
SEGMENTASI *SOFT EXUDATE* PADA CITRA FUNDUS RETINA PASIEN *DIABETIC RETINOPATHY* BERBASIS U-NET

I Md. Dendi Maysanjaya^{1*}, Kadek Suwis Satria Atmaja², I Made Gede Sunarya³

^{1,2,3} *Virtual Vision, Image, and Pattern Research Group (VVIP-RG) Fakultas Teknik dan Kejuruan Universitas Pendidikan Ganesha, Jln. Udayana No. 11 Singaraja 81116 INDONESIA*

Abstrak

Diabetic retinopathy merupakan suatu kondisi mata yang terjadi pada orang yang menderita diabetes yang dapat mengakibatkan kehilangan penglihatan dan kebutaan. Kondisi ini terjadi akibat kerusakan pada pembuluh darah dan serabut saraf mata yang disebut *exudates*. *Exudates* terdiri dari dua jenis, yaitu *hard exudate* (HE) dan *soft exudate*. Penelitian ini difokuskan pada segmentasi *soft exudate* dengan menggunakan pengolahan citra digital menggunakan metode berbasis deep learning dengan U-Net. Secara garis besar, proses dalam proses segmentasi ini terdiri dari 3 tahap yaitu (1) *pre-processing* adalah tahap untuk memperbaiki citra yang akan digunakan sebelum dilakukan tahap segmentasi agar hasil yang didapatkan lebih optimal, (2) segmentasi adalah tahap untuk melakukan pemisahan *soft exudate* dengan yang bukan *soft exudate* dan (3) evaluasi adalah tahap untuk mengetahui performa dari hasil segmentasi yang telah didapatkan. Performa kedua metode dibandingkan dengan menggunakan tiga metrik performansi, yaitu akurasi, sensitifity, dan specificity dengan membandingkan hasil segmentasi dengan groundtruth. Hasil penelitian menunjukkan bahwa metode U-Net menghasilkan rata-rata akurasi 0.99586, sensitifity 0.36203, dan specificity 0.99856 dalam evaluasi hasil performansi skor.

Kata Kunci:

segmentasi, *soft exudate*, citra retina, *diabetic retinopathy*, U-Net

Abstract

Diabetic retinopathy is an eye condition that occurs in people with diabetes and can result in vision loss and blindness. This condition is caused by damage to the blood vessels and nerve fibers in the eye known as exudates. Exudates are divided into two types: hard exudate and soft exudate. This research focuses on the segmentation of soft exudate using digital image processing with a deep learning-based method called U-Net. The segmentation process can be divided into three stages: (1) pre-processing, which improves the image quality before the segmentation stage, (2) segmentation, which separates soft exudate from non-soft exudate, and (3) evaluation, which measures the performance of the segmentation results. The performance of both methods is compared using three performance metrics: accuracy, sensitivity, and specificity by comparing the segmentation results with the ground truth. The results of the study show that the U-Net method produces an average accuracy of 0.99586, sensitivity of 0.36203, and specificity of 0.99856 in evaluating the performance score.

Keywords:

segmentation, *soft exudate*, retina image, *diabetic retinopathy*, U-Net

1. PENDAHULUAN

Diabetic retinopathy (DR) adalah kondisi mata yang dapat terjadi pada orang dengan diabetes yang dapat menyebabkan kebutaan dan kehilangan penglihatan. Kondisi ini disebabkan oleh kerusakan pada pembuluh darah di bagian belakang mata, yang dikenal sebagai retina. Faktor risiko utama yang menyebabkan kondisi ini adalah kontrol gula darah yang buruk (Manullang, Rares, & Sumual, 2016). Gejala yang terjadi termasuk kerusakan pada pembuluh darah dan serat saraf mata yang disebut sebagai *exudate*. *Exudate* terdiri dari bintik-bintik darah berwarna kuning yang bentuknya tidak teratur. Terdapat dua jenis

* Korespondensi

E-mail: dendi.ms@undiksha.ac.id

exudate yaitu *hard exudate* (HE) dan *soft exudate*. *Cotton wool spots*, yang berwarna putih dengan tepi yang kurang jelas, adalah contoh dari *soft exudate*. Sedangkan *hard exudate* disebabkan oleh kebocoran protein dan lipid pembuluh retina, dan biasanya berbentuk tajam dan cerah (Naufal, 2018).

Salah satu bentuk kerusakan tersebut yaitu kekurangan nya aliran darah dan oksigen ke retina akibat gangguan di pembuluh darah. Jika dibiarkan dapat menyebabkan kehilangan penglihatan karena kondisi penyakit yang mendasarinya. Deteksi *soft exudate* menjadi sangat berat dan sulit bagi para dokter karena penampilan dari *soft exudate* cenderung mendapat gangguan dari HE, *optic disc* (OD), makula, pembuluh darah dan juga di sekitar area OD dalam hal warna dan kecerahan. Selain itu, tampak lebih dekat ke latar belakang serta tidak terlihat jelas. Oleh karena itu, metode deteksi gejala penyakit *soft exudate* secara otomatis dengan menggunakan komputer menjadi suatu kebutuhan bagi seorang dokter untuk meyakinkan adanya tanda *soft exudate* pada citra fundus pasien DR.

Untuk mendeteksi atau mengetahui lokasi dari *soft exudate* pada citra fundus retina, dapat dilakukan dengan proses segmentasi citra. Proses ini akan membagi citra menjadi dua bagian yaitu daerah yang berisi *soft exudate* dan daerah yang tidak berisi *soft exudate*. Tujuan dari segmentasi citra adalah untuk membagi citra menjadi beberapa wilayah yang terpisah, dengan karakteristik yang sama berdasarkan tekstur, warna, dan lain-lain. Ini akan membantu dalam mengidentifikasi daerah *soft exudate* di citra fundus retina.

Penelitian terkait u-net dilakukan oleh Prasetyo (Prasetyo, Sumi, & Nuraini, 2020) melakukan penelitian yang menggunakan U-Net untuk melakukan segmentasi pada OD pada citra fundus retinal. Berdasarkan hasil eksperimen, mereka berhasil mencapai kinerja segmentasi OD sebesar 98,42% untuk koefisien Dice dengan loss 0,15. Temuan tersebut menunjukkan bahwa metode yang mereka usulkan berhasil dengan sangat baik dalam melakukan segmentasi optic cup pada citra fundus retinal. Penelitian lain yang menggunakan U-Net dilakukan oleh Joshua (Joshua, Nelwamondo, & Mabuza-Hocquet, 2020) untuk melakukan segmentasi pada pembuluh darah pada citra fundus. Hasil penelitian mencapai sensitivitas sebesar 0,8309, 0,7796, 0,7506, 0,8059 dan spesifisitas sebesar 0,9742, 0,9864, 0,9824 dan 0,9826 pada masing-masing database citra DRIVE, CHASE_DB1, STARE dan HRF.

Penelitian terkait lainnya dilakukan oleh (Bagus, Mahadya, Sudarma, Kumara, & Optimizer, 2020) melakukan penelitian terkait proses segmentasi menggunakan metode *u-net*. Dataset digunakan untuk melatih dan memvalidasi segmentasi tumor otak menggunakan machine learning dan dikategorikan sebagai BRATS 2017. Metode *unsupervised learning* dan *supervised learning* menerapkan beberapa *hyperparameter* seperti *learning rate* sebesar 0.0001, *batch size* sebesar 5, *epoch* sebanyak 80, dan beta sebesar 0.9. Metode ini didesain untuk pembelajaran otomatis informasi tumor otak dan memiliki tingkat akurasi berikut: 90.22% (Full Tumor), 78.09% (Core Tumor), dan 80.20% (Enhancing Tumor) berdasarkan rumus Dice Coefficient. Pada penelitian yang dilakukan oleh Mustafa (Mustafa, Zhao, Liu, Zhang, & Yu, 2020) Pembelajaran mendalam digunakan dalam aplikasi interpretasi citra penginderaan jauh dengan resolusi tinggi. Penelitian ini mengusulkan sistem analisis citra dengan segmentasi citra dan estimasi perubahan volume mineral menggunakan struktur Res-U-Net yang menggabungkan U-Net dan struktur residual. Hasil eksperimen pada citra penginderaan jauh menunjukkan Res-U-Net lebih unggul dibandingkan dengan metode segmentasi citra lainnya dengan akurasi piksel 92% dan mIOU 86%, serta kecepatan frame 35 FPS pada dataset pengujian, lebih baik dari U-Net tradisional.

Berikutnya penelitian terkait tentang *soft exudate* dilakukan oleh Bui (Bui, Maneerat, & Watchareeruetai, 2017) berfokus pada menangani *cotton-wool spot* penyebab kebutaan pada DR, dengan melakukan segmentasi otomatis pada citra fundus pasien menggunakan metode *Neural Network* setelah *pre-processing* untuk meningkatkan kualitas gambar dan memisahkan OD. Validitas metode ini ditentukan dengan *k-fold cross validation*, dan citra yang digunakan berasal dari DIARETDB1 dengan tingkat sensitivitas 85,9%, spesifisitas 84,4%, dan akurasi 85,54%. Penelitian dilakukan oleh Badar (Badar, Shahzad, & Fraz, 2018) Penelitian ini bertujuan untuk mendeteksi patologi pada retina, termasuk *cotton-wool spot*. Setelah *pre-processing* citra, peneliti menggunakan *Encoder Decoder based Fully Convolutional Neural Network*. Dataset yang digunakan berasal dari Messidor dan berhasil mencapai akurasi sebesar 88,65% dalam mendeteksi *cotton-wool spot*.

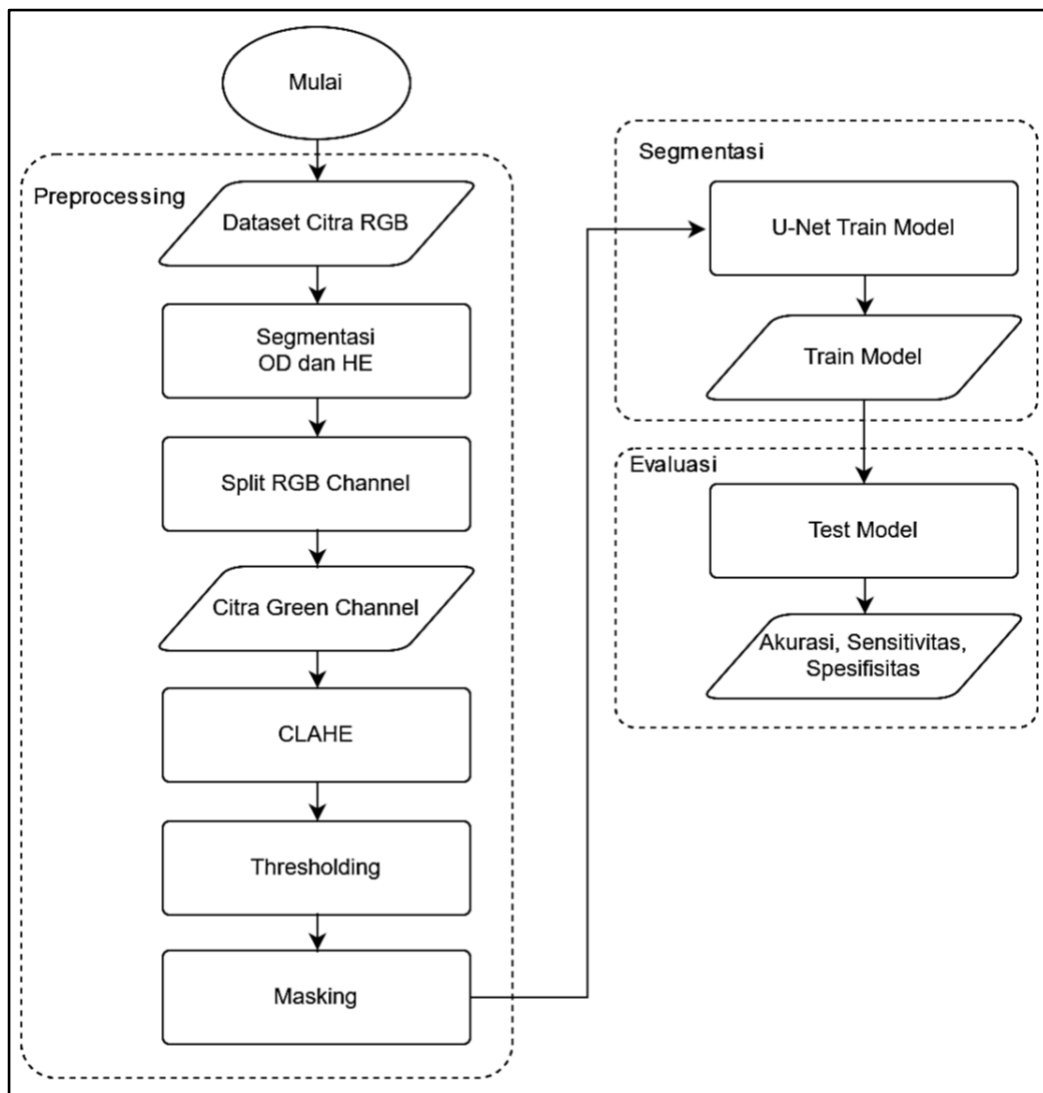
Selanjutnya dari Sreng (Sreng, Maneerat, Hamamoto, & Panjaphongse, 2019) Penelitian ini membahas pengolahan citra fundus pasien diabetic retinopathy dengan melakukan tahap *pre-processing* dan pendeteksian *cotton-wool spot* menggunakan *Principal Components Analysis* (PCA) dan *Support Vector Machine* (SVM). Dataset yang digunakan berasal dari dataset lokal dan DIARETDB1 dengan hasil akurasi 90,47%, sensitivitas 85,29%, dan spesifisitas 90,12%. Rata-rata waktu komputasi yang dibutuhkan adalah 16,47 detik per citra. Penelitian lain Sreng (Sreng, Maneerat, Win, Hamamoto, & Panjaphongse, 2019) Penelitian ini merupakan lanjutan dari penelitian sebelumnya, yang mengevaluasi pengoptimalan SVM dengan *Adaptive Thresholding* dan *Ant Colony Optimization* untuk deteksi *cotton-wool spots* pada citra fundus pasien DR. Dataset yang digunakan berasal dari dataset lokal dan DIARETDB1, dengan hasil akurasi 96,96%, sensitivitas 90,16%, spesifisitas 97,92%, dan kurva karakteristik operasi area bawah penerima

97,19%. Terakhir adalah Sudha (Sudha, Srinivasan, & Gayathri Devi, 2019) yang berfokus pada deteksi *cotton-wool spot*. Dilakukan *pre-processing* untuk memperbaiki citra dan segmentasi dengan k mean. Selanjutnya, dilakukan klasifikasi dengan SVM classifier menggunakan citra dari dataset lokal. Hasilnya, didapatkan sensitivity sebesar 95% dan spesifisitas sebesar 86%.

Selanjutnya, penulis menggunakan metode *u-net* karena arsitektur ini dikembangkan khusus untuk meningkatkan kemampuan dalam meng-segmentasi citra medis. Selain itu, metode ini diterapkan pada tingkat pixel untuk mencapai tingkat akurasi yang lebih baik. Dalam penelitian ini, *u-net* diterapkan dengan menggunakan parameter seperti aktivasi relu dan adam optimizer, yang diharapkan dapat menyelesaikan masalah segmentasi *soft exudate* yang ada pada citra medis (Suta, Sudarma, & Satya Kumara, 2020).

2. METODE

A. Skema Penelitian



Gambar 1. Skema Penelitian

Berdasarkan Gambar 1, dataset yang diakuisisi berformat RGB. Dari citra tersebut, dilakukan eliminasi terhadap bagian OD dan HE. Untuk algoritma yang digunakan mengadopsi penelitian terdahulu yang telah dilakukan yakni oleh (Putra, Maysanjaya, & Kesiman, 2023; Suardika, Maysanjaya, & Kesiman, 2022). Eliminasi ini dilakukan bertujuan untuk meminimalisir kesalahan dalam proses segmentasi *soft exudates*. Selanjutnya, dilakukan pemisahan kanal warna citra RGB, dan yang dipilih adalah kanal warna hijau. Dari citra *grayscale* ini kemudian dikenakan CLAHE, untuk meningkatkan kualitas kontras citra. Hasil proses CLAHE ini di-*threshold* untuk selanjutnya dijadikan sebagai citra *mask* untuk area yang terindikasi

sebagai *soft exudates*. Citra yang telah ter-*masking* selanjutnya dijadikan bahan untuk proses pelatihan model dengan metode U-Net. Hasil pelatihan ini selanjutnya diuji dengan citra *ground truth* dengan mengukur tingkat akurasi, sensitivitas, dan spesifisitas.

B. Dataset


Dalam melakukan penelitian terkait proses segmentasi *soft exudate*, dataset citra fundus retina yang akan digunakan dalam proses penelitian ini berasal dari di situs website *Indian Diabetic Retinopathy Image Dataset* (IDRiD) (Porwal et al., 2018). Pengambilan citra fundus dari dataset ini dilakukan terhadap pasien yang terkena *diabetic retinopathy* di Klinik Mata yang berlokasi di Nanded, (M.S.), India. Pada proses akuisisi citra dari dataset tersebut, terdapat aspek-aspek yang perlu diketahui, yaitu.

Pretreatment of Samples, Sebelum dilakukan penangkapan gambar, Seluruh subjek pada dataset telah mengalami Mydriasi. Mydriasi merupakan proses pelebaran pupil dengan menggunakan satu tetes tropikamida pada Konsentrasi 0,5%.

Fundus Camera Specifications, Tahap pengambilan gambar diperoleh dengan bantuan kamera fundus digital Kowa VX-10 alpha dengan 50-derajat field of view (FOV). Hasil gambar mempunyai resolusi 4288 x 2848 piksel, ukuran per citra sekitar 800 KB dan disimpan dalam format file jpg.

Data Quality, Kualitas dari setiap citra pada dataset ini menurut para pakar sudah di verifikasi memiliki kualitas yang sudah memadai, relevan secara klinis dan tidak ada duplikasi gambar sebagai perwakilan dari DR dan *diabetic macular edema* (DME) yang ditemukan.

Gambar 2 merupakan contoh citra retina mata yang menderita DR, serta bagian masing-masing gejalanya.




Gambar 2. Gambar fundus yang mengandung perbedaan lesi retina yang terkait dengan diabetic retinopathy. Bagian yang membesar menggambarkan adanya microaneurysms, soft exudate, hemorrhages, dan hard exudate


Pada dataset IDRiD ini, terdapat *ground truth* tentang tanda dari DR, DME, dan struktur retina normal. (Porwal et al., 2018) Dari *ground truth dataset* tersebut dilakukan tiga anotasi yang dilakukan, yaitu: Anotasi Tingkat Piksel, Pada tahap awal, Seorang ahli pemrosesan citra ditugaskan memilih 81 citra yang terdiri dari *Microaneurysms*, *Soft Exudate*, *Hemorrhages* dan *Hard Exudates*. Setelah ditentukan, dilanjutkan dengan proses piksel anotasi level oleh siswamaster dengan bantuan perangkat lunak yang dikembangkan khusus oleh ADCIS. Pada Gambar 3 ditunjukkan gambar dari dataset dan kontur yang digambar manual. Setelah diberikan tanda pada citra yang dipilih, selanjutnya dilakukan peninjauan oleh dua spesialis retina dan pada tahap ini juga selesai ketika kesepakatan tercapai. Hasil *ground truth* pada semua lesi dan disk optik dapat dilihat pada Gambar 4.

Selanjutnya adalah DR dan DME *Grading*, Pada dataset citra yang dihasilkan yaitu 516 gambar, dilakukan penilaian variasi kondisi patologis DR dan DME. Citra retina pada pasien penyakit diabetes ini diklasifikasikan menjadi beberapa kelompok yang dimulai dari 0 (DR tidak terlihat jelas) hingga 4 (DR berat).

Terkahir, markup lokasi OD dan pusat fovea, Pada tahap markup pada pusat OD dan fovea dikerjakan oleh mahasiswa master dan PhD. Dalam memperoleh koordinat pusat akhir dilakukan dengan menghitung rata-rata dari dua lokasi. Pada proses akhir markup rata-rata diverifikasi oleh ahli retina.



Gambar 3. a) Hard Exudates (b) Penandaan manual bagian *Hard Exudates* (c) penandaan dari objek lain



Gambar 4. (a) Citra retina pasien diabetes (b) penandaan *ground truth* (c) *Hard Exudates* (d) *Hemorrhages* (e) *Soft Exudate* (f) *Microaneurysms* (g) *Optic Disc*

C. U-Net

U-Net merupakan salah satu jenis arsitektur jaringan syaraf tiruan yang dapat digunakan dalam proses *deep learning* untuk melakukan pemrosesan gambar. Arsitektur ini dikembangkan untuk meningkatkan akurasi dalam melakukan taks segmentasi gambar, yaitu mengelompokkan objek-objek dalam gambar ke dalam kelompok-kelompok yang berbeda (Salman, Grover, & Shankar, 2018). *U-Net* memiliki struktur yang terdiri dari lapisan-lapisan yang saling terkait, dengan lapisan-lapisan yang lebih dalam mewakili informasi yang lebih rinci tentang objek-objek dalam gambar. Arsitektur ini sangat efektif dalam melakukan taks segmentasi citra, karena memiliki kemampuan untuk menangkap detail-detail yang sangat halus.

Arsitektur *U-Net* memiliki dua bagian utama yaitu *encoder* dan *decoder*. Melalui *encoder*, ukuran citra (panjang dan lebar gambar) akan dikurangi sementara jumlah fitur akan ditingkatkan. Pada *decoder*, operasi konvolusi digunakan untuk meningkatkan ukuran citra dan mengurangi jumlah fitur. Proses yang berlawanan dari konvolusi biasa disebut *upsampling* atau *transpose convolution*. Input dari *U-Net* adalah sebuah citra dan outputnya adalah peta segmentasi.

D. Confusion Matrix

Metode Confusion Matrix merupakan sebuah metode berbentuk tabel yang digunakan untuk menggambarkan kinerja model klasifikasi pada satu set data uji yang nilai sebenarnya diketahui (Agarwal, 2014). Adapun bentuk dari tabel Confusion Matrix dapat dilihat pada Tabel 1.

Tabel 1. Tabel Confusion Matrix

Confusion Matrix		Actual Values	
		Positive	Negative
Predictive Values	Positive	True Positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

Pada tahap ini terdapat 3 parameter yang menjadi acuan dalam mengevaluasi, yaitu Persamaan 1 untuk nilai akurasi, Persamaan 2 untuk nilai sensitivitas, serta Persamaan 3 untuk nilai spesifisitas.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$


$$Sensitivity = \frac{TP}{TP + FN} \quad (2)$$

$$Specificity = \frac{TN}{TN + FP} \quad (3)$$


3. HASIL DAN PEMBAHASAN

Berdasarkan hasil penelitian yang sudah dilakukan dalam melakukan penandaan terkait soft exudate, diperoleh hasil sebagai berikut:


Dilakukan tahap segmentasi OD dengan bantuan *growth truth* yang terdapat pada dataset IDRiD. Dengan dilakukan segmentasi ini, bertujuan untuk mengeliminasi informasi yang tidak diperlukan dan mempermudah mendeteksi *soft exudate*. Pada tahap ini didapatkan seperti Gambar 5.

Gambar 5. (a) Citra Original (b) *Growthtruth* OD (c) Setelah dilakukan OD removal

Dilakukan tahap segmentasi *hard exudate* dengan bantuan *growth truth* yang terdapat pada dataset IDRiD. Sama seperti segmentasi OD dengan melakukan segmentasi ini, bertujuan untuk mengeliminasi informasi yang tidak diperlukan dan mempermudah mendeteksi *soft exudate*. Pada tahap ini didapatkan hasil seperti Gambar 6.


Gambar 6. (a) Citra setelah dilakukan OD removal (b) *Ground truth hard exudate* (c) Setelah dilakukan *hard exudate removal*

Tahap ekstraksi fitur warna dilakukan pada kanal RGB dan didapatkan kanal hijau. Hasil dari kanal hijau dapat dilihat seperti Gambar 7.




Gambar 7. (a), (c) Citra sebelum dilakukan proses pemisahan dan ekstraksi kanal hijau (b), (d) Sesudah dilakukan proses

Tahap ini dilakukan perbaikan nilai kontras pada citra untuk menghasilkan visualisasi *soft exudate* yang jelas dengan membuatnya lebih terang dari objek yang lain. Parameter yang digunakan. Pada bagian ini parameter yang digunakan yaitu dengan *cliplimit* adalah 2.0 dan *grid* adalah 8x8. Hasil dari CLAHE dapat dilihat pada Gambar 8.




Gambar 8. (a), (c) Citra Green (b), (d) Citra CLAHE

Dalam tahap ini digunakan untuk mengubah citra *grayscale* menjadi citra biner dengan mengubah nilai *pixel gray* menjadi biner. Dalam penentuan parameter pada tahap ini, perlu membandingkan dengan *ground truth soft exudate* juga agar citra yang dihasilkan pada tahap ini masih memiliki informasi terkait *soft exudate*. Dari pengamatan tersebut parameter yang paling mendekati terdapat pada nilai *pixel grayscale* dengan batas 0 sampai 79 dianggap dengan 0 pada citra biner dan nilai *pixel citra gray* dari 80 sampai 255 dianggap dengan 1 pada biner. Hasil dari tahap ini dapat dilihat pada Gambar 9.



Gambar 9. (a), (d) Citra hasil CLAHE (b), (e) Citra biner (c), (f) Hasil komparasi dengan *ground truth*

Pada tahap *masking* dilakukan dengan menggabungkan citra hasil *thresholding* dengan citra kanal setelah penghilangan OD dan HE. Hasil dari tahap ini dapat dilihat pada Gambar 10.



Gambar 10. (a), (c) Citra biner (b), (d) Citra kanal hijau yang sudah dilakukan *masking*

Pada tahap *training*, dataset citra fundus retina akan melakukan proses pelatihan untuk menghasilkan model yang telah terlatih. Proses ini juga mencakup validasi, yang bertujuan untuk memvalidasi model dan menguji keakuratan hasil *training*. Saat ini, *dataset* yang digunakan untuk proses *training* terdiri dari 14 citra. *Input* citra pada proses *training* memiliki ukuran $256 \times 256 \text{ pixel}$. Spesifikasi perangkat serta parameter yang digunakan dalam proses *training* menggunakan U-Net dapat dilihat pada Tabel 2 dan

Tabel 3.

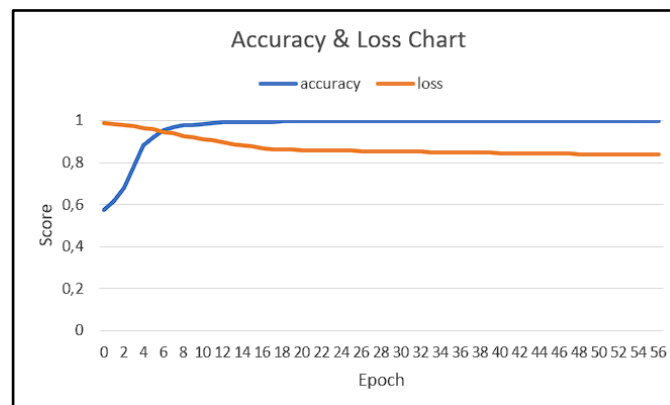
Tabel 2 Spesifikasi Perangkat

CPU	Intel Corei7-11700F @2.50Ghz
GPU	GeForce RTX 3070 NVIDIA
RAM	16 GB

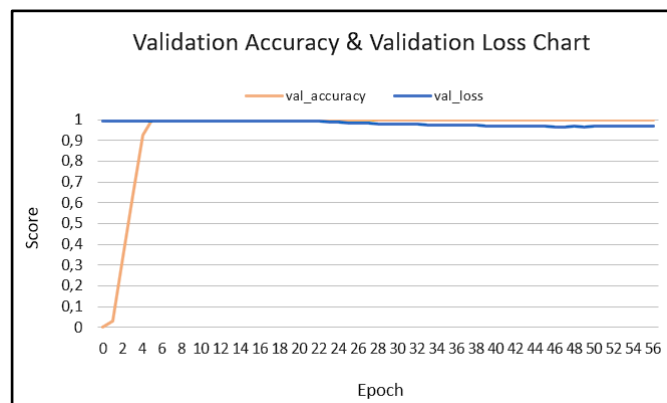
Tabel 3. Detail konfigurasi dari U-Net Layer

Layer Category	Layer	Deskripsi
Input Layer	1	Resize to 256 × 256
	1	Conv 3x3 and Batch Normalization
Encoder Layer	2	ReLU Activation Layer
	3	Max Polling 2 × 2
Bridge Layer	1	Conv 3x3 and Batch Normalization
	2	ReLU Activation Layer
Decoder Layer	1	Conv Transpose 2 × 2
	2	Concatenation with skip features
	3	Conv 3x3 and Batch Normalization
	4	ReLU Activation Layer
Output Layer	1	Conv 1×1 and Sigmoid Activation

Selama proses *training*, *learning time* berhenti pada *epoch* ke-56 dengan hasil *loss* 0,838 dan *accuracy* 0,998 pada saat *validation loss* 0,969 dan *validation accuracy* 0,998. Proses *training* dihentikan pada *epoch* ke-56 karena tidak terjadi peningkatan lagi pada *training loss* dan *validation loss* saat proses berlangsung, dan akan secara otomatis berhenti sesuai dengan parameter *early stopping* selama 10 *epoch*. Gambar 11 dan Gambar 12 menunjukkan visualisasi grafis untuk *loss*, *accuracy*, *validation loss*, dan *validation accuracy*.




Gambar 11. Grafik *loss* dan *accuracy*



Gambar 12. Grafik *validation loss* dan *validation accuracy*

Setelah melakukan proses training pada tahap training model, tahap selanjutnya adalah *evaluation model*, di mana hasil output dari training model akan diuji melalui proses pengujian model untuk melihat hasil segmentasi *soft exudate* dalam bentuk *output* citra. Sama seperti metode berbasis fitur, untuk menilai performa segmentasi *deep learning* dengan menggunakan *U-Net*, kita dapat mencari skor akurasi, sensitivitas, dan spesifisitas. Saat melakukan proses pengujian model, *dataset* citra yang digunakan terdiri dari 7 citra fundus retina yang telah dibagi sebelumnya untuk proses validasi. Dari hasil tersebut, didapatkan rata-rata akurasi, sensitivitas, dan spesifisitas secara berurutan sebesar 0.99586, 0.36203, dan 0.99856. Gambar 13 menunjukkan hasil dari pengujian model segmentasi *soft exudate* menggunakan *U-Net* dan Tabel 4 menunjukkan hasil rerata pada *U-Net*.



Gambar 13. (a) Citra Original (b) Grouthtruth optic disc (c) Setelah dilakuakn removing dengan Grouthtruth optic disc

Tabel 4. Hasil Rata-Rata U-Net

Hasil	Accuracy	Sensitivity	Specifity
Rata-Rata	0.99586	0.36203	0.99856

Hasil yang diperoleh dalam penelitian ini menunjukkan bahwa model *u-net* memiliki kinerja yang sangat baik dalam tugas segmentasi gambar, terutama dalam memprediksi area yang bukan *soft exudate* yang dapat dilihat hasil yang diperoleh dari metode tersebut mendapatkan nilai spesifisitas dengan rata-rata 0.99856. Untuk nilai sensitivitas yang didapatkan dari metode *u-net* memiliki rata-rata nilai 0.36203, yang menunjukkan menunjukkan bahwa model mungkin mengalami kesulitan dalam mengidentifikasi area yang termasuk *soft exudate* dengan tepat. oleh karena itu, perlu dilakukan evaluasi kembali dan pengoptimalan model yang lebih baik untuk meningkatkan sensitivitas model. Untuk akurasi memiliki nilai yang tinggi yaitu dengan rata-rata 0.99586, karena area yang lebih dominan adalah area yang bukan *soft exudate*.

4. SIMPULAN DAN SARAN

Hasil dari evaluasi yang telah dilakukan, didapatkan rata-rata hasil akurasi, sensitivitas, dan spesifisitas secara berurutan sebesar 0.99586, 0.36203, dan 0.99856. Berdasarkan hasil rata-rata yang telah diperoleh, dapat di simpulkan bahwa metode yang diusulkan untuk segmentasi *soft exudate* cukup baik. Namun demikian, terdapat beberapa citra yang kurang baik dalam mensegmentasi *soft exudate* dari segi visual, sehingga skor sensitivitas yang diperoleh relatif rendah.

Berdasarkan hasil evaluasi yang telah didapatkan, diperlukan beberapa penambahan agar hasil evaluasi yang lebih baik. Berikut beberapa saran yang dapat menjadi acuan untuk dikembangkan, yaitu pada proses training pada proses dengan metode *deep learning* dengan *U-Net* memiliki *dataset* yang lebih banyak dan menambahkan metode pada tahap *pre-processing* yang dapat menambahkan metode lain yang dapat membantu memperbaiki kontras

Daftar Pustaka

- Agarwal, S. (2014). Data mining: Data mining concepts and techniques. In *Proceedings - 2013 International Conference on Machine Intelligence Research and Advancement, ICMIRA 2013*. <https://doi.org/10.1109/ICMIRA.2013.45>
- Badar, M., Shahzad, M., & Fraz, M. M. (2018). Simultaneous segmentation of multiple retinal pathologies

- using fully convolutional deep neural network. *Communications in Computer and Information Science*, 894, 313–324. https://doi.org/10.1007/978-3-319-95921-4_29
- Bagus, I., Mahadya, L., Sudarma, M., Kumara, I. N. S., & Optimizer, A. (2020). Resonance Imaging dengan Menggunakan Metode U-NET. *Majalah Ilmiah Teknologi Elektro*, 19(2), 151–156.
- Bui, T., Maneerat, N., & Watchareeruetai, U. (2017). Detection of cotton wool for diabetic retinopathy analysis using neural network. *2017 IEEE 10th International Workshop on Computational Intelligence and Applications, IWCI A 2017 - Proceedings, 2017-Decem*, 203–206. <https://doi.org/10.1109/IWCI A.2017.8203585>
- Joshua, A. O., Nelwamondo, F. V., & Mabuza-Hocquet, G. (2020). Blood Vessel Segmentation from Fundus Images Using Modified U-net Convolutional Neural Network. *Journal of Image and Graphics*, 8(1), 21–25. <https://doi.org/10.18178/joig.8.1.21-25>
- Manullang, Y. R., Rares, L., & Sumual, V. (2016). Prevalensi Retinopati Diabetik Pada Penderita Diabetes Melitus Di Balai Kesehatan Mata Masyarakat (Bkmm) Propinsi Sulawesi Utara Periode Januari – Juli 2014. *E-CliniC*, 4(1). <https://doi.org/10.35790/ecl.4.1.2016.11024>
- Mustafa, N., Zhao, J., Liu, Z., Zhang, Z., & Yu, W. (2020). Iron ORE Region Segmentation Using High-Resolution Remote Sensing Images Based on Res-U-Net. *International Geoscience and Remote Sensing Symposium (IGARSS)*, c, 2563–2566. <https://doi.org/10.1109/IGARSS39084.2020.9324218>
- Naufal, A. A. (2018). *0511144000041-Ahmad-Afiif-Naufal-Buku_TA dengan Lembar Pengesahan*.
- Porwal, P., Pachade, S., Kamble, R., Kokare, M., Deshmukh, G., Sahasrabuddhe, V., & Meriaudeau, F. (2018). Indian diabetic retinopathy image dataset (IDRiD): A database for diabetic retinopathy screening research. *Data*, 3(3), 1–8. <https://doi.org/10.3390/data3030025>
- Prastyo, P. H., Sumi, A. S., & Nuraini, A. (2020). Optic Cup Segmentation using U-Net Architecture on Retinal Fundus Image. *JITCE (Journal of Information Technology and Computer Engineering)*, 4(02), 105–109. <https://doi.org/10.25077/jitce.4.02.105-109.2020>
- Putra, I. M. A. D., Maysanjaya, I. Md. 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).
- Salman, H., Grover, J., & Shankar, T. (2018). *Hierarchical Reinforcement Learning for Sequencing Behaviors*. 2733(March), 2709–2733. <https://doi.org/10.1162/NECO>
- Sreng, S., Maneerat, N., Hamamoto, K., & Panjaphongse, R. (2019). Cotton wool spots detection in diabetic retinopathy based on adaptive thresholding and ant colony optimization coupling support vector machine. *IEEJ Transactions on Electrical and Electronic Engineering*, 14(6), 884–893. <https://doi.org/10.1002/tee.22878>
- Sreng, S., Maneerat, N., Win, K. Y., Hamamoto, K., & Panjaphongse, R. (2019). Classification of Cotton Wool Spots Using Principal Components Analysis and Support Vector Machine. *BMEiCON 2018 - 11th Biomedical Engineering International Conference*, 1–5. <https://doi.org/10.1109/BMEiCON.2018.8609962>
- Suardika, I. G. P. D., Maysanjaya, I. Md. D., & Kesiman, M. W. A. (2022). Optic Disc Segmentation Based on Mask R-CNN in Retinal Fundus Images. *2022 4th International Conference on Biomedical Engineering (BIOMED)*, 71–74.
- Sudha, S., Srinivasan, A., & Gayathri Devi, T. (2019). Detection and classification of cotton wool spots in diabetic retinopathy. *International Journal of Recent Technology and Engineering*, 8(3), 4472–4475. <https://doi.org/10.35940/ijrte.C6805.098319>
- Suta, I. B. L. M., Sudarma, M., & Satya Kumara, I. N. (2020). Segmentasi Tumor Otak Berdasarkan Citra Magnetic Resonance Imaging Dengan Menggunakan Metode U-NET. *Majalah Ilmiah Teknologi Elektro*, 19(2), 151. <https://doi.org/10.24843/mite.2020.v19i02.p05>