3. Konvolusi	39
4. <i>ReLU</i>	40
5. <i>Batch Normalization</i>	41
6. <i>Max Pooling</i>	44
7. <i>Transposed Convolutional</i>	46
8. <i>Concatenate</i>	48
9. Fungsi Aktivasi <i>Sigmoid</i>	49
10. <i>Binary Cross Entropy</i>	50
4.4 Implementasi Kombinasi VGG dan <i>DenseNet</i> dalam Arsitektur <i>U-Net</i> pada Data Penelitian	52
4.5 <i>Training</i>	56

4.6 <i>Testing</i>	59
4.7 Evaluasi.....	62
4.8 Analisis Hasil.....	66
BAB V KESIMPULAN DAN SARAN.....	68
5.1 Kesimpulan.....	68
5.2 Saran.....	68
DAFTAR PUSTAKA.....	70

DAFTAR TABEL

Tabel 2.1 <i>Confusion matrix</i> untuk pembuluh darah retina.....	26
Tabel 2.2 Kategori nilai kinerja arsitektur	27
Tabel 4.1 Dataset DRIVE	33
Tabel 4.2 Perbandingan 20 citra hasil segmentasi dan <i>ground truth</i> menggunakan dataset DRIVE.....	59
Tabel 4.3 Hasil <i>confusion matrix</i> data uji DRIVE.....	63
Tabel 4.4 Hasil nilai evaluasi arsitektur arsitektur pada data uji DRIVE	65
Tabel 4.5 Perbandingan arsitektur penelitian dengan peneliti lain	66

DAFTAR GAMBAR

Gambar 2.1	Bagian-bagian retina	7
Gambar 2.2	Representasi citra digital	8
Gambar 2.3	Representasi piksel RGB	10
Gambar 2.4	Fungsi aktivasi <i>ReLU</i>	13
Gambar 2.5	Fungsi aktivasi <i>Sigmoid</i>	13
Gambar 2.6	Ilustrasi <i>convolution layer</i>	15
Gambar 2.7	<i>Max pooling</i>	16
Gambar 2.8	Penerapan lapisan <i>dropout</i>	18
Gambar 2.9	<i>Transposed convolution</i>	20
Gambar 2.10	Ilustrasi proses <i>concatenate</i>	21
Gambar 2.11	Arsitektur <i>U-Net</i> dengan <i>input</i> citra berukuran 572×572	22
Gambar 2.12	<i>Dense block</i>	23
Gambar 2.13	Arsitektur VGG	24
Gambar 3.1	Diagram alir tahapan <i>pre-processing</i>	30
Gambar 4.1	Tahapan <i>pre-processing</i>	35
Gambar 4.2	Proses partisi matriks <i>input</i> dengan <i>max pooling</i>	45
Gambar 4.3	Ilustrasi proses penggabungan matriks dengan <i>concatenate</i>	49
Gambar 4.4	Arsitektur VGG- <i>DenseU-Net</i>	53
Gambar 4.5	Proses <i>training</i> pada arsitektur VGG- <i>DenseU-Net</i>	57
Gambar 4.6	Grafik nilai <i>loss</i> data uji dan validasi pada proses <i>training</i> arsitektur VGG- <i>DenseU-Net</i>	58

Gambar 4.7 Grafik nilai akurasi data uji dan validasi pada proses *training*
arsitektur VGG-DenseU-Net 58

BAB I

PENDAHULUAN

1.1 Latar Belakang

Segmentasi citra adalah suatu teknik dalam proses pengolahan gambar yang dilakukan dengan cara membagi citra ke dalam beberapa wilayah yang berbeda, yaitu objek yang akan diteliti dan *background* (Desiani *et al.*, 2021). Segmentasi citra banyak digunakan dalam berbagai bidang termasuk diantaranya mendeteksi jalan dengan citra satelit dan melakukan diagnosis penyakit menggunakan citra medis (Bali and Singh, 2015). Segmentasi citra medis merupakan langkah pemrosesan yang penting karena dapat digunakan untuk diagnosis penyakit dan perencanaan pengobatan (Chen *et al.*, 2018). Segmentasi citra medis secara manual dilakukan oleh para ahli membutuhkan waktu pengerjaan yang sangat lama dan hasil yang tidak akurat sehingga perlu dilakukan pemeriksaan lebih lanjut (Patil, Deore and Bhusawal, 2013).

Salah satu citra medis yang banyak digunakan untuk segmentasi yaitu retina. Citra retina dapat digunakan untuk melakukan diagnosis, pengobatan, dan skrining berbagai penyakit mata, seperti Glukoma, Miopi dan *Diabetic Retinopathy* (DR) melalui pembuluh darah retina (Imani, Javidi and Pourreza, 2015). Citra retina diperoleh dengan menggunakan kamera fundus digital (Fraz *et al.*, 2012). Citra fundus tersebut biasanya mengalami penurunan kualitas citra dan terdapat masalah kontras yang rendah yang disebabkan oleh *noise* (Sonali *et al.*, 2019). Oleh karena itu, diperlukan tahapan perbaikan kualitas citra dengan tujuan

mempertajam dan mengembalikan gambar terdistorsi dengan cara memperbaiki atribut dan mengurangi *noise* pada citra (Somal, 2020).

Pada beberapa tahun terakhir *Convolutional Neural Network* (CNN) telah banyak berkembang dalam analisa citra medis (Sarvamangala and Kulkarni, 2021) (Popat *et al.*, 2020). Arsitektur CNN yang paling banyak digunakan untuk segmentasi dalam bidang medis yaitu *U-Net* (Ronneberger, Fischer and Brox, 2015; Popat *et al.*, 2020). *U-Net* mempelajari segmentasi dengan *cara end-to-end* yaitu citra *input* akan masuk pada jalur *contracting path (encode)* untuk menangkap informasi berupa fitur dan hasil segmentasi akan keluar pada jalur *expanding path (decode)* yang simetris (Ronneberger, Fischer and Brox, 2015). Keuntungan dari arsitektur ini terletak pada kemampuannya dalam memprediksi setiap piksel piksel gambar secara akurat dan banyak digunakan untuk segmentasi pembuluh darah retina (Popat *et al.*, 2020).

Beberapa penelitian telah menunjukkan hasil yang baik dalam segmentasi pembuluh darah retina, diantaranya Laibacher, Weyde and Jalali, (2019); Popat *et al.*, (2020); Al-masni and Kim, (2021). Laibacher, Weyde and Jalali, (2019) mengkombinasikan arsitektur *U-Net* dan *MobileNetV2* memperoleh nilai akurasi sebesar 96,35% dan *F1 Score* sebesar 80,91% namun tidak menghitung nilai sensitifitas, spesifisitas dan *Intersection over Union* (IoU). Popat *et al.*, (2020) mengkombinasikan antara arsitektur *U-Net* dan algoritma genetika standar menghasilkan nilai akurasi sebesar 95%, spesifitas sebesar 98,5%, *F1 Score* sebesar 80,83%, namun untuk nilai sensitivitas masih tergolong rendah yaitu 75,06%, dan tidak menghitung nilai kinerja berdasarkan IoU. Al-masni and Kim,

(2021) menggabungkan *U-Net* dengan *Inversion Recovery* dan *Contextual Multi-Scale Multi-Level Network* (CMM-NET) menghasilkan nilai akurasi sebesar 96,64%, spesifitas sebesar 98,39%, *F1 Score* sebesar 80,27%, namun untuk nilai sensitivitas dan IoU masih kecil yaitu 78,59% dan 67,08%.

U-Net termasuk jaringan yang tidak dalam karena hanya terdiri dari beberapa lapisan saja (Zhang *et al.*, 2020). Secara khusus jaringan yang dalam akan menghasilkan kinerja yang lebih baik dan dapat mempelajari lebih banyak fitur citra (Mousavi, Schukat and Howley, 2018). Sayangnya penambahan jaringan dalam arsitektur *U-Net* akan membuat parameter semakin banyak dan meningkatkan kompleksitas jaringan (Chen *et al.*, 2018; Zhang *et al.*, 2020)

Salah satu arsitektur CNN yang termasuk jaringan yang dalam yaitu *Visual Geometry Group* (VGG) (Simonyan and Zisserman, 2015). Kelebihan dari arsitektur ini yaitu meskipun termasuk jaringan yang dalam, tetapi tidak akan mempengaruhi kompleksitas jaringan karena menggunakan filter konvolusi yang kecil pada data dengan jumlah besar (Simonyan and Zisserman, 2015; Vignesh *et al.*, 2017). Sayangnya VGG tidak cocok digunakan pada data yang berukuran kecil karena akan menyebabkan jaringan mempelajari fitur-fitur secara berlebihan dan banyak digunakan dalam klasifikasi dibandingkan segmentasi (Vignesh *et al.*, 2017; Kaur and Gandhi, 2019). Beberapa penelitian telah menunjukkan hasil yang baik untuk klasifikasi menggunakan VGG. Khan *et al.*, (2021) menggunakan arsitektur VGG dan lapisan *pooling* piramid spasial untuk klasifikasi penyakit DR. Hasil dari penelitian diperoleh nilai akurasi dan spesifitas yang tinggi yaitu 85% dan 91%, namun untuk nilai *F1 Score* masih tergolong kecil yaitu 59,6%.

Kaur and Gandhi, (2019) menggunakan lapisan VGG sebanyak 16 lapisan, untuk klasifikasi citra otak. Hasil dari penelitian diperoleh nilai akurasi, sensitifitas, dan spesifisitas yang tinggi masing-masing 100%, sayangnya penelitian ini tidak membahas *F1 Score*, dan IoU. Mateen *et al.*, (2019) mengkombinasikan arsitektur VGG dengan dekomposisi analisis tunggal dan analisis komponen prinsip untuk klasifikasi penyakit DR, diperoleh nilai akurasi yang tinggi diatas 92%, namun penelitian ini tidak membahas tentang sensitivitas, spesifisitas, *F1 Score*, dan IoU.

Arsitektur yang dapat mengurangi masalah mempelajari fitur yang berlebihan yaitu *Dense Connected (DenseNet)* (Huang *et al.*, 2017). *DenseNet* menghubungkan setiap lapisannya dengan cara menggabungkan peta fitur pada lapisan sebelumnya (Huang *et al.*, 2017; Wang *et al.*, 2019). Peta fitur tersebut akan dijadikan sebagai *input* untuk lapisan selanjutnya, lalu dikeluarkan dengan kedalaman *input* yang tetap sehingga membuat jumlah total parameter berkurang dan dapat menghindari pembelajaran fitur secara berlebihan (Huang *et al.*, 2017; Wang *et al.*, 2019; Zhang *et al.*, 2020).

Beberapa penelitian telah terbukti sangat akurat melakukan segmentasi pembuluh darah retina menggunakan arsitektur *DenseNet*. Wang *et al.*, (2019) mengkombinasikan *DenseNet* dengan teknik *patching* diperoleh nilai akurasi dan spesifisitas yang besar yaitu 96,09% dan 99,04%, namun sensitivitas yang dihasilkan masih kecil yaitu 75,39%. Cheng *et al.*, (2020) menggabungkan arsitektur *DenseNet* dengan *U-Net* diperoleh nilai akurasi dan spesifisitas yang tinggi yaitu 95,59% dan 98,34%, namun nilai sensitivitas yang dihasilkan masih

rendah yaitu 76,72%. Sayangnya dari kedua penelitian tersebut tidak mengukur kinerja *F1 Score* dan IoU.

Dari kelebihan arsitektur VGG yang mampu mengatasi kedangkalan jaringan dan *DenseNet* yang dapat mengurangi jumlah parameter maka dalam penelitian ini akan memodifikasi kedua arsitektur tersebut dengan menggabungkannya bersama arsitektur *U-Net* (Arsitektur *VGG-DenseU-Net*) untuk melakukan segmentasi pembuluh darah retina secara akurat dengan melihat nilai kinerja berdasarkan akurasi, sensitivitas, spesifisitas, *F1 Score*, dan IoU.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah bagaimana memperoleh alternatif arsitektur baru yang mengkombinasikan kelebihan antara VGG dan *DenseNet* pada arsitektur *U-Net* untuk segmentasi pembuluh darah retina dengan mengukur hasil kinerja berdasarkan akurasi, sensitivitas, spesifisitas, *F1 Score*, dan IoU.

1.3 Pembatasan Masalah

Pembatasan masalah dalam penelitian ini yaitu hanya akan membahas mengenai segmentasi pembuluh darah retina dan tidak membahas tahapan perbaikan kualitas citra ataupun klasifikasi.

1.4 Tujuan

Tujuan dari penelitian ini yaitu memberikan alternatif arsitektur baru yang mengkombinasikan kelebihan VGG dan *DenseNet* kedalam arsitektur *U-Net* pada segmentasi pembuluh darah retina berdasarkan nilai kinerja akurasi, sensitivitas, spesifisitas, *F1 Score*, dan IoU.

1.5 Manfaat

Manfaat dari penelitian ini adalah :

1. Dapat memperoleh hasil segmentasi pembuluh darah retina dengan hasil yang baik dengan menggunakan kombinasi VGG dan *DenseNet* kedalam arsitektur *U-Net*.
2. Dapat dijadikan sebagai *input* untuk klasifikasi penyakit DR
3. Dapat digunakan sebagai referensi untuk melakukan penelitian terkait dengan segmentasi pembuluh darah retina.

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(10191), pp. 1–18. doi: 10.1038/s41598-021-89686-3.
- Albawi, S., Mohammed, T. A. and Al-Zawi, S. (2018) ‘Understanding of A Convolutional Neural Network’, *International Conference on Engineering and Technology, ICET 2017*, pp. 1–6. doi: 10.1109/ICEngTechnol.2017.8308186.
- Atapour-abarghouei, A. and Breckon, T. P. (2019) ‘Monocular Segment-Wise Depth : Monocular Depth Estimation Based on A Semantic Segmentation Prior’, in *2019 IEEE International Conference on Image Processing (ICIP)*. IEEE, pp. 4295–4299.
- Bali, A. and Singh, S. N. (2015) ‘A Review On The Strategies and Techniques of Image Segmentation’, *International Conference on Advanced Computing and Communication Technologies, ACCT, 2015-April*, pp. 113–120. doi: 10.1109/ACCT.2015.63.
- Boss, R. S. C., Thangavel, K. and Daniel, D. A. P. (2013) ‘Automatic Mammogram Image Breast Region Extraction and Removal of Pectoral Muscle’, *International Journal of Science and Engineering Research*, 4(5), pp. 1722–1728. Available at: <http://arxiv.org/abs/1307.7474>.
- Brancati, N. *et al.* (2018) ‘Retinal Vessels Segmentation Based on a Convolutional Neural Network’, in *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, pp. 119–126. doi: 10.1007/978-3-319-75193-1.
- Chen, L. *et al.* (2018) ‘DRINet for Medical Image Segmentation’, *IEEE Transactions on Medical Imaging*, 37(11), pp. 2453–2462. doi: 10.1109/TMI.2018.2835303.
- Cheng, Y. *et al.* (2020) ‘Retinal Blood Vessel Segmentation Based on Densely Connected U-Net’, *Mathematical Biosciences and Engineering*, 17(4), pp. 3088–3108. doi: 10.3934/MBE.2020175.
- Dasgupta, A. and Singh, S. (2017) ‘A Fully Convolutional Neural Network Based Structured Prediction’, *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*, pp. 248–251.
- Desiani, A. *et al.* (2019) ‘Naive Bayes Classifier for Infant Weight Prediction of Hypertension Mother’, *Journal of Physics: Conference Series PAPER*. Palembang, 1282. 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 (IJ-AI)*, 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', *Jurnal Edukasi dan Penelitian Informatika JEPIN*, 7(2), pp. 255–262.
- Fraz, M. M. *et al.* (2012) 'Blood Vessel Segmentation Methodologies in Retinal Images - A Survey', *Computer Methods and Programs in Biomedicine*. Elsevier Ireland Ltd, 108(1), pp. 407–433. doi: 10.1016/j.cmpb.2012.03.009.
- Freund, B. K. *et al.* (2017) *The Retinal Atlas Second Editon*, Elsevier.
- Gonzales, R. C. and Woods, R. E. (2008) *Digital Image Processing Third Editon*. United State of America: Pearson Hall.
- Gonzales, R. C., Woods, R. E. and Eddins, S. L. (2004) *Digital Image Processing Using Matlab*. Landon: Prentice-Hall, Inc.
- Huang, G. *et al.* (2017) 'Densely Connected Convolutional Networks', in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, pp. 2261–2269. doi: 10.1109/CVPR.2017.243.
- Im, D. *et al.* (2020) 'DT-CNN: An Energy-Efficient Dilated and Transposed Convolutional Neural Network Processor for Region of Interest Based Image Segmentation', *IEEE Transactions on Circuits and Systems I: Regular Papers*, 67(10), pp. 3471–3483. doi: 10.1109/TCSI.2020.2991189.
- Imani, E., Javidi, M. and Pourreza, H. R. (2015) 'Improvement of Retinal Blood Vessel Detection Using Morphological Component Analysis', *Computer Methods and Programs in Biomedicine*. Elsevier Ireland Ltd, 118(3), pp. 263–279. doi: 10.1016/j.cmpb.2015.01.004.
- Ioffe, S. and Szegedy, C. (2015) 'Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift', in *Proceedings of the 32 nd International Conference on Machine Learning*. France: JMLR: W&CP, pp. 448–456.
- Jadon, S. (2020) 'A Survey of Loss Functions for Semantic Segmentation', in *2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB 2020*. doi: 10.1109/CIBCB48159.

2020.9277638.

- Kaur, T. and Gandhi, T. K. (2019) ‘Automated Brain Image Classification based on VGG-16 and Transfer Learning’, *Proceedings - 2019 International Conference on Information Technology, ICIT 2019*, pp. 94–98. doi: 10.1109/ICIT48102.2019.00023.
- Kaushik, R. and Kumar, S. (2019) ‘Image Segmentation using Convolutional Neural Network for Image Annotation’, *International Journal Of Scientific & Technology Research*, 8(11), pp. 667–675. doi: 10.1109/ICCES45898.2019.9002121.
- Kushol, R. *et al.* (2017) ‘Contrast Enhancement by Top-Hat and Bottom-Hat Transform with Optimal Structuring Element: Application to Retinal Vessel Segmentation’, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10317, pp. 533–540. doi: 10.1007/978-3-319-59876-5_59.
- Laibacher, T., Weyde, T. and Jalali, S. (2019) ‘M2U-net: Effective and Efficient Retinal Vessel Segmentation for Real-World Applications’, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 2019-June, pp. 115–124. doi: 10.1109/CVPRW.2019.00020.
- Marrugo, A. G. and Millan, M. S. (2011) ‘Retinal Image Analysis : Preprocessing and Feature Extraction’, in *Journal of Physics: Conference Series*, pp. 1–8. doi: 10.1088/1742-6596/274/1/012039.
- Mishra, S. *et al.* (2016) ‘Regularized Discriminant Analysis for Multi-Sensor Decision Fusion and Damage Detection with Lamb Waves’, in *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016*. doi: 10.1117/12.2217959.
- Moccia, S. *et al.* (2018) ‘Blood Vessel Segmentation Algorithms — Review Of Methods, Datasets and Evaluation Metrics’, *Computer Methods and Programs in Biomedicine*. Elsevier B.V., 158, pp. 71–91. doi: 10.1016/j.cmpb.2018.02.001.
- Mousavi, S. S., Schukat, M. and Howley, E. (2018) ‘Deep Reinforcement Learning: An Overview’, *Lecture Notes in Networks and Systems*, 16, pp. 426–440. doi: 10.1007/978-3-319-56991-8_32.
- Nwankpa, C. E. *et al.* (2020) ‘Activation Functions: Comparison of Trends in Practice and Research for Deep Learning’, *2nd International on Computational Sciences and Technologies*.
- Oloumi, F., Rangayyan, R. M. and Ells, A. L. (2014) ‘Measurement of Vessel Width in Retinal Fundus Images of Preterm Infants with Plus Disease’, in *IEEE MeMeA 2014 - IEEE International Symposium on Medical Measurements and Applications, Proceedings*, pp. 2–6. doi: 10.1109/

MeMeA.2014.6860082.

- Padmavathi, K. and Thangadurai, K. (2016) 'Implementation of RGB and Grayscale Images in Plant Leaves Disease Detection - Comparative study', *Indian Journal of Science and Technology*, 9(6), pp. 4–9. doi: 10.17485/ijst/2016/v9i6/77739.
- Patil, D. D., Deore, S. G. and Bhusawal, S. (2013) 'Medical Image Segmentation: A Review', *Ijcsmc*, 2(1), pp. 22–27.
- Pauly, L. *et al.* (2017) 'Deeper Networks for Pavement Crack Detection', in Cheng, M.-Y. (National T. U. of S. *et al.* (eds) *Proceedings of the 34th International Symposium on Automation and Robotics in Construction (ISARC)*. Taipei, Taiwan: Tribun EU, s.r.o., Brno, pp. 479–485. doi: 10.22260/ISARC2017/0066.
- 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.
- Ronneberger, O., Fischer, P. and Brox, T. (2015) 'U-net: Convolutional Networks for Biomedical Image Segmentation', in *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI) 2015*, pp. 234–241. doi: 10.1007/978-3-319-24574-4_28.
- Sarvamangala, D. R. and Kulkarni, R. V. (2021) 'Convolutional Neural Networks in Medical Image Understanding: A Survey', *Evolutionary Intelligence*. Springer Berlin Heidelberg, (0123456789). doi: 10.1007/s12065-020-00540-3.
- 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.
- Simonyan, K. and Zisserman, A. (2015) 'Very Deep Convolutional Networks for Large-Scale Image Recognition', *3rd International Conference on Learning Representations, ICLR 2015*, pp. 1–14.
- Solomon, C. and Breckon, T. (2011) *Fundamentals of digital image processing*. United State of America: John Wiley & Sons, Inc. doi: 10.1007/978-981-10-7272-7_1.
- Somal, S. (2020) 'Image Enhancement Using Local and Global Histogram Equalization Technique and Their Comparison', in, pp. 739–753. doi: 10.1007/978-981-15-0029-9_58.
- 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.* (2019) ‘Deep Learning Models for Retinal Blood Vessels Segmentation: A Review’, *IEEE Access*. IEEE, 7, pp. 71696–71717. doi: 10.1109/ACCESS.2019.2920616.
- Sun, M. *et al.* (2017) ‘Learning Pooling for Convolutional Neural Network’, *Neurocomputing*. Elsevier, 224, pp. 96–104. doi: 10.1016/j.neucom.2016.10.049.
- Turgut, B. (2017) ‘Pearls for Correct Assessment of Optic Disc at Glaucoma Diagnosis’, *US Ophthalmic Review*, 10(02), p. 104. doi: 10.17925/usor.2017.10.02.104.
- Vignesh, K. *et al.* (2017) ‘Abnormal Event Detection on BMTT-PETS 2017 Surveillance Challenge’, *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp. 2161–2168. doi: 10.1109/CVPRW.2017.268.
- Wang, C. *et al.* (2019) ‘Dense U-net Based on Patch-Based Learning for Retinal Vessel Segmentation’, *Entropy*, 21(2), pp. 1–15. doi: 10.3390/e21020168.
- Wang, S. *et al.* (2015) ‘Hierarchical retinal blood vessel segmentation based on feature and ensemble learning’, *Neurocomputing*. Elsevier, 149(PB), pp. 708–717. doi: 10.1016/j.neucom.2014.07.059.
- Wang, S. *et al.* (2018) ‘Multiple Sclerosis Identification by 14-Layer Convolutional Neural Network With Batch Normalization , Dropout , and Stochastic Pooling’, *Frontiers in Neuroscience*, 12(818), pp. 1–11. doi: 10.3389/fnins.2018.00818.
- Xu, Y. *et al.* (2019) ‘Medical Breast Ultrasound Image Segmentation by Machine Learning’, *Ultrasonics*. Elsevier, 91(March 2018), pp. 1–9. doi: 10.1016/j.ultras.2018.07.006.
- 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’, in *Journal of Physics: Conference Series*. Palembang: IOP Publishing. 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.
- Zeng, G. (2020) ‘On The Confusion Matrix in Credit Scoring and Its Analytical Properties’, *Communications in Statistics - Theory and Methods*. Taylor & Francis, 49(9), pp. 2080–2093. doi: 10.1080/03610926.2019.1568485.

- Zhang, Y., Zhao, X. and Liu, P. (2019) 'Multi-Point Displacement Monitoring Based on Full Convolutional Neural Network and Smartphone', *IEEE Access*. IEEE, 7, pp. 139628–139634. doi: 10.1109/ACCESS.2019.2943599.
- 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.