

**SEGMENTASI CITRA RETINA
MENGUNAKAN ARSITEKTUR *RESIDUAL NETWORK*
DAN *CONVOLUTIONAL LONG SHORT-TERM MEMORY***

SKRIPSI

Sebagai Salah Satu Syarat untuk Memperoleh Gelar Sarjana

Sains Bidang Studi Matematika

Oleh:

VALENTINO SIMAMORA

08011282025023



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2024**

SURAT PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan dibawah ini :

Nama Mahasiswa : Valentino Simamora
NIM : 08011282025023
Fakultas/Jurusan : Matematika

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai penentuan persyaratan untuk memperoleh gelar kesarjanaan strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain.

Semua informasi yang dimuat dalam skripsi ini berasal dari penulisan lain baik yang dipublikasikan atau tidak, telah diberikan penghargaan dengan mengutip nama sumber penulis secara benar. Semua isi dari skripsi sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.



Valentino Simamora
NIM. 08011282025023

LEMBAR PENGESAHAN

**SEGMENTASI CITRA RETINA
MENGUNAKAN ARSITEKTUR *RESIDUAL NETWORK* DAN
*CONVOLUTIONAL LONG SHORT-TERM MEMORY***

SKRIPSI

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
Sarjana Sains Bidang Studi Matematika**

Oleh

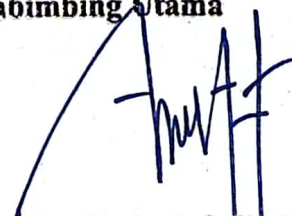
**VALENTINO SIMAMORA
NIM. 08011282025023**

Pembimbing Kedua

**Indralaya, Mei 2024
Pembimbing Utama**



**Dr. Bambang Suprihatin, S.Si., M.Si.
NIP. 19710126 199412 1001**



**Dr. Anita Desiani, S.Si., M.Kom
NIP. 19771211 200312 2002**

**Mengetahui,
Ketua Jurusan Matematika**



**Dr. Dian Cahyawati S. S.Si., M.Si.
NIP. 19730321 200012 2001**

LEMBAR PERSEMBAHAN

**“Orang yang berjalan maju dengan menangis sambil menabur benih,
pasti pulang dengan sorak-sorai sambil membawa berkas-berkasnya”**

(Mazmur 126:6)

“Be Honest, Be Brave, Be Willing”

Skripsi ini kupersembahkan kepada

- Tuhan Yesus Kristus
- Kedua Orang Tuaku
- Adik-adikku
- Keluarga Besarku
- Semua Dosen dan Guruku
- Teman-temanku
- Almamaterku

KATA PENGANTAR

Puji dan Syukur kepada Tuhan Yesus Kristus atas segala kasih, berkat, dan kemurahan-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul **“Segmentasi Citra Retina Menggunakan Arsitektur *Residual Network* dan *Convolutional Long Short-Term Memory*”** dengan baik. Skripsi ini adalah salah satu syarat untuk memperoleh gelar Sarjana Sains Bidang Studi Matematika di Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya.

Dalam penelitian skripsi ini, penulis ingin menyampaikan terima kasih buat Tuhan Yesus Kristus atas segala penyertaan, kekuatan, dan kasih yang diberikan, sehingga penulis dapat melewati tahap demi tahap dalam penulisan skripsi ini. Penulis juga mendapatkan banyak dukungan dan bantuan dari berbagai pihak baik secara moril maupun materil. Oleh karena itu, dengan segala hormat dan kerendahan hati penulis mengucapkan terima kasih kepada:

1. Teristimewa kepada orang tua (Bapak **Baliga Simamora** dan Ibu **Fitri Yani Pardede**) atas seluruh doa, cinta, kasih sayang, didikan, nasihat, dan dukungan yang tidak pernah berhenti untuk keberhasilan penulis.
2. Ibu **Dr. Anita Desiani, S.Si., M.Kom.** dan Bapak **Dr. Bambang Suprihatin, S.Si., M.Si.** selaku Dosen Pembimbing Utama dan Dosen Pembimbing Kedua yang telah bersedia memberikan waktu, pikiran, tenaga, nasihat, motivasi, ide, pengarahan, serta kritik saran yang sangat bermanfaat bagi penulis dalam penyelesaian dan penyempurnaan skripsi ini.
3. Bapak **Prof. Hermansyah, S.Si., M.Si., PhD.** selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya. Ibu **Dr. Dian Cahyawati Sukanda, S.Si., M.Si.** selaku Ketua Jurusan dan Ibu **Des Alwine**

Zayanti, S.Si., M.Si. selaku Sekretaris Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu dalam penyelesaian skripsi ini.

4. Ibu **Irmeilyana, S.Si., M.Si** selaku Dosen Pembimbing Akademik yang telah banyak membantu dan membimbing penulis selama menempuh perkuliahan di Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya. Ibu **Dr. Yuli Andriani, S.Si., M.Si.** dan Ibu **Dra. Ning Eliyati, M.Pd.** selaku Dosen Pembahas dan Penguji yang telah memberikan kritikan, saran, dan tanggapan dalam penyempurnaan skripsi ini. Bapak **Drs. Endro Setyo Cahyono, M.Si.** selaku Ketua Seminar dan Bapak **Drs. Putra BJ bangun, M.Si.** selaku Sekretaris Seminar yang telah bersedia memberikan waktu untuk seminar penulis.
5. **Seluruh Dosen** jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya atas ilmu dan didikan yang diberikan kepada penulis selama menjalani perkuliahan. Bapak **Irwansyah** dan Ibu **Hamidah** yang telah membantu penulis dalam proses administrasi selama masa perkuliahan sampai dengan penyelesaian skripsi ini.
6. Keluarga besar penulis yang sangat disayangi **Putra Simamora, Charol Simamora, Rodenson Simamora,** Bapak **Jonny Simamora,** Ibu **Rosianna Bangun, S.Pd.,** Bapak **Dapot Simamora, S.T.,** Ibu **R. Krista R.P, S.E.** yang telah memberikan doa, kasih sayang, dukungan, motivasi, nasihat, dan semangat kepada penulis.
7. Semua pihak yang tidak dapat disebutkan satu per satu yang telah memberikan doa, dukungan, dan bantuan dalam menyelesaikan skripsi ini.

Penulis menyadari bahwa skripsi ini masih terdapat kekurangan. Oleh sebab itu, penulis mengharapkan kritik dan saran yang membangun dari semua pihak. Akhir kata, semoga skripsi ini dapat bermanfaat bagi pembaca terutama mahasiswa/mahasiswi Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya.

Indralaya, Mei 2024

Penulis

**RETINA IMAGE SEGMENTATION
USING RESIDUAL NETWORK ARCHITECTURE
AND *CONVOLUTIONAL LONG SHORT-TERM MEMORY***

**Valentino Simamora
08011282025023**

ABSTRACT

Diabetic Retinopathy is a condition that often causes blindness in the retina. One characteristic of diabetic retinopathy in the retina is the presence of exudates. Exudates segmentation is one way to detect diabetic retinopathy. A commonly used method for exudates segmentation is Convolutional Neural Network (CNN). One architecture found in CNN methods is U-Net. Even though it is successful in some cases, U-Net sometimes still faces problems such as experiencing overfitting caused by the large number of parameters. To overcome this obstacle, it is necessary to modify the U-Net architecture. This study proposes combining the Residual Network (ResNet) architecture with Convolutional Long Short-Term Memory (ConvLSTM). The encoder part of U-Net is replaced with ResNet to reduce parameters and prevent overfitting. The use of ResNet may result in some features being skipped and not learned. To address this, the decoder part of U-Net is replaced with ConvLSTM so that it can recall the skipped features in the ResNet section. This architecture is capable of producing exudates segmentation with high accuracy. This method has the potential to improve the diagnosis of Diabetic Retinopathy with good segmentation of exudates.

Keywords : Diabetic Retinopathy, Exudates Segmentation, ResNet, ConvLSTM, U-Net

**SEGMENTASI CITRA RETINA
MENGUNAKAN ARSITEKTUR *RESIDUAL NETWORK*
DAN *CONVOLUTIONAL LONG SHORT-TERM MEMORY***

**Valentino Simamora
08011282025023**

ABSTRAK

Diabetic Retinopathy adalah kondisi yang sering menyebabkan kebutaan pada retina. Salah satu ciri retina mengalami *Diabetic Retinopathy* adalah adanya *exudates* pada retina. Segmentasi *exudates* merupakan salah satu cara untuk mendeteksi *Diabetic Retinopathy*. Metode yang sering digunakan untuk melakukan segmentasi *exudates* adalah *Convolutional Neural Network* (CNN). Salah satu arsitektur yang terdapat pada metode CNN adalah *U-Net*. Meskipun berhasil dalam beberapa kasus, *U-Net* terkadang masih menghadapi kendala seperti mengalami *overfitting* yang diakibatkan oleh banyaknya parameter. Untuk mengatasi kendala ini, maka perlu dilakukan modifikasi pada arsitektur *U-Net*. Penelitian ini mengusulkan penggabungan arsitektur *Residual Network* (*ResNet*) dengan *Convolutional Long Short-Term Memory* (*ConvLSTM*). Bagian *encoder* pada *U-Net* digantikan dengan *ResNet* untuk mengurangi parameter dan mencegah *overfitting*. Penggunaan *ResNet* dapat mengakibatkan beberapa fitur terlewat dan tidak dipelajari. Untuk mengatasi hal tersebut, bagian *decoder* pada *U-Net* digantikan dengan *ConvLSTM* sehingga dapat memanggil kembali fitur yang terlewat pada bagian *ResNet*. Arsitektur ini mampu menghasilkan segmentasi *exudates* dengan akurasi yang tinggi. Metode ini berpotensi meningkatkan diagnosis *Diabetic Retinopathy* dengan segmentasi *exudates* yang baik.

Kata Kunci : *Diabetic Retinopathy*, Segmentasi *Exudates*, *ResNet*, *ConvLSTM*, *U-Net*

DAFTAR ISI

<u>LEMBAR PENGESAHAN</u>	ii
<u>LEMBAR PERSEMBAHAN</u>	iii
<u>KATA PENGANTAR</u>	iv
<u>ABSTRACT</u>	vii
<u>ABSTRAK</u>	viii
<u>DAFTAR ISI</u>	ix
<u>DAFTAR TABEL</u>	xi
<u>DAFTAR GAMBAR</u>	xii
<u>BAB I PENDAHULUAN</u>	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah.....	6
1.3 Pembatasan Masalah	6
1.4 Tujuan.....	7
1.5 Manfaat.....	7
<u>BAB II TINJAUAN PUSTAKA</u>	8
2.1 <i>Diabetic Retinopathy</i>	8
2.2 <i>Exudates</i>	8
2.3 Citra Digital.....	9
2.4 <i>Preprocessing Citra</i>	10
2.5 Segmentasi Citra.....	11
2.6 <i>Convolutional Neural Network (CNN)</i>	11
2.6.1 <i>Convolutional Layer</i>	12
2.6.2 <i>Batch Normalization</i>	13
2.6.3 <i>Rectified Linear Unit (ReLU)</i>	14
2.6.4 <i>UpSampling Layer</i>	15
2.6.5 <i>Concatenate layer</i>	16
2.6.6 <i>Loss Function: Binary Cross Entropy</i>	16
2.6.7 <i>Adaptive Momen Estimation (Adam)</i>	17
2.7 <i>Convolutional Long Short-Term Memory (ConvLSTM)</i>	18

<u>2.8 Residual Network (ResNet)</u>	20
<u>2.9 Confusion Matrix</u>	21
<u>BAB III METODOLOGI PENELITIAN</u>	25
<u>3.1 Tempat</u>	25
<u>3.2 Waktu</u>	25
<u>3.3 Alat</u>	25
<u>3.4 Tahapan Penelitian</u>	26
<u>3.4.1 Pengumpulan data</u>	26
<u>3.4.2 Preprocessing</u>	26
<u>3.4.3 Tahap Training</u>	26
<u>3.4.4 Tahap Testing</u>	28
<u>3.4.5 Analisis dan interpretasi hasil</u>	28
<u>BAB IV PEMBAHASAN</u>	29
<u>4.1 Deskripsi Data</u>	29
<u>4.2 Preprocessing</u>	29
<u>4.3 Arsitektur ResNet dan ConvLSTM</u>	30
<u>4.4 Contoh Operasi Manual pada Convolutional Neural Network (CNN)</u>	31
<u>4.4.1 Padding Same</u>	31
<u>4.4.2 Operasi Konvolusi</u>	32
<u>4.4.3 Batch Normalization</u>	34
<u>4.4.4 Rectified Linear Unit (ReLU)</u>	37
<u>4.4.5 UpSampling</u>	38
<u>4.4.6 Concatenate</u>	38
<u>4.4.7 Loss Function: Binary Cross Entropy</u>	39
<u>4.4.8 Adaptive Momen Estimation (Adam)</u>	41
<u>4.5 Implementasi Arsitektur</u>	44
<u>4.6 Analisis dan Interpretasi Hasil</u>	48
<u>BAB IV KESIMPULAN DAN SARAN</u>	50
<u>5.1 Kesimpulan</u>	50
<u>5.2 Saran</u>	50
<u>DAFTAR PUSTAKA</u>	51

DAFTAR TABEL

<u>Tabel 2. 1 <i>Confusion Matrix</i></u>	22
<u>Tabel 2. 2 Kategori Evaluasi Kinerja Model</u>	23
<u>Tabel 4. 1 Data Citra pada Dataset Citra Retina</u>	29
<u>Tabel 4. 2 <i>Confusion Matrix</i> pada Testing Arsitektur <i>ResNet ConvLSTM</i></u>	46
<u>Tabel 4. 3 Perbandingan Nilai Hasil Evaluasi dengan Penelitian Lainnya</u>	49

DAFTAR GAMBAR

<u>Gambar 2. 1 Mata Penderita <i>Diabetic Retinopathy</i> (Saiyar, 2017)</u>	8
<u>Gambar 2. 2 Tampilan warna RGB (Mendrofa, 2021)</u>	9
<u>Gambar 2. 3 Proses Konvolusi</u>	12
<u>Gambar 2. 4 Ilustrasi <i>UpSampling Layer</i></u>	15
<u>Gambar 2. 5 Visualisasi Arsitektur <i>ConvLSTM</i></u>	19
<u>Gambar 2. 6 <i>Residual Block</i> Arsitektur <i>ResNet</i></u>	21
<u>Gambar 4. 1 Proses <i>Preprocessing</i> Citra Retina</u>	30
<u>Gambar 4. 2 Arsitektur <i>ResNet ConvLSTM</i></u>	31
<u>Gambar 4. 3 Grafik Akurasi dan Validasi Akurasi</u>	44
<u>Gambar 4. 4 Grafik <i>Loss</i> dan Validasi <i>Loss</i></u>	45
<u>Gambar 4. 5 Perbandingan Hasil Segmentasi Arsitektur Modifikasi (a) Citra Asli (b) <i>Ground Truth</i> (c) Hasil Segmentasi</u>	46

BAB I

PENDAHULUAN

1.1 Latar Belakang

Retina merupakan salah satu bagian dari organ penglihatan atau mata. Retina memiliki reseptor yang berfungsi untuk meneruskan cahaya yang diterima dalam bentuk bayangan sehingga kita dapat melihat (Suwanda *et al.*, 2022). Retina yang sehat dapat meneruskan cahaya dengan baik, berbeda dengan retina yang menderita *Diabetic Retinopathy*. *Diabetic Retinopathy* merupakan penyebab utama kebutaan pada retina. Salah satu bagian retina yang dapat digunakan untuk mendiagnosis *Diabetic Retinopathy* adalah *exudates*. *Exudates* merupakan bercak-bercak berwarna kuning dengan bentuk yang tidak beraturan dan tersebar pada retina (Jena *et al.*, 2023). Terdapat dua macam *exudates*, yaitu *hard exudates* dan *soft exudates*. *Hard exudates* memiliki gambar yang besar dan jelas, sedangkan *soft exudates* terlihat seperti bitnik-bintik kecil (Kaur *et al.*, 2018). *Exudates* dapat mengganggu proses penerusan cahaya dan mengakibatkan seseorang tidak mampu melihat dengan baik (Joshi *et al.*, 2018). Untuk memperoleh *exudates* yang lebih jelas dan teliti perlu dilakukan segmentasi.

Segmentasi adalah pemisahan suatu bagian dengan bagian lainnya, dimana bagian yang akan diamati dipisahkan dari bagian yang tidak diperlukan (Maison *et al.*, 2019). Segmentasi yang dilakukan secara manual membutuhkan keahlian khusus. Namun, ketersediaan para ahli atau pakar di bidang segmentasi masih terbatas. Selain itu, segmentasi manual membutuhkan tingkat ketelitian yang tinggi

dan memakan banyak waktu (Alqazzaz *et al.*, 2019). Adanya sudut pandang yang bersifat subjektif dari seseorang yang melakukan segmentasi secara manual dapat memengaruhi hasil akhir dari segmentasi tersebut. Segmentasi dapat dilakukan secara otomatis dengan memanfaatkan *machine learning* (Hesamian *et al.*, 2019). Salah satu metode yang berkembang dan populer untuk segmentasi citra pada *machine learning* adalah *Convolutional Neural Network* (CNN) (Soomro *et al.*, 2019). CNN adalah model jaringan saraf yang banyak digunakan dalam pengenalan pola pada data seperti pengolahan citra (Suartika *et al.*, 2016). Salah satu arsitektur yang dapat digunakan dari metode CNN adalah arsitektur *U-Net*.

Arsitektur *U-Net* merupakan salah satu arsitektur yang sering digunakan. Arsitektur *U-Net* memiliki struktur jaringan seperti huruf “U” dimana pada arsitektur terdapat jalur *encoder*, *bridge*, dan *decoder*. Kelebihan dari arsitektur *U-Net* adalah mampu mengembalikan citra dengan piksel yang baik sehingga dapat memberikan hasil kinerja dari segmentasi citra dengan baik (Zioulis *et al.*, 2022). Zabihollahy *et al.* (2019) menerapkan *U-Net* untuk segmentasi *hard exudates* citra retina pada *Indian Diabetic Retinopathy image Dataset* (IDRiD). Namun, akurasi yang diperoleh hanya sebesar 88%. Liu *et al.* (2022) juga menerapkan *U-Net* pada *dataset* yang sama untuk segmentasi *hard exudates*. Namun, penelitian ini memperoleh akurasi yang lebih rendah yaitu hanya sebesar 83%. Kou *et al.* (2020) juga menerapkan *U-Net* pada *dataset* yang sama untuk segmentasi *hard exudates*. Namun, penelitian ini memperoleh hasil akurasi yang lebih rendah dibandingkan dari dua penelitian lainnya yaitu hanya sebesar 81%. Ketiga penelitian ini hanya

mengambil *exudates* yang besar (*hard exudates*) dan belum berhasil mendeteksi *exudates* yang kecil atau halus (*soft exudates*).

Arsitektur *U-Net* dikenal sebagai arsitektur dengan jumlah parameter yang besar. Parameter yang besar disebabkan oleh *layer* yang banyak, sehingga semakin banyak *layer* maka akan semakin besar parameter yang dihasilkan (Wang, 2020). Salah satu bagian yang menghasilkan parameter dalam jumlah besar pada *U-Net* adalah *encoder*. *Layer* pada *encoder U-Net* terdiri atas banyak blok konvolusi secara berulang sehingga dapat menghasilkan parameter dalam jumlah besar. Jika parameter terlalu besar pada model pembelajaran dapat mengakibatkan proses pembelajaran menjadi *overfitting* (Lei *et al.*, 2020). *Overfitting* adalah kejadian dimana suatu arsitektur sangat baik mengenali pola yang sudah dilatih tetapi tidak mampu mengenali pola untuk data baru yang belum pernah dilatih (Salehinejad *et al.*, 2019).

Arsitektur yang menghasilkan parameter lebih sedikit dibandingkan dengan *U-Net* adalah *ResNet*. Berbeda dengan *U-Net*, *ResNet* adalah arsitektur yang umum digunakan untuk melakukan klasifikasi (Ridhovan *et al.*, 2022). Beberapa penelitian telah menggabungkan *ResNet* dengan *U-Net* dalam proses segmentasi seperti lidah, otak, hati dan lain lain (Lin *et al.*, 2018, Shehab *et al.*, 2021, dan UI Haq *et al.*, 2021).

Berbeda dengan *U-Net* yang menggunakan *max-pooling* pada proses konvolusinya. *ResNet* tidak menerapkan *max-pooling* atau *downsampling* di dalam setiap lapisannya seperti *U-Net*. Sebagai gantinya, *ResNet* menggunakan *residual block* pada proses konvolusinya untuk mengurangi jumlah parameter. *Residual*

block terdiri dari dua cabang utama yaitu jalur identitas (*identity path*) dan jalur residu (*residual path*). Jalur identitas (*identity path*) berguna untuk mengirimkan *input* langsung ke lapisan keluaran *residual block*. Jalur residu (*residual path*) adalah jalur yang memungkinkan jaringan untuk mempelajari perbedaan atau residu antara *input* dan *output* yang diinginkan (Liu *et al.*, 2020). Penggunaan *residual block* ini mengakibatkan parameter yang digunakan pada *ResNet* lebih sedikit dibandingkan dengan *U-Net*.

Penelitian yang dilakukan oleh Zong *et al.* (2020) menerapkan *residual nets* pada *U-Net* untuk melakukan segmentasi *exudates* memperoleh nilai akurasi sebesar 97%. Kou *et al.* (2020) menerapkan *residual* pada *U-Net* untuk melakukan segmentasi *exudates* pada *dataset* IDRiD memperoleh nilai akurasi sebesar 99%. Abbasi *et al.* (2017) menerapkan *residual nets (ResNet)* untuk melakukan segmentasi *exudates* memperoleh nilai akurasi hanya sebesar 81%. Namun ketiga penelitian tersebut melakukan segmentasi hanya pada *exudates* yang besar (*hard exudates*). Meskipun *ResNet* lebih ringan karena memanfaatkan *residual block*, namun *residual block* juga dapat memberikan efek negatif yaitu beberapa fitur akan terlewat. Beberapa fitur dapat terlewat karena pengaruh dari kompresi informasi. Kompresi informasi ini terjadi ketika fitur melalui lapisan dengan penurunan jumlah kernel. Semakin banyak kernel yang berkurang, maka akan semakin banyak fitur yang hilang atau terlewat. Jika fitur-fitur yang terlewat merupakan yang penting, maka model akan kehilangan fitur-fitur yang sangat diperlukan pada model pembelajaran. Arsitektur yang mampu memanggil kembali fitur-fitur yang terlewat adalah *Convolutional Long Short-Term Memory (ConvLSTM)*.

ConvLSTM adalah arsitektur yang menggabungkan lapisan konvolusi dengan sel memori jangka panjang. Kelebihan arsitektur *ConvLSTM* mampu menyimpan informasi sebelumnya dan saat ini dalam jangka waktu lama. Kemampuan ini didukung oleh struktur *ConvLSTM* yang terbagi menjadi tiga bagian yaitu *forget gate*, *input gate*, dan *output gate*. *Forget gate* berfungsi untuk melupakan fitur yang tidak diperlukan atau tidak dapat dikenali. *Input gate* berfungsi untuk mencari dan memasukkan fitur yang diperlukan, baik yang tersedia ataupun yang terlewat pada bagian *encoder* (Liu *et al.*, 2020). Kemampuan ini membuat *ConvLSTM* dapat mempelajari lebih banyak fitur (Li *et al.*, 2021). Lopes, (2020) menerapkan *ConvLSTM* dalam melakukan segmentasi pada *hard exudates* citra retina dan memperoleh akurasi sebesar 95%. Ashir *et al.* (2021) menerapkan *ConvLSTM* dalam melakukan segmentasi pada *hard exudates* citra retina. Penelitian ini juga hanya memperoleh akurasi sebesar 86%. Shenavarmasouleh *et al.* (2021) menerapkan *ConvLSTM* pada R-CNN dalam melakukan segmentasi *exudates* citra retina. Namun, penelitian ini memperoleh akurasi yang lebih rendah yaitu hanya sebesar 84%. Kekurangan dari *ConvLSTM* adalah membutuhkan memori yang sangat besar. Penggunaan *forget gate*, *input gate*, dan *output gate* dalam menyimpan informasi pada jangka waktu lama mengakibatkan terjadinya penumpukan informasi. Untuk mengatasi penumpukan tersebut, maka dibutuhkan juga memori yang banyak dalam menjalankan proses komputasi.

Penelitian ini mengusulkan penggabungan arsitektur *ResNet* dengan *ConvLSTM* yang digunakan untuk melakukan segmentasi *exudates* pada citra retina. Arsitektur ini melibatkan tiga arsitektur yaitu *U-Net*, *ResNet*, dan

ConvLSTM. *Encoder* pada *U-Net* diganti dengan menggunakan *ResNet*. Hal ini dilakukan agar parameter pada bagian *encoder* menjadi lebih ringan dan terhindar dari *overfitting*. *Bridge* pada *U-Net* digunakan untuk menghubungkan bagian *encoder* dengan *decoder*. *Decoder* pada *U-Net* diganti dengan menggunakan *ConvLSTM*. Penggunaan *ConvLSTM* bertujuan agar fitur yang terlewat pada bagian *encoder* dapat dipanggil kembali. Untuk mengukur keberhasilan kombinasi arsitektur ini, hasil pengujian *training* akan diukur dengan menggunakan akurasi, sensitivitas, spesifisitas, dan *F1-Score*.

1.2 Perumusan Masalah

Bagaimana cara mengatasi kelemahan *U-Net* dengan menggunakan arsitektur *ResNet* dan *ConvLSTM* dalam menentukan *exudates* pada segmentasi citra retina berdasarkan nilai akurasi, sensitivitas, spesifisitas, dan *F1-Score*.

1.3 Pembatasan Masalah

Pembatasan masalah dalam penelitian ini sebagai berikut:

1. Penelitian ini hanya menggunakan *dataset* yang diperoleh dari IDRiD.
2. Kriteria penilaian yang dilakukan dalam segmentasi citra retina berdasarkan nilai akurasi, sensitivitas, spesifisitas, dan *F1-Score*.

1.4 Tujuan

Tujuan dari penelitian ini untuk mengetahui cara mengatasi kelemahan *U-Net* dengan menggunakan arsitektur *ResNet* dan *ConvLSTM* dalam menentukan *exudates* pada segmentasi citra retina berdasarkan nilai akurasi, sensitivitas, spesifisitas, dan *F1-Score*.

1.5 Manfaat

Manfaat dari hasil penelitian ini sebagai berikut:

1. Memperoleh model yang dapat melakukan segmentasi *exudates* pada citra retina dengan menerapkan kombinasi arsitektur *ResNet* dan *ConvLSTM*.
2. Dapat digunakan sebagai referensi penelitian mengenai segmentasi citra retina.

DAFTAR PUSTAKA

- Abbasi-Sureshjani, S., Dashtbozorg, B., ter Haar Romeny, B. M., & Fleuret, F. (2017). Boosted exudate segmentation in retinal images using residual nets. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10554 LNCS, 210–218. https://doi.org/10.1007/978-3-319-67561-9_24
- Alqazzaz, S., Sun, X., Yang, X., & Nokes, L. (2019). Automated brain tumor segmentation on multi-modal MR image using SegNet. *Computational Visual Media*, 5(2), 209–219. <https://doi.org/10.1007/s41095-019-0139-y>
- Ashir, A. M., Ibrahim, S., Abdulghani, M., Ibrahim, A. A., & Anwar, M. S. (2021). Diabetic Retinopathy Detection Using Local Extrema Quantized Haralick Features with Long Short-Term Memory Network. *International Journal of Biomedical Imaging*, 2021. <https://doi.org/10.1155/2021/6618666>
- Ortega, O. J. H. J. (2020). Analysis of Performance of Classification Algorithms in Mushroom Poisonous Detection using Confusion Matrix Analysis. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(1.3), 451–456. <https://doi.org/10.30534/ijatcse/2020/7191.32020>
- Desiani, A., Erwin, M., Suprihatin, B., Yahdin, S., Putri, A. I., & Husein, F. R. (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), 1–9.
- Erwin, Putra, H. K., Suprihatin, B., & Ramadhini, F. (2022). A Hybrid CLAHE-GAMMA Adjustment and Densely Connected U-NET for Retinal Blood Vessel Segmentation using Augmentation Data. *Engineering Letters*, 30(2), 485–493.
- Fan, Z., Lin, H., Li, C., Su, J., Bruno, S., & Loprencipe, G. (2022). Use of Parallel ResNet for High-Performance Pavement Crack Detection and Measurement. *Sustainability (Switzerland)*, 14(3). <https://doi.org/10.3390/su14031825>
- Fauzi, A., & Lubis, L. E. (2023). Optimization of retinal blood vessel segmentation based on Gabor filters and particle swarm optimization. *Indonesian Journal of Electrical Engineering and Computer Science*, 29(3), 1590–1596. <https://doi.org/10.11591/ijeecs.v29.i3.pp1590-1596>

- Fei, C., Wen, J., Han, L., Huang, B., & Yan, C. (2022). Optimizable Image Segmentation Method with Superpixels and Feature Migration for Aerospace Structures. *Aerospace*, 9(8). <https://doi.org/10.3390/aerospace9080465>
- Hagenmuller, P., Chambon, G., Lesaffre, B., Flin, F., & Naaim, M. (2013). Energy-based binary segmentation of snow microtomographic images. *Journal of Glaciology*, 59(217), 859–873. <https://doi.org/10.3189/2013JoG13J035>
- Hesamian, M. H., Jia, W., He, X., & Kennedy, P. (2019). Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. *Journal of Digital Imaging*, 32(4), 582–596. <https://doi.org/10.1007/s10278-019-00227-x>
- Jena, P. K., Khuntia, B., Palai, C., Nayak, M., Mishra, T. K., & Mohanty, S. N. (2023). A Novel Approach for Diabetic Retinopathy Screening Using Asymmetric Deep Learning Features. *Big Data and Cognitive Computing*, 7(1). <https://doi.org/10.3390/bdcc7010025>
- Joshi, S., & Karule, P. T. (2018). Detection of hard exudates based on morphological feature extraction. *Biomedical and Pharmacology Journal*, 11(1), 215–225. <https://doi.org/10.13005/bpj/1366>
- Kaur, J., & Mittal, D. (2018). A generalized method for the segmentation of exudates from pathological retinal fundus images. *Biocybernetics and Biomedical Engineering*, 38(1), 27–53. <https://doi.org/10.1016/j.bbe.2017.10.003>
- Kou, C., Li, W., Yu, Z., & Yuan, L. (2020). An enhanced residual u-net for microaneurysms and exudates segmentation in fundus images. *IEEE Access*, 8, 185514–185525. <https://doi.org/10.1109/ACCESS.2020.3029117>
- Lei, T., Zhou, W., Zhang, Y., Wang, R., Meng, H., & Nandi, A. K. (2020). LIGHTWEIGHT V-NET FOR LIVER SEGMENTATION School of Electronic Informataion and Artificial Intelligence , Shaanxi University of Science and Technology , Department of Electronic and Computer Engineering , Brunel University London , Uxbridge , Middlesex , UB. *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 1379–1383.
- Li, J., Ou, X., Shen, N., Sun, J., Ding, J., Zhang, J., Yao, J., & Wang, Z. (2021). Study on strategy of CT image sequence segmentation for liver and tumor based on U-Net and Bi-ConvLSTM. *Expert Systems with Applications*, 180(333), 115008. <https://doi.org/10.1016/j.eswa.2021.115008>

- Li, Y., Liu, D., Li, H., Li, L., Wu, F., Zhang, H., & Yang, H. (2018). Convolutional Neural Network-Based Block Up-Sampling for Intra Frame Coding. *IEEE Transactions on Circuits and Systems for Video Technology*, 28(9), 2316–2330. <https://doi.org/10.1109/TCSVT.2017.2727682>
- Lian, S., Li, L., Lian, G., Xiao, X., Luo, Z., & Li, S. (2021). A Global and Local Enhanced Residual U-Net for Accurate Retinal Vessel Segmentation. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 18(3), 852–862. <https://doi.org/10.1109/TCBB.2019.2917188>
- Lin, B., Xie, J., Li, C., & Qu, Y. (2018). Deeptongue: Tongue segmentation via resnet. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings, 2018-April*, 1035–1039. <https://doi.org/10.1109/ICASSP.2018.8462650>
- Lin, Z., Ji, K., Leng, X., & Kuang, G. (2019). Squeeze and Excitation Rank Faster R-CNN for Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*, 16(5), 751–755. <https://doi.org/10.1109/LGRS.2018.2882551>
- Liu, S., Wang, D., & Wang, X. (2022). GLER-Unet: An ensemble network for hard exudates segmentation. *ITM Web of Conferences*, 47, 01012. <https://doi.org/10.1051/itmconf/20224701012>
- Liu, W., Wu, G., Ren, F., & Kang, X. (2020). DFF-ResNet: An insect pest recognition model based on residual networks. *Big Data Mining and Analytics*, 3(4), 300–310. <https://doi.org/10.26599/BDMA.2020.9020021>
- Lopes, A. P. R. (2020). *Study of Deep Neural Network architectures for medical image segmentation*, 7, 80-86.
- Maison, Lestari, T., & Luthfi, A. (2019). Retinal Blood Vessel Segmentation using Gaussian Filter. *Journal of Physics: Conference Series*, 1376(1). <https://doi.org/10.1088/1742-6596/1376/1/012023>
- Mendrofa, Y. M. S. (2021). Segmentasi Citra Gesture Tangan Berbasis Ruang Warna HSV. *Infact Ukrin*, 6(2), 35–52.
- Mishra, S., Vanli, O. A., Huffer, F. W., & Jung, S. (2016). Regularized discriminant analysis for multi-sensor decision fusion and damage detection with Lamb waves. *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016*, 9803(850), 98032H. <https://doi.org/10.1117/12.2217959>

- Mohan, V. M., Kanaka Durga, R., Devathi, S., & Srujan Raju, K. (2016). Image processing representation using binary image; grayscale, color image, and histogram. *Advances in Intelligent Systems and Computing*, 381, 353–361. https://doi.org/10.1007/978-81-322-2526-3_37
- Önder, M., Evli, C., Türk, E., Kazan, O., Bayrakdar, İ. Ş., Çelik, Ö., Costa, A. L. F., Gomes, J. P. P., Ogawa, C. M., Jagtap, R., & Orhan, K. (2023). Deep-Learning-Based Automatic Segmentation of Parotid Gland on Computed Tomography Images. *Diagnostics*, 13(4), 1–10. <https://doi.org/10.3390/diagnostics13040581>
- Prasad, D. K., Vibha, L., & Venugopal, K. R. (2016). *Early detection of diabetic retinopathy from digital retinal fundus images*. December, 240–245. <https://doi.org/10.1109/raics.2015.7488421>
- Purwono, Ma'arif, A., Rahmani, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & Haq, Q. M. U. (2022). Understanding of Convolutional Neural Network (CNN): A Review. *International Journal of Robotics and Control Systems*, 2(4), 739–748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Putra, I. M. A. D., Maysanjaya, I. M. D., & Kesiman, M. W. A. (2023). Pendekatan Berbasis U-Net untuk Segmentasi Hard Exudate dalam Citra Fundus Retina. *INSERT: Information System and Emerging Technology Journal*, 4(1), 26–36.
- Ridhovan, A., & Suharso, A. (2022). Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum. *JIPi (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(1), 58–65. <https://doi.org/10.29100/jipi.v7i1.2410>
- Ruby, U. (2020). Binary cross entropy with deep learning technique for Image classification. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(4), 5393–5397. <https://doi.org/10.30534/ijatcse/2020/175942020>
- Saiyar, H. (2017). Klasifikasi Retinopati Diabetes Dengan Metode Neural Network. *Journal Paradigma*, 19(2), 92–101.
- Sajeev, S., Bajger, M., & Lee, G. (2015). Segmentation of Breast Masses in Local Dense Background Using Adaptive Clip Limit-CLAHE. *2015 International Conference on Digital Image Computing: Techniques and Applications, DICTA 2015*. <https://doi.org/10.1109/DICTA.2015.7371305>
- Salehinejad, H., & Valaee, S. (2019). Ising-dropout: A Regularization Method for

- Training and Compression of Deep Neural Networks. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 2019-May, 3602–3606. <https://doi.org/10.1109/ICASSP.2019.8682914>
- Shehab, L. H., Fahmy, O. M., Gasser, S. M., & El-Mahallawy, M. S. (2021). An efficient brain tumor image segmentation based on deep residual networks (ResNets). *Journal of King Saud University - Engineering Sciences*, 33(6), 404–412. <https://doi.org/10.1016/j.jksues.2020.06.001>
- Shenavarmasouleh, F., Mohammadi, F. G., Amini, M. H., Taha, T., Rasheed, K., & Arabnia, H. R. (2021). *DRDrV3: Complete Lesion Detection in Fundus Images Using Mask R-CNN, Transfer Learning, and LSTM*. 1–13. <http://arxiv.org/abs/2108.08095>
- Sonali, Sahu, S., Singh, A. K., Ghreera, S. P., & Elhoseny, M. (2019). An approach for de-noising and contrast enhancement of retinal fundus image using CLAHE. *Optics and Laser Technology*, 110, 87–98. <https://doi.org/10.1016/j.optlastec.2018.06.061>
- Soomro, T. A., Afifi, A. J., Zheng, L., Soomro, S., Gao, J., Hellwich, O., & Paul, M. (2019). Deep Learning Models for Retinal Blood Vessels Segmentation: A Review. *IEEE Access*, 7, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>
- Suartika E. P, I Wayan, Wijaya Arya Yudhi, S. R. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101. *Jurnal Teknik ITS*, 5(1), 76. <http://repository.its.ac.id/48842/>
- Suwanda, A. E., & Dwi Juniati. (2022). Klasifikasi Penyakit Mata Berdasarkan Citra Fundus Retina Menggunakan Dimensi Fraktal Box Counting Dan Fuzzy K-Means. In *Halaman* (Vol. 10).
- Uddin, M. J., Li, Y., Sattar, M. A., Nasrin, Z. M., & Lu, C. (2022). Effects of Learning Rates and Optimization Algorithms on Forecasting Accuracy of Hourly Typhoon Rainfall: Experiments With Convolutional Neural Network. *Earth and Space Science*, 9(3). <https://doi.org/10.1029/2021EA002168>
- Ul Haq, M. N., Irtaza, A., Nida, N., Shah, M. A., & Zubair, L. (2021). Liver Tumor Segmentation using Resnet based Mask-R-CNN. *Proceedings of 18th International Bhurban Conference on Applied Sciences and Technologies, IBCAST* 2021, 276–281. <https://doi.org/10.1109/IBCAST51254.2021.9393194>

- Bindhu, V. (2019). Biomedical Image Analysis Using Semantic Segmentation. *Journal of Innovative Image Processing*, 1(02), 91–101. <https://doi.org/10.36548/jiip.2019.2.004>
- Vyas, A., Yu, S., & Paik, J. (2018). Fundamentals of digital image processing. In *Signals and Communication Technology* (pp. 3–11). Springer. https://doi.org/10.1007/978-981-10-7272-7_1
- Wang, C., Sun, J., Xu, W., & Chen, X. (2019). Depth learning standard deviation loss function. *Journal of Physics: Conference Series*, 1176(3). <https://doi.org/10.1088/1742-6596/1176/3/032050>
- Wang, W. (2020). *Using UNet and PSPNet to explore the reusability principle of CNN parameters*. <http://arxiv.org/abs/2008.03414>
- Wang, Y., Sun, L., & Peng, D. (2022). A Multihead ConvLSTM for Time Series Classification in eHealth Industry 4.0. *Wireless Communications and Mobile Computing*, 2022. <https://doi.org/10.1155/2022/8773900>
- Wu, S., Li, G., Deng, L., Liu, L., Wu, D., Xie, Y., & Shi, L. (2019). L1 -Norm Batch Normalization for Efficient Training of Deep Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 30(7), 2043–2051. <https://doi.org/10.1109/TNNLS.2018.2876179>
- Zioulis, N., Albanis, G., Drakoulis, P., Alvarez, F., Zarpalas, D., & Daras, P. (2022). Hybrid Skip: A Biologically Inspired Skip Connection for the UNet Architecture. *IEEE Access*, 10, 53928–53939. <https://doi.org/10.1109/ACCESS.2022.3175864>
- Zong, Y., Chen, J., Yang, L., Tao, S., Aoma, C., Zhao, J., & Wang, S. (2020). U-net based method for automatic hard exudates segmentation in fundus images using inception module and residual connection. *IEEE Access*, 8, 167225–167235. <https://doi.org/10.1109/ACCESS.2020.3023273>