

**SEGMENTASI *EXUDATE* PADA CITRA RETINA PENYAKIT
DIABETIC RETINOPATHY MENGGUNAKAN MODIFIKASI
ARSITEKTUR *U-NET*, *DENSE BLOCK*, DAN
*CONVOLUTIONAL LONG SHORT-TERM MEMORY***

SKRIPSI

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

Oleh :

NIKEN AYUPUTRI

NIM 08011182126012



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2025**

LEMBAR PENGESAHAN

**SEGMENTASI *EXUDATE* PADA CITRA RETINA PENYAKIT
DIABETIC RETINOPATHY MENGGUNAKAN MODIFIKASI
ARSITEKTUR *U-NET*, *DENSE BLOCK*, DAN
*CONVOLUTIONAL LONG SHORT-TERM MEMORY***

SKRIPSI

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

Oleh

NIKEN AYUPUTRI

NIM. 08011182126012

Pembimbing Kedua



Prof. Yulia Resti, S.Si., M.Si., Ph.D
NIP. 197307191997022001

Indralaya, 22 Mei 2025

Pembimbing Utama



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

**Mengetahui,
Ketua Jurusan Matematika**



Dr. Dian Cahyawati Sukanda, S.Si., M.Si.
NIP. 197303212000122001

PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Niken Ayuputri

NIM : 08011182126012

Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain. Semua informasi yang dimuat didalam skripsi ini yang berasal dari penulis lain baik yang dipublikasi atau telah diberikan penghargaan dengan mengutip nama sumber penulis yang secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, 22 Mei 2025

Penulis



Niken Ayuputri

NIM. 08011182126012

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk:

Yang Maha Kuasa Allah Subhanahu Wa Ta'ala,

Kedua orang tuaku tercinta,

Saudara laki-laki dan perempuanku,

Keluarga besarku,

Semua guru dan dosenku,

Sahabat-sahabatku,

Almamaterku.

Motto

“Maka sesungguhnya bersama kesulitan itu ada kemudahan.

Sesungguhnya bersama kesulitan itu ada kemudahan (Q.S Al-Insyirah, 94: 5-6)”

KATA PENGANTAR

Puji syukur kehadiran Allah *Subhana Wa Ta'ala* yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Segmentasi *Exudate* Pada Citra Retina Penyakit *Diabetic Retinopathy* Menggunakan Modifikasi Arsitektur *U-Net*, *Dense Block* dan *Convolutional Long Short-Term Memory*”. Skripsi ini ditulis sebagai salah satu syarat memperoleh gelar sarjana Sains bidang studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa skripsi ini tidak mungkin terselesaikan tanpa adanya semangat, dukungan, bantuan, bimbingan dan nasihat yang diberikan berbagai pihak selama proses penyusunan ini berlangsung. Penulis mengucapkan terima kasih sebesar-besarnya kepada orang tua tercinta, Ayahku **Hery Jatmiko** dan Ibuku **Yuliati** yang tidak pernah berhenti berjuang dan memberikan yang terbaik untukku sebagai putrinya. Terima kasih karena tak pernah lelah mendidik, menasehati, membimbing, mendukung, dan terus mendoakan. Penulis juga ingin menyampaikan ucapan terima kasih kepada sebesar-besarnya dan penghargaan setinggi-tingginya kepada:

1. Bapak **Prof. Hermansyah, S.Si., M.Si., Ph.D** selaku Dekan Fakultas MIPA Universitas Sriwijaya, beserta **seluruh staf Dekanat FMIPA**. Ibu **Dr. Dian Cahyawati Sukanda, S.Si., M.Si** selaku Ketua Jurusan Matematika dan Ibu **Des Alwine Zayanti, S.Si., M.Si** selaku Sekretaris Jurusan Matematika yang telah membimbing dan mengarahkan dalam urusan akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya.

2. Ibu **Dr. Anita Desiani, S.Si., M.Kom** selaku Dosen Pembimbing Utama dan Ibu **Prof. Yulia Resti, S.Si., M.Si., Ph.D** selaku Dosen Pembimbing Pendamping yang telah menyediakan waktu, tenaga, dan pikiran untuk memberikan bimbingan, arahan, motivasi, kritik dan saran yang sangat berarti bagi penulis selama proses pembuatan skripsi dan proses perkuliahan. Bapak **Dr. Bambang Suprihatin, S.Si., M.Si** selaku Dosen Pembahas Pertama dan Ibu **Irmeilyana, S.Si., M.Si** selaku Dosen Pembahas Kedua yang telah memberikan tanggapan, kritik dan saran yang bermanfaat untuk perbaikan dan penyelesaian skripsi ini. Ibu **Dr. Yuli Andriani, S.Si., M.Si** selaku Dosen Pembimbing Akademik yang telah membimbing dan mengarahkan urusan akademik penulis.
3. **Seluruh Dosen Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya** yang telah memberikan ilmu yang sangat bermanfaat bagi penulis. Bapak **Irwansyah** dan Ibu **Hamidah** selaku staf administrasi di Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu penulis selama perkuliahan.
4. Kakak Perempuan **Helen Monica Sari, S.Pd.**, Kakak Iparku **Ahmad Ridhoni, S.T.**, Kakak laki-lakiku **Kevin Rico Septiadi**, serta **Seluruh Keluarga Besar** yang senantiasa memberikan semangat, motivasi, dan doa terbaik untuk penulis.
5. **Kakak-kakak dan Adik-adik tingkat bidang minat Komputasi, Asisten Laboratorium Komputasi Matematika, Keluarga Matematika angkatan 2021, Himpunan Mahasiswa Matematika, Tim PKM Smart Talk** yang

telah berbagi ilmu dan memberikan banyak bantuan selama perkuliahan dan proses pembuatan skripsi ini.

6. Sahabat-sahabat terbaik penulis **Suristhia Rahmadita, Alda Amalia Mortara**, dan **Mitta Permata Sari** yang selalu mendukung, membersamai dan menjadi tempat ternyaman bagi penulis, Tim *Exudate* **Rifki Kurniawan**, teman-teman seperjuangan penulis **Lucy Chania Agatha, Annisa Aulia Lestari, Bagus, Refky Maulana, Faishal Fitra Ramadhan, Giovillando** serta **Teman-teman bidang minat Komputasi angkatan 2021** yang telah berjuang bersama, saling menguatkan, selalu sedia menjadi tempat berkeluh kesah penulis, memberikan dukungan dan banyak bantuan kepada penulis selama proses penyelesaian skripsi ini.
7. **Niken Ayuputri**, Diri Saya sendiri. Terima kasih karena telah bertanggung jawab untuk menyelesaikan apa yang telah dimulai, tidak mudah menyerah, serta menikmati setiap prosesnya. Terima kasih sudah bertahan hingga akhir.
8. Semua pihak yang tidak dapat penulis sebutkan satu per satu, semoga semua kebaikan yang telah diberikan mendapatkan balasan dari Allah.

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 membutuhkan.

Indralaya, Mei 2025

Penulis

EXUDATE SEGMENTATION IN DIABETIC RETINOPATHY IMAGES USING MODIFIED U-NET ARCHITECTURE, DENSE BLOCKS, AND CONVOLUTIONAL LONG SHORT-TERM MEMORY

By:

Niken Ayuputri

08011182126012

ABSTRACT

Diabetic retinopathy (DR) is an eye disease caused by high glucose and blood pressure levels that can lead to blindness. DR can be detected through the presence of exudates, which are white or yellow spots that form due to damage to the blood vessels of the retina. The process of image segmentation is performed to obtain exudate features in the retinal image. Automatic segmentation development can use the Convolutional Neural Network (CNN) method. U-Net is a CNN architecture that is capable of segmentation because it has encoder and decoder parts. Encoder functions to extract features but has the risk of losing fine image features and vanishing gradient due to the down sampling process. The decoder functions to reconstruct the image but has the risk of losing important information due to skip connection. This research modifies the U-Net architecture by adding Dense Block and Convolutional Long Short-Term Memory (ConvLSTM) for exudate segmentation in retinal images. Dense Block is applied to the encoder part to retain the fine features of the image and overcome the vanishing gradient problem. ConvLSTM is inserted in the decoder to retain important information in the image. This research performs image segmentation with two labels, namely exudate and background. The exudate segmentation results with the application of the proposed architecture obtained an accuracy of 99%, indicating the model is very good at predicting all labels correctly as a whole. Sensitivity of 82%, indicating the model predicts the exudate area well. Specificity of 99%, indicating the model is very good at predicting areas that are not part of the exudate. *F1-Score* 75%, indicating the model has a good balance between sensitivity and specificity. IoU 61%, indicating a poor level of overlap between the prediction results and the ground truth. The results of this study show that the model predicts and performs well in segmenting exudates in retinal images. However, improvements in sensitivity, *F1-Score* and IoU are required to optimize the performance of the segmentation model.

Keywords: ConvLSTM, Dense Block, Exudate, Segmentation, U-Net

SEGMENTASI *EXUDATE* PADA CITRA RETINA PENYAKIT *DIABETIC RETINOPATHY* MENGGUNAKAN MODIFIKASI ARSITEKTUR *U-NET*, *DENSE BLOCK*, DAN *CONVOLUTIONAL LONG SHORT-TERM MEMORY*

Oleh:

Niken Ayuputri

08011182126012

ABSTRAK

Diabetic retinopathy (DR) adalah penyakit mata disebabkan oleh kadar glukosa dan tekanan darah yang tinggi sehingga dapat mengakibatkan kebutaan. DR dapat dideteksi melalui keberadaan *exudate*, yaitu bintik-bintik putih atau kuning yang terbentuk akibat kerusakan pembuluh darah retina. Proses segmentasi citra dilakukan untuk mendapatkan fitur *exudate* pada citra retina. Pengembangan segmentasi secara otomatis dapat menggunakan metode *Convolutional Neural Network* (CNN). *U-Net* adalah arsitektur CNN yang mampu melakukan segmentasi karena memiliki bagian *encoder* dan *decoder*. *Encoder* berfungsi untuk mengekstrak fitur-fitur namun memiliki resiko kehilangan fitur-fitur halus citra dan terjadi *vanishing gradient* akibat proses *down sampling*. *Decoder* berfungsi untuk merekonstruksi ulang citra namun memiliki resiko kehilangan informasi penting akibat *skip connection*. Penelitian ini memodifikasi arsitektur *U-Net* dengan menambahkan *Dense Block* dan *Convolutional Long Short-Term Memory* (*ConvLSTM*) untuk segmentasi *exudate* pada citra retina. *Dense Block* diterapkan pada bagian *encoder* untuk mempertahankan fitur halus citra dan mengatasi masalah *vanishing gradient*. *ConvLSTM* disisipkan pada bagian *decoder* untuk mempertahankan informasi penting pada citra. Penelitian ini melakukan segmentasi citra dengan dua label yaitu *exudate* dan *background*. Hasil segmentasi *exudate* dengan penerapan arsitektur yang diusulkan memperoleh akurasi 99%, menunjukkan model sangat baik dalam memprediksi semua label dengan benar secara keseluruhan. Sensitivitas 82%, menunjukkan model memprediksi area *exudate* dengan baik. Spesifisitas 99%, menunjukkan model sangat baik dalam memprediksi area yang bukan bagian dari *exudate*. *F1-Score* 75%, menunjukkan model memiliki keseimbangan cukup baik antara sensitivitas dan spesifisitas. IoU 61%, menunjukkan tingkat tumpang tindih yang kurang baik antara hasil prediksi dengan *ground truth*. Hasil penelitian ini menunjukkan bahwa model memprediksi dan bekerja dengan baik dalam melakukan segmentasi *exudate* pada citra retina. Namun peningkatan sensitivitas, *F1-Score* dan IoU diperlukan untuk mengoptimalkan performa kinerja model segmentasi.

Kata Kunci: *ConvLSTM*, *Dense Block*, *Exudate*, Segmentasi, *U-Net*

DAFTAR ISI

HALAMAN PENGESAHAN	ii
HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH	iii
HALAMAN PERSEMBAHAN.....	iv
KATA PENGANTAR.....	v
ABSTRACT	viii
ABSTRAK	ix
DAFTAR ISI.....	x
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	5
1.3 Batasan Masalah.....	5
1.4 Tujuan.....	5
1.5 Manfaat	6
BAB II TINJAUAN PUSTAKA	7
2.1 <i>Diabetic Retinopathy</i>	7
2.2 Citra Digital.....	8
2.3 Segmentasi Citra	8
2.4 <i>Preprocessing Data</i>	8
2.6 <i>Convolutional Neural Network</i>	12
2.7 <i>U-Net</i>	12
2.7.1 <i>Encoder U-Net</i>	14
2.7.2 <i>Decoder U-Net</i>	21
2.8 <i>Loss Function: Binary Cross-Entropy</i>	25
2.9 <i>Optimization Function: Adaptive Moment Estimation (Adam)</i>	26
2.10 <i>Confusion Matrix</i>	27
BAB III METODOLOGI PENELITIAN	30
3.1 Tempat.....	30

3.2 Waktu	30
3.3 Alat.....	30
3.4 Tahapan Penelitian	30
BAB IV HASIL DAN PEMBAHASAN.....	37
4.1 Deskripsi Data.....	37
4.2 <i>Preprocessing</i> Data	38
4.3 Modifikasi Arsitektur <i>U-Net</i> , <i>Dense Block</i> , dan <i>ConvLSTM</i>	43
4.4 Operasi Perhitungan Manual.....	45
4.4.1 <i>Encoder U-Net</i>	45
4.4.2 <i>Decoder U-Net</i>	58
4.5 <i>Loss Function: Binary Cross-Entropy</i>	70
4.6 <i>Optimization Function: Adaptive Moment Estimation (Adam)</i>	73
4.7 Hasil Implementasi Arsitektur <i>U-Net</i> , <i>Dense Block</i> dan <i>ConvLSTM</i>	76
4.7.1 <i>Training</i> Data	76
4.7.2 <i>Testing</i> Data.....	79
4.7.3 Evaluasi Kinerja Model	80
4.7 Pembahasan, Analisis dan Interpretasi Hasil	81
BAB V KESIMPULAN DAN SARAN	84
5.1 Kesimpulan	84
5.2 Saran.....	84
DAFTAR PUSTAKA.....	86

DAFTAR TABEL

Tabel 2.1 <i>Confusion matrix</i>	27
Tabel 2.2 Kategori nilai evaluasi kinerja model.....	29
Tabel 4.1 Sampel citra dan <i>ground truth hard exudate</i>	37
Tabel 4.1 Sampel citra dan <i>ground truth hard exudate</i>	37
Tabel 4.2 Sampel citra sebelum dan setelah augmentasi	41
Tabel 4.3 Perbandingan citra asli, <i>ground truth</i> , dan hasil segmentasi	79
Tabel 4.4 <i>Confusion matrix</i> dari proses <i>testing</i>	80
Tabel 4.5 Perbandingan hasil evaluasi kinerja dengan penelitian lain.....	82

DAFTAR GAMBAR

Gambar 2.1 Mata penderita <i>diabetic retinopathy</i>	7
Gambar 2.2 Proses augmentasi data.....	10
Gambar 2.3 Ilustrasi <i>patch</i>	11
Gambar 2.4 Arsitektur U-Net.....	13
Gambar 2.5 Ilustrasi <i>padding same</i>	14
Gambar 2.6 Ilustrasi proses <i>convolutional layer</i>	15
Gambar 2.7 <i>Dense Block</i>	19
Gambar 2.8 Ilustrasi proses <i>max pooling</i>	20
Gambar 2.9 Ilustrasi proses <i>upsampling layer</i>	21
Gambar 2.10 Ilustrasi proses <i>concatenate layer</i>	22
Gambar 2.11 Arsitektur <i>ConvLSTM</i>	23
Gambar 4.1 Segmentasi biner <i>exudate</i>	38
Gambar 4.2 Citra Hasil CLAHE.....	39
Gambar 4.3 Proses patch citra retina.....	41
Gambar 4.4 Arsitektur <i>U-Net</i> , <i>Dense Block</i> , dan <i>ConvLSTM</i>	44
Gambar 4.5 Grafik akurasi.....	77
Gambar 4. 6 Grafik <i>loss</i>	78

BAB I

PENDAHULUAN

1.1 Latar Belakang

Diabetic Retinopathy (DR) adalah gangguan mata yang terjadi pada penderita diabetes mellitus (Sule, 2022). Penyakit DR disebabkan oleh tingginya kadar glukosa dan tekanan darah tinggi, sehingga merusak pembuluh darah retina dan dapat mengakibatkan kebutaan (Zhou *et al.*, 2021). DR ditandai dengan adanya *exudate* yaitu titik-titik berwarna putih atau kuning di sekitar pembuluh darah retina (Kou *et al.*, 2020). Terdapat dua jenis *exudate* yaitu *soft exudate* yang berbentuk bintik-bintik kecil berwarna putih keabuan dan *hard exudate* berbentuk endapan kecil berwarna putih kekuningan di sekitar retina (Verma and Yadav, 2019). Ketidaknormalan pada retina akibat penyakit DR dapat dianalisis melalui segmentasi *exudate* (Qomariah *et al.*, 2022).

Segmentasi adalah teknik yang memisahkan citra menjadi bagian objek dan latar belakang (Desiani *et al.*, 2022). Segmentasi secara manual membutuhkan para ahli berpengalaman yang jumlahnya terbatas, rentan terhadap kesalahan, dan memakan waktu yang lama, sehingga diperlukan teknik segmentasi secara otomatis (Zhang *et al.*, 2022). Pemanfaatan *Deep Learning* dengan metode *Convolutional Neural Network* (CNN) dapat digunakan dalam segmentasi secara otomatis karena mampu mengenali fitur-fitur kompleks pada citra (Ilesanmi *et al.*, 2023). *U-Net* adalah arsitektur CNN yang mampu melakukan segmentasi karena memiliki bagian *encoder* dan *decoder* (Desiani *et al.*, 2023).

Bagian *encoder U-Net* berfungsi untuk melakukan ekstraksi fitur-fitur penting pada citra melalui serangkaian lapisan konvolusi dan *pooling* (Tatli and Budak, 2023). Liu *et al.*, (2022) menerapkan arsitektur *U-Net* dalam segmentasi *exudate* namun sensitivitas masih dibawah 90%. Fu *et al.*, (2023) menerapkan arsitektur *U-Net* dalam segmentasi *exudate* dengan akurasi dan spesifisitas 98%. Pereira *et al.*, (2024) menerapkan arsitektur *U-Net* dalam segmentasi *exudate* dengan nilai akurasi sebesar 98%. Kedua penelitian tersebut memperoleh nilai sensitivitas, *F1-Score*, dan IoU yang masih dibawah 90%. Bagian *encoder U-Net* mampu mempelajari fitur-fitur pada citra namun penggunaan *down sampling* dengan *pooling* yang berulang dapat menyebabkan hilangnya informasi detail citra. *Pooling* adalah proses mengekstrak fitur utama untuk mengurangi dimensi citra sehingga beberapa fitur halus dapat hilang. Proses esstraksi fitur yang langsung diteruskan ke layer berikutnya tanpa melibatkan layer sebelumnya dapat menyebabkan berkurangnya pembelajaran gradien saat proses *training* sehingga dapat beresiko terjadi *vanishing gradient* (Du *et al.*, 2021).

Permasalahan *vanishing gradient* disebabkan oleh proses *max pooling*. Proses *max pooling* dapat menyebabkan berkurangnya jumlah fitur yang dipelajari pada citra karena hanya mengambil nilai maksimal, membuat gradien pada lapisan juga berkurang sehingga dapat menyebabkan *vanishing gradient* (Khan *et al.*, 2021).. Arsitektur CNN yang dikembangkan untuk mengatasi masalah *vanishing gradient* adalah *DenseNet*. *DenseNet* adalah arsitektur CNN untuk klasifikasi yang hanya memiliki bagian *encoder*. *DenseNet* terdiri dari beberapa lapisan yang disebut dengan *Dense Block*. *Dense Block* adalah kumpulan beberapa layer yang saling

terhubung ke semua lapisan pada layer sebelum dan semua lapisan pada layer-layer berikutnya yang dapat meningkatkan aliran informasi citra (Lodhi *and* Kang, 2019). Koneksi antar lapisan dapat mengatasi *vanishing gradient* karena memungkinkan aliran gradien yang lebih baik antara semua lapisan dengan memanggil kembali fitur-fitur semua lapisan sebelumnya dan menggabungkannya dengan layer berikutnya. Penerapan *Dense Block* pada *DenseNet* telah diterapkan dalam berbagai arsitektur termasuk *U-Net* (Lodhi *and* Kang, 2019). Garifullin *et al.*, (2021) menerapkan *Dense Block* pada bagian *encoder U-Net* dalam segmentasi *exudate* dengan spesifisitas sebesar 99%, namun sensitivitas masih dibawah 80%. Mohanty *et al.*, (2023) menerapkan *Dense Block* pada bagian *encoder U-Net* dalam segmentasi *exudate* dengan akurasi sebesar 97%, namun tidak mengukur kinerja evaluasi lain. Abbas *et al.*, (2021) menerapkan *Dense Block* pada bagian *encoder U-Net* dalam segmentasi *exudate* dengan akurasi 92,6%, sensitivitas 90,5%, spesifisitas 91,5%, namun tidak mengukur kinerja evaluasi lain. Selain memiliki bagian *encoder*, *U-Net* juga memiliki bagian *decoder*.

Bagian *decoder* berfungsi untuk mengembalikan *feature map* yang diproses oleh *encoder* ke resolusi asli citra melalui proses *upsampling* (Tatli *and* Budak, 2023). Hasil *upsampling* akan digabungkan dengan fitur dari layer *encoder* yang ditranfer dari *skip connection*. *Skip connection* berfungsi untuk memanggil dan mentransfer fitur dari layer sebelumnya. Penggunaan *skip connection* tanpa filter dapat membuat informasi yang tidak relevan ikut diteruskan ke bagian *decoder* sehingga mengurangi informasi yang relevan pada citra (Ahmad *et al.*, 2021). Arsitektur yang mampu menyaring dan mempertahankan informasi yang relevan

adalah *Long Short-Term Memory (LSTM)*. LSTM adalah arsitektur *Recurrent Neural Network (RNN)* yang terdiri dari tiga *gate* utama yaitu *forget gate* berfungsi untuk menentukan informasi yang akan dihapus, *input gate* yang berfungsi untuk mengatur informasi baru yang akan disimpan, dan *output gate* berfungsi untuk mengatur informasi yang akan dikeluarkan sebagai *output*. *Convolutional Long Short-Term Memory (ConvLSTM)* merupakan arsitektur LSTM yang dimodifikasi dengan menambahkan operasi konvolusi (Jeong *et al.*, 2024). *ConvLSTM* dirancang untuk mengatasi data spasial seperti citra. *ConvLSTM* menambahkan konvolusi pada *gates* dan *cell states* yang dapat menyaring dan menangkap informasi spasial pada citra (Xia *et al.*, 2022). Ashir *et al.*, (2021) menyisipkan *ConvLSTM* pada *decoder U-Net* untuk segmentasi *exudate* dengan akurasi sebesar 94%, namun sensitivitas masih dibawah 80%. Yi *et al.*, (2022) menyisipkan *ConvLSTM* pada *decoder U-Net* dalam segmentasi *exudate* dengan akurasi sebesar 97%, namun sensitivitas, *F1-Score* dan *IoU* yang diperoleh masih dibawah 80%. Azad *et al.*, (2019) menyisipkan *ConvLSTM* pada *decoder U-Net* dalam segmentasi *exudate* dengan akurasi sebesar 95%, namun *F1-Score* dan sensitivitas masih dibawah 85%.

Penelitian ini menerapkan arsitektur *U-Net* untuk segmentasi *exudate* pada citra retina dengan modifikasi arsitektur *U-Net*, menerapkan *Dense Block* pada bagian *encoder* dan menyisipkan *ConvLSTM* pada bagian *decoder U-Net*. Penggunaan *Dense Block* pada setiap blok konvolusi *encoder U-Net* ditujukan agar fitur halus pada citra tetap terjaga dan mengatasi masalah *vanishing gradient*. Arsitektur *ConvLSTM* disisipkan pada bagian *decoder* setelah layer penggabungan *skip connection* yang ditujukan untuk menyaring dan mempertahankan informasi

yang relevan melalui konvolusi dan *gates* dalam *ConvLSTM*. Penelitian ini melakukan segmentasi biner pada citra retina penyakit *diabetic retinopathy* dengan memisahkan *exudate* sebagai *foreground* dan area latar belakang (*background*).

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah bagaimana meningkatkan kinerja segmentasi *exudate* pada citra retina dengan menerapkan modifikasi arsitektur *U-Net*, dengan menerapkan *Dense Block* untuk mempertahankan fitur halus pada citra dan mengatasi masalah *vanishing gradient* yang terjadi pada bagian *encoder U-Net* dan menyisipkan blok *ConvLSTM* untuk menyaring dan mempertahankan informasi relevan pada bagian *decoder U-Net*.

1.3 Batasan Masalah

Batasan masalah pada penelitian ini adalah ukuran evaluasi kinerja segmentasi *exudate* pada citra retina penyakit *diabetic retinopathy* yang dilakukan menggunakan akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *IoU*. Segmentasi yang dilakukan hanya pada *dataset hard exudate*.

1.4 Tujuan

Tujuan dari penelitian ini adalah meningkatkan kinerja segmentasi *exudate* pada citra retina dengan menerapkan modifikasi arsitektur *U-Net* dimana bagian *encoder* menggunakan *Dense Block* dan menyisipkan *ConvLSTM* pada bagian *decoder* untuk meningkatkan kinerja model dalam segmentasi.

1.5 Manfaat

Manfaat dari hasil penelitian ini sebagai berikut:

1. Hasil segmentasi *exudate* dapat digunakan pada proses klasifikasi penyakit *diabetic retinopathy*.
2. Penelitian ini menghasilkan model baru yang dapat digunakan sebagai referensi penelitian lainnya, khususnya dalam segmentasi *exudate* pada citra retina dan pengembangan *deep learning*.

DAFTAR PUSTAKA

- Abbas, Q., Qureshi, I., & Ibrahim, M. E. A. (2021). An automatic detection and classification system of five stages for hypertensive retinopathy using semantic and instance segmentation in DenseNet architecture. *Sensors*, 21(20), 6936. <https://doi.org/10.3390/s21206936>
- Abdou, M. A. (2022). Literature review: efficient deep neural networks techniques for medical image analysis. *Neural Computing and Applications*, 34(8), 5791–5812. <https://doi.org/10.1007/s00521-022-06960-9>
- Ahmad, P., Jin, H., Alroobaea, R., Qamar, S., Zheng, R., Alnajjar, F., & Aboudi, F. (2021). MH UNet: A multi-scale hierarchical based architecture for medical image segmentation. *IEEE Access*, 9, 148384–148408. <https://doi.org/10.1109/ACCESS.2021.3122543>
- Alomar, K., Aysel, H. I., & Cai, X. (2023). Data augmentation in classification and segmentation: A survey and new strategies. *Journal of Imaging*, 9(2), 46. <https://doi.org/10.3390/jimaging9020046>
- 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(1), 6618666. <https://doi.org/10.1155/2021/6618666>
- Azad, R., Aghdam, E. K., Rauland, A., Jia, Y., Avval, A. H., Bozorgpour, A., Karimijafarbigloo, S., Cohen, J. P., Adeli, E., & Merhof, D. (2024). Medical image segmentation review: the success of U-Net. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 46(12), 10076–10095. <https://doi.org/10.1109/TPAMI.2024.3435571>
- Azad, R., Asadi-Aghbolaghi, M., Fathy, M., & Escalera, S. (2019). Bi-directional ConvLSTM U-Net with densely connected convolutions. *Proceeding of IEEE/CVF International Conference on Computer Vision Workshop*, 406–415. <https://doi.org/10.1109/ICCVW.2019.00052>
- Chen, P. (2019). Effects of normalization on the entropy-based TOPSIS method. *Expert Systems With Applications*, 136, 33–41. <https://doi.org/10.1016/j.eswa.2019.06.035>
- Desiani, A., Adrezo, M., Alfani, A. M., Erwin, & Suprihatin, B. (2021). A hybrid system for enhancement retinal image reduction. *International Conference on Informatics, Multimedia, Cyber, and Information System (ICIMCIS)*, 80–85. <https://doi.org/10.1109/ICIMCIS53775.2021.9699259>
- Desiani, A., Erwin, Suprihatin, B., Efriliyanti, F., Arhami, M., & Setyaningsih, E.

- (2022). VG-DropDNet a robust architecture for blood vessels segmentation on retinal image. *IEEE Access*, 10, 92067–92083. <https://doi.org/10.1109/ACCESS.2022.3202890>
- Desiani, A., Priyanta, S., Ramayanti, I., Suprihatin, B., Rio Halim, M., Geovani, D., & Rayani, I. (2023). Multi-stage CNN: U-Net and Xcep-Dense of glaucoma detection in retinal images. *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, 5(4), 211–222. <https://doi.org/10.35882/jeeemi.v5i4.314>
- Du, X., Wang, J., & Sun, W. (2021). Densely connected U-Net retinal vessel segmentation algorithm based on multi-scale feature convolution extraction. *Medical Physics*, 48(7), 3827–3841. <https://doi.org/10.1002/mp.14944>
- Fu, Y., Zhang, G., Lu, X., Wu, H., & Zhang, D. (2023). RMCA U-net: Hard exudates segmentation for retinal fundus images. *Expert Systems with Applications*, 234, 120987. <https://doi.org/10.1016/j.eswa.2023.120987>
- Garifullin, A., Lensu, L., & Uusitalo, H. (2021). Deep bayesian baseline for segmenting diabetic retinopathy lesions: advances and challenges. *Computers in Biology and Medicine*, 136, 104725. <https://doi.org/10.1016/j.combiomed.2021.104725>
- Hassan, E., Shams, M. Y., Hikal, N. A., & Elmougy, S. (2023). The effect of choosing optimizer algorithms to improve computer vision tasks: a comparative study. *Multimedia Tools and Applications*, 82(11), 16591–16633. <https://doi.org/10.1007/s11042-022-13820-0>
- Hayati, M., Muchtar, K., Roslidar, Maulina, N., Syamsuddin, I., Elwirehardja, G. N., & Pardamean, B. (2022). Impact of CLAHE-based image enhancement for diabetic retinopathy classification through deep learning. *Procedia Computer Science*, 216, 57–66. <https://doi.org/10.1016/j.procs.2022.12.111>
- Huang, C., Zong, Y., Ding, Y., Luo, X., Clawson, K., & Peng, Y. (2021). A new deep learning approach for the retinal hard exudates detection based on super pixel multi-feature extraction and patch-based CNN. *Neurocomputing*, 452, 521–533. <https://doi.org/10.1016/j.neucom.2020.07.145>
- Hussain, M., Al-Aqrabi, H., Munawar, M., Hill, R., & Parkinson, S. (2023). Exudate regeneration for automated exudate detection in retinal fundus images. *IEEE Access*, 11, 83934–83945. <https://doi.org/10.1109/ACCESS.2022.3205738>
- Hyun, J., Seong, H., & Kim, E. (2021). Universal pooling – a new pooling method for convolutional neural networks. *Expert Systems with Applications*, 180, 1–16. <https://doi.org/10.1016/j.eswa.2021.115084>

- Ilesanmi, A. E., Ilesanmi, T., & Gbotoso, G. A. (2023). A systematic review of retinal fundus image segmentation and classification methods using convolutional neural networks. *Healthcare Analytics*, 4, 100261. <https://doi.org/10.1016/j.health.2023.100261>
- Islam, M. A., Kowal, M., Jia, S., Derpanis, K. G., & Bruce, N. D. B. (2024). Position, padding and predictions: a deeper look at position information in CNNs. *International Journal of Computer Vision*, 132(9), 3889–3910. <https://doi.org/10.1007/s11263-024-02069-9>
- Jeong, S. H., Lee, W. K., Kil, H., Jang, S., Kim, J. H., & Kwak, Y. S. (2024). Deep learning-based regional ionospheric total electron content prediction—long short-term memory (LSTM) and convolutional LSTM approach. *Space Weather*, 22(1), 1–10. <https://doi.org/10.1029/2023SW003763>
- Kesidis, A. L., Krassanakis, V., Misthos, L. M., & Merlemis, N. (2022). patchIT: A multipurpose patch creation tool for image processing applications. *Multimodal Technologies and Interaction*, 6(12), 111. <https://doi.org/10.3390/mti6120111>
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 5455–5516. <https://doi.org/10.1007/s10462-020-09825-6>
- Khan, Z., Yahya, N., Alsaih, K., Al-Hiyali, M. I., & Meriaudeau, F. (2021). Recent automatic segmentation algorithms of MRI prostate regions: a review. *IEEE Access*, 9, 97878–97905. <https://doi.org/10.1109/ACCESS.2021.3090825>
- 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>
- Krichen, M. (2023). Convolutional neural networks: a survey. *Computers*, 12(8), 1–41. <https://doi.org/10.3390/computers12080151>
- Liang, J., Liu, Y., & Vlassov, V. (2023). The impact of background removal on performance of neural networks for fashion image classification and segmentation. *Congress in Computer Science, Computer Engineering, and Applied Computing*, 1960–1968. <https://doi.org/10.1109/CSCE60160.2023.00323>
- 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, X., Song, L., Liu, S., & Zhang, Y. (2021). A review of deep-learning-based medical image segmentation methods. *Sustainability*, 13(3), 1224.

<https://doi.org/10.8890/su13031224>

- Lodhi, B., & Kang, J. (2019). Multipath-DenseNet: A supervised ensemble architecture of densely connected convolutional networks. *Information Sciences*, 482, 63–72. <https://doi.org/10.1016/j.ins.2019.01.012>
- Mohanty, C., Mahapatra, S., Acharya, B., Kokkoras, F., Gerogiannis, V. C., Karamitsos, I., & Kanavos, A. (2023). Using deep learning architectures for detection and classification of diabetic retinopathy. *SensorsNetwork Modeling Analysis in Health Informatics and Bioinformatics*, 23(12), 5278. <https://doi.org/10.3390/s23125726>
- Pereira, A., Santos, C., Aguiar, M., Welfer, D., Dias, M., De Menezes, R., Ferreira, P. R., Rossi, F., D'Ornellas, M., Haygert, C. J., Kazienko, J., Comim, F., Hoppe, A., Weber, J., Tavares, L., Guths, L., & Guerra, R. (2024). An Improved Approach for Semantic Segmentation of Fundus Lesions using R2U-Net. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 1–4. <https://doi.org/10.1109/EMBC53108.2024.10782763>
- Qomariah, D. U. N., Tjandrasa, H., & Fatichah, C. (2022). Exudate segmentation for diabetic retinopathy using nodified FCN-8 and dice loss. *International Journal of Intelligent Engineering and Systems*, 15(2), 508–520. <https://doi.org/10.22266/ijies2022.0430.45>
- Rane, D. T., Kumbharkar, D. P., & Bhise, D. A. T. (2023). Improved image segmentation technique for foreground extraction. *International Journal of Advances in Electrical Engineering*, 4(2), 12–29. <https://doi.org/10.22271/27084574.2023.v4.i2a.41>
- Ruby, U., Theerthagiri, P., Jacob, J., & Yamsidhar. (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>
- Salehi, A. W., Khan, S., Gupta, G., Alabdullah, B. I., Almjally, A., Alsolai, H., Siddiqui, T., & Mellit, A. (2023). A study of CNN and transfer learning in medical imaging: advantages, challenges, future scope. *Sustainability*, 15(7), 1–28. <https://doi.org/10.3390/su15075930>
- Sarki, R., Ahmed, K., Wang, H., Zhang, Y., Ma, J., & Wang, K. (2021). Image preprocessing in classification and identification of diabetic eye diseases. *Data Science and Engineering*, 6(4), 455–471. <https://doi.org/10.1007/s41019-021-00167-z>
- Sarvamangala, D. R., & Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: a survey. *Evolutionary Intelligence*, 15(1), 1–

22. <https://doi.org/10.1007/s12065-020-00540-3>
- Sebastian, A., Elharrouss, O., Al-Maadeed, S., & Almaadeed, N. (2023). A survey on diabetic retinopathy lesion detection and segmentation. *Applied Sciences*, 13(8), 5111. <https://doi.org/10.3390/app13085111>
- Shaukat, N., Amin, J., Sharif, M. I., Sharif, M. I., Kadry, S., & Sevcik, L. (2023). Classification and segmentation of diabetic retinopathy: a systemic review. *Applied Sciences*, 13(5), 3108. <https://doi.org/10.3390/app13053108>
- Singh, D., & Birmohan. (2019). Investigating the impact of data normalization on classification performance. *Applied Soft Computing Journal*, 97, 105524. <https://doi.org/10.1016/j.asoc.2019.105524>
- Sule, O. O. (2022). A survey of deep learning for retinal blood vessel segmentation methods: taxonomy, trends, challenges and future directions. *IEEE Access*, 10, 38202–38236. <https://doi.org/10.1109/ACCESS.2022.3163247>
- Szandała, T. (2021). Review and comparison of commonly used activation functions for deep neural networks. *Bio-Inspire Neurocomputing*, 903, 203–224. https://doi.org/10.1007/978-981-15-5495-7_11
- Tatli, U., & Budak, C. (2023). Biomedical image segmentation with modified U-Net. *International Information and Engineering Technology Assosiation*, 40(2), 523–531. <https://doi.org/10.18280/ts.400211>
- Verma, S. B., & Yadav, A. K. (2019). Detection of hard exudates in retinopathy images. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 8(4), 41–48. <https://doi.org/10.14201/ADCAIJ2019844148>
- Vujovic, Ž. (2021). Classification Model Evaluation Metrics. *International Journal of Advanced Computer Science and Applications*, 12(6), 599–606. <https://doi.org/10.14569/IJACSA.2021.0120670>
- Wang, C., Gan, M., Zhang, M., & Li, D. (2020). Adversarial convolutional network for esophageal tissue segmentation on OCT images. *Biomedical Optics Express*, 11(6), 3095. <https://doi.org/10.1364/boe.394715>
- Xia, D.-H., Song, S., Tao, L., Qin, Z., Wu, Z., Gao, Z., Wang, J., Hu, W., Behnamian, Y., & Luo, J.-L. (2020). Review-material degradation assessed by digital image processing: fundamentals, progresses, and challenges. *Journal of Materials Science and Technology*, 53, 146–162. <https://doi.org/10.1016/j.jmst.2020.04.033>
- Xia, G., Zhang, F., Wang, C., & Zhou, C. (2022). ED-ConvLSTM: A novel global ionospheric eotal Electron content medium-term forecast model. *Space Weather*, 20(8), 1–17. <https://doi.org/10.1029/2021SW002959>

- Yi, Y., Guo, C., Hu, Y., Zhou, W., & Wang, W. (2022). BCR-UNet: Bi-directional ConvLSTM residual U-Net for retinal blood vessel segmentation. *Frontiers in Public Health*, 10, 1056266. <https://doi.org/10.3389/fpubh.2022.1056226>
- Yinghua, M., Heng, Y., Amarnath, R., & Hui, Z. (2024). Hard exudates segmentation in diabetic retinopathy using diaRetdb1. *IEEE Access*, 11, 1–17. <https://doi.org/10.1109/ACCESS.2024.3455433>
- Zhang, J., Chen, X., Qiu, Z., Yang, M., Hu, Y., & Liu, J. (2022). Hard exudate segmentation supplemented by super-resolution with multi-scale attention fusion module. *International Conference on Bioinformatics and Biomedicine (BIBM)*, 1375–1380. <https://doi.org/10.1109/BIBM55620.2022.9995545>
- Zhou, T., Ye, X., Lu, H., Zheng, X., Qiu, S., & Liu, Y. (2022). Dense Convolutional Network and Its Application in Medical Image Analysis. *BioMed Research International*, 2022(1), 1–22. <https://doi.org/10.1155/2022/2384830>
- Zhou, Y., Wang, B., Huang, L., Cui, S., & Shao, L. (2021). A benchmark for studying diabetic retinopathy: segmentation, grading, and transferability. *IEEE Transactions on Medical Imaging*, 40(3), 818–828. <https://doi.org/10.1109/TMI.2020.3037771>