
PENDEKATAN BERBASIS U-NET UNTUK SEGMENTASI *HARD EXUDATE* DALAM CITRA FUNDUS RETINA

I Made Angga Darma Putra¹, I Md. Dendi Maysanjaya^{2,*}, Made Windu Antara Kesiman³

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

Abstrak

Menurut perkiraan *World Health Organization (WHO)*, secara global, 422 juta orang dewasa di atas usia 18 tahun hidup dengan diabetes pada tahun 2014. Ini didukung oleh perkiraan *World Diabetes Foundation* bahwa lebih dari 439 juta orang akan terancam oleh diabetes pada tahun 2030. Salah satu penyakit yang disebabkan oleh diabetes adalah *diabetic retinopathy* yang dapat menyebabkan gangguan penglihatan hingga kebutaan. Kerusakan pembuluh darah dan kerusakan pada serabut saraf mata disebut *exudate*, yang merupakan bintik-bintik darah yang mengandung lemak berwarna kekuningan yang memiliki bentuk tidak menentu. Untuk mengetahui letak *hard exudate* pada citra fundus retina, dokter mata masih melihat dan mencari secara manual. Oleh karena itu, penelitian ini, berkontribusi pada segmentasi *hard exudate* menggunakan metode *U-Net*, dengan mengukur skor metrik *accuracy*, *sensitivity*, dan *specificity*. Dataset retina yang digunakan pada penelitian ini berasal dari *Indian Diabetic Retinopathy Image Dataset (IDRiD)*, sebanyak 81 citra, yang terdiri atas 54 citra *training* dan 27 citra *testing*. Alur penelitian dibagi menjadi dua bagian. *Training Model* dan *Evaluation Model*. *Training Model* melibatkan pelatihan sejumlah dataset citra untuk menghasilkan model yang terlatih. Proses *training* juga mencakup validasi untuk mengukur keakuratan model. *Evaluation Model* melibatkan pengujian model yang telah dilatih menggunakan dataset citra yang tidak digunakan selama pelatihan. Hasil segmentasi *hard exudate* menunjukkan untuk skor metrik *U-Net* masing-masing adalah 0.993, 0.454, dan 0.997.

Kata Kunci:

Diabetic Retinopathy, Hard Exudate, Segmentation, U-Net

Abstract

According to *World Health Organization (WHO)* estimates, globally, 422 million adults over the age of 18 were living with diabetes in 2014. This is supported by the *World Diabetes Foundation's* estimate that more than 439 million people will be threatened by diabetes by 2030. One of the diseases caused by diabetes is *diabetic retinopathy*, which can cause visual impairment up to blindness. Blood vessel damage and damage to the nerve fibers of the eye are called *exudates*, which are yellowish, fat-containing blood spots that have an erratic shape. To find out the location of *hard exudate* on the retinal fundus image, ophthalmologists still look and search manually. Therefore, this research contributes to *hard exudate* segmentation using the *U-Net* method by measuring the *accuracy*, *sensitivity*, and *specificity* metric scores. The retinal dataset used in this study comes from the *Indian Diabetic Retinopathy Image Dataset (IDRiD)*, totaling 81 images, consisting of 54 training images and 27 testing images. The research flow is divided into two parts. *Training Model* and *Evaluation Model*. The training model involves training a number of image datasets to produce a trained model. The training process also includes validation to measure the accuracy of the model. The evaluation model involves testing the trained model using image datasets that were not used during training. The *hard exudate* segmentation results show *U-Net* metric scores of 0.993, 0.454, and 0.997, respectively.

Keywords:

Diabetic Retinopathy, Hard Exudate, Segmentation, U-Net

*Korespondensi

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

1. PENDAHULUAN

Menurut perkiraan *World Health Organization (WHO)*, secara global, 422 juta orang dewasa di atas usia 18 tahun hidup dengan diabetes pada tahun 2014. Ini didukung oleh perkiraan *World Diabetes Foundation* bahwa lebih dari 439 juta orang akan terancam oleh diabetes pada tahun 2030. Ini terkait dengan populasi yang semakin tua dan obesitas yang disebabkan oleh gaya hidup tidak sehat. Peningkatan diabetes ini akan terjadi paling banyak di negara berkembang, yang disebabkan oleh pertumbuhan populasi, penuaan, diet tidak sehat, obesitas, dan gaya hidup tidak sehat yang kurang aktif (Mane & Jadhav, 2014).

Diabetic retinopathy adalah gangguan pada mata yang terjadi pada penderita diabetes. Kondisi mata dapat menyebabkan kehilangan penglihatan dan kebutaan. Gangguan ini disebabkan oleh kerusakan pada pembuluh darah jaringan belakang mata, yaitu retina. Faktor risiko yang menyebabkannya adalah kontrol gula darah yang buruk. Kerusakan pada pembuluh darah dan kerusakan pada serat saraf mata disebut *exudate*, yang berisi bintik darah yang berwarna kuning dengan bentuk yang tidak teratur. Jenis *exudate* dibagi menjadi dua, yaitu *hard exudate* dan *soft exudate*. *Soft exudate* juga dikenal sebagai *cotton wool spots* dan muncul dengan warna putih dengan tepi yang kurang jelas. Sementara *hard exudate* terjadi karena bocoran protein dan pembuluh lipid retina. Bentuknya terlihat tajam dan cerah (Nugroho, Oktoeberza, Adji, & Sasongko, 2015).

Hard exudate terdiri terutama dari lipid ekstrasellular yang bocor dari kapiler retina abnormal, sehingga sering terdapat edema retina (tidak terlihat menggunakan oftalmoskopi langsung). Masalah yang mendasar sering terlihat sebagai *exudate* akan membentuk cincin atau pola '*circinate*' sekitar pembuluh yang bocor (yang dapat dilihat sebagai kelompok mikroaneurisma). *Hard exudate* ditemukan terutama di wilayah makula dan saat lipid berpadu dan menjangkau *central macula (fovea)*, maka penglihatan bisa sangat terganggu.

Untuk mengetahui letak *hard exudate* pada citra fundus retina, para ahli mata atau dokter masih melihat dan mencari atau menganotasi secara manual sehingga membutuhkan waktu yang lama untuk mengetahui letak *hard exudate*. Tantangan lain adalah retina yang *diabetic retinopathy* memiliki banyak karakteristik atau bagian seperti *optic discs*, *microaneurysms*, *hemorrhages*, dan *soft exudate*. Maka sangat diterima bahwa segmentasi *hard exudate* pada citra retina yang berwarna memainkan peran penting dalam diagnosis *diabetic retinopathy* karena dapat memantau perkembangan pengobatan dan mengetahui bentuk dan letak *hard exudate* dengan cepat. Oleh karena itu, segmentasi *hard exudate* menjadi fokus utama dari penelitian ini (Long et al., 2019).

Dalam penelitian ini, tujuannya adalah melakukan proses segmentasi *hard exudate* dengan menggunakan pemrosesan citra digital dan *deep learning* sehingga dapat melakukan segmentasi *hard exudate* dengan lebih cepat daripada dengan metode manual. Metode yang digunakan untuk melakukan segmentasi *hard exudate* pada citra fundus *diabetic retinopathy* adalah *U-Net* karena karakteristik pada masalah ini memberikan *U-Net* dengan kegunaan yang tinggi dalam komunitas citra medis dan telah menghasilkan adopsi yang luas dari *U-Net* sebagai alat utama untuk tugas segmentasi dalam citra medis (Siddique, Paheding, Elkin, & Devabhaktuni, 2021).

Penelitian yang terkait dengan *U-Net* yang dilakukan oleh Prasetyo, et al (Prastyo, Sumi, & Nuraini, 2020) dengan hasil eksperimen pada segmentasi optic cup atau *optic disc*, kinerja segmentasi optic cup mencapai 98,42% untuk *Dice coefficient* dengan *loss* 0,15. Hasil tersebut menunjukkan bahwa metode yang penulis usulkan berhasil dalam segmentasi optic cup pada citra fundus retina warna dengan sangat baik. Selain itu, penelitian lain yang menggunakan *U-Net* untuk segmentasi gambar dilakukan oleh Joshua, et. al (Joshua, Nelwamondo, & Mabuza-Hocquet, 2020) untuk memisahkan pembuluh darah dari citra fundus dengan *sensitivity* sebesar 0,8309, 0,7796, 0,7506, 0,8059 dan *specificity* 0,9742, 0,9864, 0,9824 dan 0,9826 dicapai pada tiap database citra *DRIVE*, *CHASE_DB1*, *STARE* dan *HRF* di masing-masingnya.

Alasan penulis menggunakan metode *U-Net* untuk memsegmentasi *hard exudate* karena *U-Net* adalah *Fully Convolutional Network (FCN)* yang diterapkan pada segmentasi citra biomedik, yang terdiri dari *encoder*, modul *bottleneck*, dan *decoder*. *U-Net* yang banyak digunakan memenuhi syarat segmentasi citra medis dengan struktur berbentuk U-nya, kombinasi informasi konteks, kecepatan training yang cepat, dan sedikit data yang digunakan (Yin, Sun, Fu, Lu, & Zhang, 2022). Berdasarkan keunggulan yang dimiliki metode *U-Net*, pada penelitian ini dilakukan suatu studi untuk memsegmentasi *hard exudate* menggunakan metode *U-Net*.

Berdasarkan penelitian sebelumnya mengenai segmentasi *exudate* dengan proses pengolahan citra digital, terdapat beberapa penelitian yang relevan dengan penelitian yang akan dilakukan antara lain sebagai berikut:

Penelitian dilakukan oleh Noriandi Dewi Salyasari dengan judul "Implementasi Segmentasi *Hard Exudates* Pada *Diabetic Retinopathy* Untuk Citra Fundus Retina". Dalam tulisan ini, segmentasi eksudat keras gambar fundus retina menggunakan metode algoritma *Fuzzy C Means (FCM)* dengan korelasi spasial

mampu mengelompokkan *hard exudate* secara otomatis (Salyasari, Tjandrasa, & Wijaya, 2016). Penelitian lain dilakukan oleh Hanung Adi Nugroho dengan judul "*Segmentation of Exudates Based on High Pass Filtering in Retinal Fundus Images*" of (Nugroho et al., 2015). Pada paper tersebut, segmentasi *hard exudate* pada citra fundus retina menggunakan metode *High Pass Filtering*. Penelitian lain terkait segmentasi *hard exudate* dilakukan oleh Nugroho. dengan judul "*Automated Segmentation of Hard Exudates Based on Matched Filtering*". Dalam penelitian dilakukan segmentasi *hard exudate* dengan menggunakan metode *matched filtering* (Nugroho, Oktoeberza, Ardiyanto, Buana, & Sasongko, 2017).


Berdasarkan penelitian sebelumnya, penelitian ini berfokus pada segmentasi *hard exudate* dengan salah satu metode *deep learning* yaitu *U-Net* dengan harapan segmentasi *hard exudate* lebih baik dibandingkan metode lain yang telah digunakan.

2. METODE

A. Dataset


Dataset citra retina yang digunakan berasal dari himpunan data yang sudah tersedia di Indian Diabetic Retinopathy Image Dataset (IDRiD) (Porwal et al., 2018) website. *Dataset* pada website dibagi menjadi tiga bagian folder, yaitu: *Segmentation*, *Disease Grading*, dan *Localization*. Namun, *dataset* yang akan digunakan untuk penelitian ini hanyalah dataset bagian folder *Segmentation*. Bagian *Segmentation* terdiri dari dua bagian folder lagi, yaitu *Original Image* dan *All Segmentation Groundtruth*. Dimana *Original Image* terdiri dari 81 gambar retina untuk *train set* dan *test set* dalam format citra jpg. Sedangkan *All Segmentation Groundtruths* terdiri dari *Groundtruth Microaneurysms*, *Haemorrhages*, *Hard Exudates*, *Soft Exudates*, dan *Optic Disc* dengan format *TIF*. Dataset *IDRiD* ini merupakan citra *RGB* yang memiliki resolusi 4288 x 2848 piksel. Untuk penelitian ini, hanya diperlukan dataset *Hard Exudates* yang telah dibagi ke dalamnya, yaitu Training Set sebanyak 54 citra dan Testing Set sebanyak 27 citra kemudian diikuti juga dengan *groundtruth* dengan jumlah *Training Set* dan *Testing Set* yang sama. Kemudian untuk *groundtruth* perlu dibinarisasi karena *groundtruth* yang tersedia pada dataset *IDRiD* masih berupa gambar *RGB*.

Citra fundus dalam database *IDRiD* diperoleh dari Klinik Mata yang berlokasi di Nanded, (M.S.), India. Citra retina manusia yang menderita *diabetic retinopathy* diambil pada jarak 39 mm antara lensa dan mata menggunakan kamera fundus noninvasif yang dilengkapi dengan *flashlight xenon*.



Gambar 1. 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 gambar 2 menampilkan visualisasi dataset citra fundus yang tersedia pada dataset *IDRiD* dan Gambar 3 menampilkan contoh *groundtruth* dari gambar dataset *IDRiD*.



Gambar 2. Contoh citra dataset. Gambar di sebelah kiri adalah citra dataset, gambar di tengah adalah citra *groundtruth*, dan gambar di sebelah kanan adalah citra *groundtruth* yang sudah di binarisasi

B. Arsitektur U-Net

Metode yang digunakan dalam penelitian ini menggunakan *U-Net*. *U-Net* merupakan salah satu arsitektur yang dibangun dari basis *Fully Convolutional Network (FCN)* yang telah dimodifikasi sehingga dapat mensegmentasi citra medis dengan baik.



Gambar 3. Ilustrasi dari struktur jaringan konvolusi U-Net


Gambar 3 menunjukkan ilustrasi struktur jaringan konvolusi *U-Net*. Sisi kiri dari bentuk-U adalah tahap *encoding*, juga disebut *contraction path* dengan setiap *layer* yang terdiri dari dua 3×3 konvolusi dengan aktivasi ReLU dan 2×2 *maximum pooling layer*. Sisi kanan bentuk-U, juga disebut *expansion part*, terdiri dari tahap *decoding* dan proses *up-sampling* yang direalisasikan melalui 2×2 dekonvolusi untuk mengurangi jumlah saluran *input channel* hingga setengahnya.

Tabel 1. Parameter Model U-Net

<i>Parameters</i>	<i>Description</i>
<i>Batch Size</i>	2
<i>Size of Input Image</i>	256 x 256
<i>Optimizer</i>	<i>Adam</i>
<i>Learning Rate</i>	0.0001
<i>Activation Function</i>	<i>ReLU and Sigmoid</i>
<i>Early Stopping</i>	<i>val_loss (10 epoch)</i>
<i>Filter Size</i>	64, 128, 256, 512

C. Metodologi

Gambar 6 menampilkan alur kerja metode dari *U-Net* yang akan dijalankan. Metode ini akan dibagi menjadi dua bagian, yaitu *Training Model* dan *Evaluation Model*. *Training Model* adalah proses melatih beberapa dataset citra untuk mendapatkan data model yang sudah terlatih. Dalam proses *training* ini juga terdapat proses *validation* di dalamnya untuk memakan model dan menguji hasil *training* apakah akurat atau tidak. *Evaluation model* adalah mengevaluasi dan mencoba menguji model yang diperoleh dari proses *training* dengan menggunakan dataset citra yang belum atau tidak digunakan selama proses *training*.



Gambar 4. Alur kerja segmentasi *hard exudate* menggunakan U-Net

Berikut adalah penjelasan lebih rinci dari alur kerja pada gambar diatas:

1) *Training Model*

- a) Langkah pertama adalah melatih model menggunakan sejumlah dataset citra. Dataset ini terdiri dari citra-citra yang telah dikategorikan dan diberi label yang sesuai.
- b) Citra-citra tersebut digunakan sebagai input untuk melatih model. Model akan belajar untuk mengenali pola dan fitur dari citra-citra tersebut.
- c) Selama proses pelatihan, terdapat tahap validasi yang digunakan untuk mengevaluasi kinerja model. Model yang dilatih akan diuji dengan menggunakan subset dataset yang tidak digunakan selama proses pelatihan. Hasil dari validasi ini akan memberikan informasi tentang seberapa akurat model dalam mengenali pola pada citra-citra yang belum pernah dilihat sebelumnya.
- d) Proses pelatihan akan dilakukan berulang kali dengan mengoptimalkan parameter-model yang sudah ditentukan. Hal ini bertujuan untuk meningkatkan kinerja dan akurasi model

2) *Evaluation Model*

- a) Setelah model selesai dilatih, tahap selanjutnya adalah melakukan evaluasi pada model yang telah diperoleh.

- b) Evaluasi dilakukan dengan menggunakan dataset citra yang tidak digunakan selama proses pelatihan. Tujuannya adalah untuk menguji kinerja model pada citra-citra yang belum pernah dilihat sebelumnya.
- c) Model akan memproses citra-citra evaluasi dan menghasilkan prediksi atau segmentasi berdasarkan pola dan fitur yang telah dipelajari selama proses pelatihan.
- d) Hasil segmentasi dari model akan dibandingkan dengan citra referensi atau *ground truth* yang telah diberi label oleh ahli. Perbandingan ini dilakukan untuk mengukur akurasi segmentasi model dalam mengenali dan memisahkan *hard exudate* pada citra retina.
- e) Evaluasi model dapat dilakukan dengan menggunakan metrik evaluasi kualitatif dan kuantitatif, seperti *accuracy*, *sensitivity*, dan *specificity*. Metrik ini memberikan informasi tentang seberapa baik model dalam mengenali dan memisahkan *hard exudate* pada citra retina.

Dengan mengikuti alur kerja tersebut, metode U-Net dapat digunakan untuk melatih dan menguji model segmentasi *hard exudate* pada citra retina dengan menggunakan dataset yang telah disiapkan.

Metode yang diusulkan kemudian dievaluasi dengan mempertimbangkan pengukuran statistik menggunakan performansi metrik: *accuracy*, *sensitivity*, dan *specificity*. Ada empat parameter yang digunakan, antara lain *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN), yang dinyatakan dengan persamaan (1) hingga persamaan (3). Persamaan dari *accuracy*, *sensitivity*, dan *specificity* seperti berikut:

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

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

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

3. HASIL DAN PEMBAHASAN

Bagian ini akan menjelaskan hasil dari alur kerja di bagian metode dan kemudian mengevaluasi metode menggunakan *accuracy*, *sensitivity*, dan *specificity*.

Perlu diketahui untuk distribusi atau pembagian dataset untuk proses *training* dan *testing*, disesuaikan dengan dataset default dari citra *idrid*. Dimana untuk dataset *training set* ada sebanyak 54 citra sedangkan *validation* dan *testing set* disini dibagi dari dataset *testing set* yang ada pada default folder dataset *idrid* yang semula 27 citra setelah itu dibagi dua menjadi 14 citra untuk *validation set* dan 13 citra untuk *testing set*. Kemudian tinggi dan lebar citra, diubah menjadi 256 x 256 piksel. *Groundtruth* sendiri perlu di-binarisasi karena *groundtruth* yang tersedia pada dataset *idrid* masih berupa citra rgb.


Setelah proses *training* dilakukan, *learning time* dalam proses *training* berhenti pada *epoch* ke-55 karena tidak ada lagi peningkatan *validation loss* dalam proses *training* dimana sesuai dengan parameter *u-net* yang digunakan yaitu *early stopping 10 epoch*.

Tabel 2. Data hasil training untuk epoch, loss, validation loss, accuracy, dan validation accuracy


Epoch	Loss	Validation Loss	Accuracy	Validation Accuracy
0	0,97	0,98	0,55	0,01
1	0,96	0,98	0,82	0,89
2	0,94	0,98	0,93	0,98
3	0,93	0,98	0,94	0,99
4	0,92	0,98	0,95	0,99
5	0,91	0,98	0,96	0,99

Epoch	Loss	Validation Loss	Accuracy	Validation Accuracy
6	0,90	0,97	0,97	0,99
7	0,89	0,97	0,97	0,99
8	0,88	0,97	0,97	0,98
9	0,89	0,97	0,96	0,89
10	0,88	0,97	0,97	0,14
11	0,87	0,95	0,98	0,99
12	0,86	0,94	0,98	0,99
13	0,85	0,92	0,98	0,99
14	0,84	0,91	0,98	0,99
15	0,84	0,93	0,98	0,99
16	0,83	0,88	0,98	0,95
17	0,81	0,85	0,99	0,99
18	0,80	0,82	0,99	0,98
19	0,79	0,80	0,99	0,99
20	0,77	0,79	0,99	0,99
21	0,76	0,80	0,99	0,99
22	0,74	0,76	0,99	0,99
23	0,73	0,78	0,99	0,99
24	0,72	0,76	0,99	0,99
25	0,70	0,78	0,99	0,99
26	0,70	0,75	0,99	0,99
27	0,70	0,78	0,99	0,99
28	0,67	0,75	0,99	0,99
29	0,65	0,75	0,99	0,99
30	0,64	0,70	0,99	0,99
31	0,63	0,75	0,99	0,99
32	0,61	0,73	0,99	0,99
33	0,59	0,69	0,99	0,99
34	0,57	0,67	0,99	0,99
35	0,55	0,68	0,99	0,99
36	0,54	0,65	0,99	0,99

Epoch	Loss	Validation Loss	Accuracy	Validation Accuracy
37	0,52	0,67	0,99	0,99
38	0,53	0,62	0,99	0,99
39	0,50	0,62	1,00	0,99
40	0,47	0,60	1,00	0,99
41	0,46	0,63	1,00	0,99
42	0,44	0,62	1,00	0,99
43	0,43	0,63	1,00	0,99
44	0,43	0,57	1,00	0,99
45	0,42	0,54	1,00	0,99
46	0,43	0,60	1,00	0,99
47	0,40	0,62	1,00	0,99
48	0,41	0,61	1,00	0,99
49	0,38	0,54	1,00	0,99
50	0,36	0,61	1,00	0,99
51	0,35	0,55	1,00	0,99
52	0,33	0,55	1,00	0,99
53	0,32	0,55	1,00	0,99
54	0,31	0,56	1,00	0,99
55	0,31	0,55	1,00	0,99



Gambar 5. Grafik *loss* dan *accuracy*




Gambar 6. Grafik *validation loss* dan *validation accuracy*


Saat proses *training* berjalan kemudian learning time berhenti pada saat *epoch* ke-55 dengan hasil *loss* 0.307 dan *accuracy* 0.997 sedangkan *validation loss* 0.554 dan *validation accuracy* 0.989. Proses *training* berhenti di *epoch* ke-55 dikarenakan tidak ada lagi penurunan *validation loss* pada saat proses berjalan dan kemudian akan otomatis berhenti sesuai dengan paramater *early stopping* sebanyak 10 *epoch* dapat dilihat pada Tabel 2 untuk *validation loss* pada saat saat *training* untuk tiap *epoch*.

Pada gambar 5 terlihat untuk visualisasi grafik pada *loss* terlihat ada penurunan yang baik dalam proses *training* pada tiap *epoch* dengan *loss* akhir yang didapatkan sebesar 0.307 dan untuk *accuracy* terus meningkat hingga 0.997. Kemudian pada gambar 6 terlihat visualisasi grafik pada *validation loss* terjadi nilai yang naik dan turun pada proses *training* hingga pada akhirnya tidak lagi terjadi penurunan nilai sebanyak 10 *epoch* dan berhenti dengan nilai *validation loss* sebesar 0.554. Sedangkan *validation accuracy* terlihat naik dan turun yang drastis saat proses *training* berjalan hingga pada akhirnya nilai akhir dari *validation accuracy* sebesar 0.989.

Setelah proses segmentasi menggunakan metode *U-Net* dilakukan, tahap selanjutnya adalah mengevaluasi setiap metode menggunakan *accuracy*, *sensitifity*, dan *specifity*. Perlu diketahui untuk *accuracy* adalah ada berapa banyak yang berhasil benar diprediksi *hard exudate* dan yang tidak benar diprediksi *hard exudate* dari keseluruhan citra fundus retina. Untuk *sensitifity* adalah dari semua citra fundus retina yang memiliki *hard exudate*, berapa banyak yang benar diprediksi *hard exudate*. Kemudian untuk *specificity* adalah berapa banyak citra fundus retina yang benar di prediksi tidak memiliki *hard exudate* di dibandingkan dengan keseluruhan citra fundus retina yang sebenarnya tidak memiliki *hard exudate*. Maka kenapa nilai dari *sensitifity* lebih kecil dibandingkan dengan *accuracy*, dan *specificity* karena banyaknya yang di prediksi benar *hard exudate* dari seluruh citra yang sebenarnya memiliki *hard exudate* masih sedikit.

Hasil untuk *accuracy* adalah 0.993, *sensitifity* 0.454, dan *specifity* 0.997. Hasil yang diperoleh setelah pengujian dari 13 citra *testing set* diperoleh hasil yang dapat dilihat pada Gambar 7. Dari segi visual, ditemukan hasil yang cukup baik dalam mensegmentasi *hard exudate* yang dibandingkan dengan *groundtruth*. Akan tetapi hanya ada beberapa hasil segmentasi *hard exudate* yang kurang atau bahkan tidak terdeteksi dengan baik. Skor metrik yang didapatkan setelah dilakukan tahapan *evaluation model* yaitu: *accuracy* 0.993 *sensitifity* 0.454, dan *specifity* 0.997.





Gambar 7. Contoh hasil *output* segmentasi menggunakan metode *U-Net*. Gambar di sebelah kiri adalah citra input, gambar di tengah adalah citra *groundtruth*, dan gambar di sebelah kanan adalah citra yang dihasilkan dari prediksi *U-Net* (Hasil prediksi memiliki dimensi citra yang berbeda karena selama proses *training* dan *evaluasi* citra retina diubah menjadi 256 x 256 pixel)

4. SIMPULAN DAN SARAN

Dalam penelitian ini, penulis mengusulkan metode *deep learning* menggunakan *U-Net* untuk mensegmentasi *hard exudate* pada citra fundus retina. Metode yang kami usulkan menggunakan total 81 citra fundus retina RGB di mana 54 citra *training set* untuk proses *training*, 14 citra *validation set* untuk proses *validation*, dan 13 citra *testing set* untuk proses *testing*. Kemudian proses *training* otomatis berhenti pada *epoch* ke-55 karena tidak ada lagi peningkatan *validation loss* selama proses *training* berjalan. Hasil *training* memperoleh untuk *loss* 0.307, *accuracy* 0.997, *validation loss* 0.554, dan *validation accuracy* 0.989. Setelah proses *training* selesai dan memperoleh *training model*, segmentasi hasil *training model* dibandingkan dengan *groundtruth* kemudian dievaluasi diperoleh untuk *accuracy* 0.993, *sensitifity* 0.454, dan *specifity* 0.997. Dari hasil tersebut, metode yang diusulkan sudah cukup baik dalam segmentasi *hard exudate* jika dilihat dari skor *accuracy* dan *specifity* yang mendapatkan skor yang tinggi. Akan tetapi, dari segi visual ada beberapa citra yang kurang baik dalam mensegmentasi *hard exudate* sehingga mendapatkan skor yang kecil di *sensitifity*.

Dalam studi berikutnya, penulis melihat mungkin masih ada tahapan yang perlu ditingkatkan atau ditambahkan, misalnya *pre-processing* dataset terlebih dahulu sebelum segmentasi dengan *U-Net* atau memerlukan untuk mengacak atau menggunakan metode *folding* untuk membagi dari 81 total *dataset*. Sehingga, memungkinkan untuk menghasilkan kinerja yang lebih baik

Daftar Pustaka

- 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>
- Long, S., Huang, X., Chen, Z., Pardhan, S., Zheng, D., & Scalzo, F. (2019). Automatic detection of hard exudates in color retinal images using dynamic threshold and SVM classification: Algorithm development and evaluation. *BioMed Research International*, 2019. <https://doi.org/10.1155/2019/3926930>
- Mane, V. M., & Jadhav, D. V. (2014). Progress towards automated early stage detection of diabetic retinopathy: Image analysis systems and potential. *Journal of Medical and Biological Engineering*, 34(6), 520–527. <https://doi.org/10.5405/jmbe.2060>
- Nugroho, H. A., Oktoeberza, K. Z. W., Adji, T. B., & Sasongko, M. B. (2015). Segmentation of exudates based on high pass filtering in retinal fundus images. *Proceedings - 2015 7th International Conference on Information Technology and Electrical Engineering: Envisioning the Trend of Computer, Information and Engineering, ICITEE 2015*, 436–441. <https://doi.org/10.1109/ICITEED.2015.7408986>
- Nugroho, H. A., Oktoeberza, K. Z. W., Ardiyanto, I., Buana, R. L. B., & Sasongko, M. B. (2017). Automated segmentation of hard exudates based on matched filtering. *Proceeding - 2016 International Seminar*

- on *Sensors, Instrumentation, Measurement and Metrology, ISSIMM 2016*, 84–87. <https://doi.org/10.1109/ISSIMM.2016.7803728>
- 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>
- Salyasari, N. D., Tjandrasa, H., & Wijaya, A. Y. (2016). *Implementasi segmentasi hard exudates pada diabetic retinopathy untuk citra fundus retina*. (February), 1–7.
- Siddique, N., Paheding, S., Elkin, C. P., & Devabhaktuni, V. (2021). U-net and its variants for medical image segmentation: A review of theory and applications. *IEEE Access*, 82031–82057. <https://doi.org/10.1109/ACCESS.2021.3086020>
- Yin, X. X., Sun, L., Fu, Y., Lu, R., & Zhang, Y. (2022). U-Net-Based Medical Image Segmentation. *Journal of Healthcare Engineering*, 2022. <https://doi.org/10.1155/2022/4189781>