

## **Diskus Optik dan Segmentasi Cawa Optik untuk Glaukoma Deteksi dari Gambar Retina Buram Menggunakan Mask-RCNN yang Ditingkatkan**

**Abdul Majid<sup>1</sup>, Anggada Alif Fahrizal<sup>2</sup>, M. Abi Syihab Alkhornain<sup>3</sup>, Putra Arda Imawan<sup>4</sup>**

<sup>1,4</sup>Ilmu Komputer, Teknik Informatika, Universitas Pamulang, Tangerang Selatan, Indonesia

Email: <sup>1</sup>[abdulmajid.040601@gmail.com](mailto:abdulmajid.040601@gmail.com), <sup>2</sup>[anggadaalif@gmail.com](mailto:anggadaalif@gmail.com), <sup>3</sup>[mabisyihab@gmail.com](mailto:mabisyihab@gmail.com),

<sup>4</sup>[ptrarda27@gmail.com](mailto:ptrarda27@gmail.com)

**Abstrak**– Glaukoma, penyakit mata yang melemahkan yang menyebabkan kerusakan optic disc (OD) dan optic cup (OC), yang akhirnya menyebabkan kebutaan pada stadium lanjut, menimbulkan tantangan untuk identifikasi dini karena perkembangannya yang lambat dan gejala awal yang terbatas. Oleh karena itu, kerangka kerja otomatis sangat penting untuk membantu skrining dan meningkatkan deteksi penyakit tahap awal. Dalam penelitian ini, kami fokus pada lokalisasi dan segmentasi OD dan OC dalam gambar retina kabur untuk deteksi glaukoma. Untuk mengatasi tantangan tersebut, kami mengusulkan pendekatan baru, yaitu Mask-RCNN berbasis Densenet-77. Kami mulai dengan menambah kumpulan data dan memperkenalkan keburaman untuk meningkatkan keragaman data. Selanjutnya, kami membuat anotasi dari gambar ground-truth (GT). Kerangka kerja Densenet-77 kemudian digunakan dalam fase ekstraksi fitur dari Mask-RCNN untuk menghitung poin-poin penting yang mendalam. Selanjutnya, fitur yang dihitung ini digunakan oleh model Mask-RCNN yang disesuaikan untuk melokalkan dan menyegmentasikan OD dan OC. Evaluasi kinerja dilakukan pada kumpulan data ORIGA yang tersedia untuk umum, dan validasi lintas kumpulan data dilakukan menggunakan database HRF untuk menunjukkan ketahanan kerangka kerja. Kerangka kerja yang disajikan mencapai rata-rata presisi, daya ingat, ukuran-F, dan IOU masing-masing sebesar 0,965, 0,963, 0,97, dan 0,972. Hebatnya, metode yang diusulkan menunjukkan kinerja yang unggul dalam hal efisiensi dan efektivitas bila dibandingkan dengan teknik canggih, bahkan dengan adanya variasi kabur, kebisingan, dan cahaya.

**Kata Kunci:** *Deteksi glaukoma, Optic disc (OD), Optic cup (OC), Retina images, Blur images, Fully automatic framework, ground-truth (GT).*

**Abstract**- Glaucoma, a debilitating eye disease that leads to optic disc (OD) and optic cup (OC) damage, eventually causing blindness in advanced stages, poses challenges for early identification due to its slow progression and limited initial symptoms. Therefore, an automated framework is crucial to aid in screening and enhance early-stage disease detection. In this study, we focus on localizing and segmenting the OD and OC in blur retinal images for glaucoma detection. To address the challenges, we propose a novel approach, namely Densenet-77-based Mask-RCNN. We begin by augmenting the dataset and introducing blurriness to enhance data diversity. Next, we generate annotations from ground-truth (GT) images. The Densenet-77 framework is then employed within the feature extraction phase of the Mask-RCNN to compute deep key points. Subsequently, these calculated features are utilized by a customized Mask-RCNN model to localize and segment the OD and OC. The performance evaluation is conducted on the publicly available ORIGA dataset, and cross-dataset validation is performed using the HRF database to demonstrate the framework's robustness. The presented framework achieves an average precision, recall, F-measure, and IOU of 0.965, 0.963, 0.97, and 0.972, respectively. Remarkably, the proposed method demonstrates superior performance in terms of both efficiency and effectiveness when compared to state-of-the-art techniques, even in the presence of blurring, noise, and light variations.

**Keywords:** *Glaucoma detection, Optic disc (OD), Optic cup (OC), Retinal images, Blur images, Fully automatic framework, ground-truth (GT).*

### **1. PENDAHULUAN**

Glaukoma merusak saraf optik karena ketidakseimbangan tekanan intraokular di dalam mata. Serabut saraf yang terkena mengakibatkan kerusakan lapisan retina dan menimbulkan saraf optik yang membesar, yaitu bagian retina, dan optic cup adalah bagian utama dari saraf optik. Glaukoma biasanya dianalisis dengan memperoleh riwayat medis pasien, menentukan tekanan intraokular (intraocular pressure), melakukan tes kehilangan lapang pandang, dan penilaian manual menggunakan oftalmoskopi untuk menyelidiki bentuk dan warna saraf [1]. cup-to-disc ratio (CDR)

adalah salah satu isyaratgambar struktural utama yang direfleksikan untuk identifikasi glaukoma CDR membandingkan diameter optic cup dengan kation. nilai diameter optic disc; kurang dari 0,5 CDR dianggap sebagai normal [2]. Jadi, deteksi penyakit tepat waktu dapat menghindari kebutaan.

[3]. Oleh karena itu, pengelompokan area berbahaya tidak hanya menguntungkan untuk analisis medis tambahan yang ketat oleh dokter mata tetapi juga berguna untuk merancang sistem otomatis untuk kategorisasi penyakit [4]. Awalnya, para ahli mengidentifikasi kelainan mata melalui pemeriksaan manual daerah glaukoma, dengan menghitung CDR, diameter, dan variasi batas [5]. Namun, karena kurangnya ahli yang tersedia, identifikasi kelainan mata yang tepat waktu biasanya tertunda [6], sedangkan deteksi dini dan pengobatan penyakit dapat menyelamatkan korban dari kebutaan total. Untuk mengatasi tantangan tersebut, komunitas riset menargetkan identifikasi penyakit melalui solusi berbasis Computer Aided Diagnosis (CAD).

Dalam penelitian, pendekatan berbasis pembelajaran mendalam [3, 4, 7-20] telah digunakan untuk mengidentifikasi tanda-tanda glaukoma dari gambar retina. Dalam [21], RCNN end-to-end metode untuk segmentasi optic disc dan optic cup bersama diusulkan. Dalam joint- RCNN, jaringan proposal optic disc dan optic cup digunakan untuk membuat proposal kotak pembatas masing-masing untuk Optik Disk dan Optic Cup. Teknik yang disajikan rumit secara komputasi karena menggunakan dua RCNN yang berbeda untuk menghitung wilayah ROI.

Oleh karena itu, diperlukan teknik yang lebih andal yang dapat mendeteksi daerah yang terkena glaukoma secara efisien. Dalam [22], metode perhitungan kerapatan piksel berbasis wilayah digunakan untuk okalisasi OD. Selanjutnya dilakukan segmentasi OD melalui metode Circular Hough Transform. e prosedur efisien dan kuat untuk segmentasi OD; namun, kinerja pengenalannya terganggu karena gambar memiliki gangguan patologis. Dalam [3], penulis mengadaptasi DenseNet menjadi kerangka kerja berbentuk U-Net untuk segmentasi OD dan OC.

Metode ini terdiri dari tiga fase utama, (i) pra pemrosesan, (ii) perancangan model FC-DenseNet, dan (iii) segmentasi OD dan OC. Yang pertama, saluran hijau diekstraksi dari gambar RGB; setelah itu, wilayah OD dalam dua diameter OD dikumpulkan, yang digunakan untuk pelatihan model. Pada tahap kedua, model telah dibangun yang terdiri dari tiga blok yaitu padat dan transisi ke bawah dan ke atas. Pada tahap akhir dilakukan penyempurnaan untuk ekstraksi OD dan OC melalui operasi Softmax. Kinerja metode [3] dievaluasi pada lima set data yang berbeda dan telah mencapai hasil yang baik dengan waktu pengujian yang singkat. Namun, metode [3] memiliki beberapa kekurangan: (i) perhitungan pusat OD bergantung pada data GT, (ii) waktu pelatihan yang tinggi, dan (iii) pelatihan dilakukan pada set kecil. Pada [18], arsitektur CNN delapan belas lapis diusulkan untuk lokalisasi glaukoma, yang memiliki dua komponen utama: (i) fase lapisan convolutional dan max-pooling (ii) dan fase lapisan yang terhubung

sepenuhnya. Metode e telah mengevaluasi 1426 citra dan mencapai akurasi sebesar 98,13%. Namun, metode di [18] menurunkan kinerja pada sampel yang tidak terlihat dan mungkin tidak mendeteksi koma glau pada tahap awal. Dalam [15], Lu et al. menyajikan metode segmentasi mingguan dan semisupervised berdasarkan model Modified U-Net untuk segmentasi OD. Awalnya, teknik GrabCut digunakan untuk pembuatan GT. e Model U-Net ditingkatkan dengan meminimalkan struktur bentuk- U asli dengan menambahkan lapisan konvolusional 2 dimensi di ujung lapisan konvolusional. Namun, metode ini membutuhkan jumlah pelatihan yang lebih sedikit, menunjukkan akurasi yang lebih rendah daripada metode lain karena kurangnya GT. Elangovan et al. [23] telah

mengusulkan pendekatan untuk identifikasi glaukoma berdasarkan CNN yang terdiri dari 18 lapisan. teknik memiliki fase yang berbeda: preprocessing, perhitungan poin kunci, dan klasifikasi. Awalnya, perubahan ukuran gambar dan augmentasi data dilakukan; selanjutnya, augmentasi rotasi diterapkan untuk meningkatkan jumlah sampel. Fitur diekstrak melalui CNN yang memiliki

empat convolutional, dua pooling, dan satu layer yang terhubung penuh. Untuk evaluasi kinerja metode ini, dataset yang berbeda digunakan, yaitu ORIGA, DRISHTIGS1,

RIM-ONE2, LAG, dan ACRIMA. Dalam [24], penulis telah mempresentasikan teknik CNN berbasis perhatian (AG-CNN) untuk pengenalan glaukoma. Pada tulisan ini [24], penulis telah membuat sebuah database baru bernama glaukoma berbasis perhatian skala besar, yang memiliki total 11760 gambar retina. Semua gambar ditandai dengan glaukoma negatif atau positif. Metode Mask-RCNN terdiri dari dua tahap utama; pada fase pertama, subnet prediksi perhatian digunakan untuk mempelajari ROI glaukoma dan kemudian memprediksi peta perhatian. Kedua, peta yang diprediksi digunakan di wilayah lokal, dan kemudian peta fitur subnet ini divisualisasikan untuk menemukan wilayah patologis.

Terakhir, wilayah yang terletak digabungkan dengan perhatian yang diantisipasi untuk menggabungkan input dan subnet poin kunci glaukoma, untuk menghitung label biner glaukoma. Metode pada [24] menunjukkan kinerja yang baik dan mengurangi redundansi gambar fundus; namun, metode ini bergantung pada subnet prediksi perhatian.

Teknik yang ada bekerja dengan baik di atas kumpulan data standar tetapi tidak digeneralisasi dengan baik untuk skenario dunia nyata. Alasan utama penurunan kinerja adalah terjadinya keburaman, kebisingan, dan variasi cahaya selama proses pengambilan gambar, sedangkan dataset standar diperoleh di lingkungan kontrol. Dalam karya ini, motivasi utama kami adalah untuk mengusulkan teknik yang dapat melokalisasi dan mensegmentasi sampel fundus di bawah adanya faktor tersebut. Kami telah memilih kumpulan data standar seperti database ORIGA dan HRF yang berisi variasi cahaya dan efek derau tetapi tidak memiliki keburaman. Jadi, dalam pekerjaan ini, kami telah menambahkan keburaman dalam sampel dari kumpulan data yang disebutkan dan mengusulkan teknik baru, yaitu, Mask-RCNN berbasis Densenet-77 [25] yang disesuaikan untuk mendeteksi dan mensegmentasi OC dan OD dari sampel fundus. Berikut adalah kontribusi utama dari pekerjaan kami:

1. metode yang diusulkan dapat secara tepat mengelompokkan OD dan OC untuk diagnosis glaukoma dari gambar retina di bawah adanya variasi buram, kebisingan, dan cahaya pada gambar masukan.
2. Kami telah membuat anotasi yang penting untuk pelatihan model yang diusulkan karena dataset yang tersedia tidak memiliki BB dan mask GT.
3. Lokalisasi dan segmentasi OD yang akurat dan OC karena jaringan proposal wilayah yang efektif Custom Mask-RCNN karena berfungsi secara end-to-end tata krama.
4. Hasil ekstensif tampil di atas dataset ORIGA yang menantang untuk menunjukkan kekokohan kerangka kerja yang disajikan. Selain itu, kami telah melakukan validasi lintas dataset pada database HRF untuk menunjukkan kekuatan generalisasi teknik kami ke skenario dunia nyata.

## 2. METODE PENELITIAN

Gambar retina yang dikumpulkan dari klinik berbeda dapat berisi berbagai artefak seperti buram, noise, gambar tidak fokus, atau variasi cahaya, yang harus dihilangkan untuk meningkatkan kinerja segmentasi sistem. Dalam makalah kami, kami telah menggunakan teknik set level fitur untuk mengoreksi bidang bias dan menerapkan filter median untuk meminimalkan efek bising dari gambar retina. Jurnal Optik Internasional

2.1 Preprocessing. Langkah augmentasi digunakan untuk meningkatkan sampel gambar dalam hal keragaman data. Untuk tujuan ini, gambar input diputar pada sudut 0o dan 270o derajat, dan Gaussian blur [26], digunakan 180o, di atasnya untuk menambah keburaman.

2.2 Lokalisasi dan Segmentasi OD dan OC Menggunakan Custom Mask-RCNN. Tujuan kami adalah deteksi otomatis dan segmentasi OD dan OC dari gambar fundus dengan latar belakang yang rumit dan dengan adanya operasi pascapemrosesan tanpa keterlibatan manusia. Kami bertujuan untuk mengidentifikasi daerah yang terkena dan tidak terkena glaukoma dari sampel yang diberikan dengan menggunakan pendekatan Mask RCNN [28].

2.3 Fitur Ekstraksi. Dalam pendekatan kami, kami telah menggunakan DenseNet-77 pada tingkat ekstraksi fitur Mask RCNN untuk menghitung poin-poin penting dari sampel yang diberikan. Memanfaatkan DenseNet-77 untuk komputasi fitur menunjukkan peningkatan baik dalam akurasi segmentasi maupun kompleksitas komputasi. Lapisan awal menghitung titik kunci tingkat rendah dari gambar, yaitu informasi tepi dan sudut, dan lapisan dalam menghitung titik kunci tingkat tinggi, yaitu informasi struktur dan chrominance.

2.4 Jaringan Usulan Wilayah. Peta fitur yang dihitung dari langkah sebelumnya diteruskan sebagai input ke modul RPN untuk menghasilkan ROI. Pekerjaan kami telah menggunakan lapisan konvolusional  $3 \times 3$  untuk memindai sampel input dengan jendela geser untuk menghasilkan jangkar yang sesuai yang menunjukkan BB dengan berbagai skala dan tersebar di seluruh sampel input.

2.5 Klasifikasi ROI dan Regresi Bounding Box. modul ini menerima dua jenis input yaitu RoI yang diperkenalkan dan peta fitur dari langkah sebelumnya. Berbeda dengan modul RPN, bagian ini lebih dalam dan menetapkan kelas khusus untuk RoI seperti glaukoma atau nonglaukoma dan memperbaiki lokasi BB. Tujuan utama dari BBR adalah untuk meningkatkan lokasi dan dimensi BB untuk menangkap daerah glaukoma dengan benar.

2.6 Masker Segmentasi. is module menerima ROI bertanda positif oleh pengklasifikasi ROI sebagai input dan menghitung mask segmentasi dengan dimensi  $28 \times 28$  yang ditunjukkan oleh nilai mengambang yang menyimpan lebih banyak detail dibandingkan dengan mask biner. e Topeng GT diubah ukurannya menjadi  $28 \times 28$  untuk menghitung kerugian menggunakan topeng yang teridentifikasi pada langkah pelatihan, yang kemudian ditingkatkan agar sesuai dengan ukuran ROI BB yang sebenarnya untuk menunjukkan topeng akhir. di mana  $p_{xy}$  adalah nilai piksel pada lokasi  $(x, y)$  dalam topeng  $gt$  ukuran  $N \times N$  dan untuk piksel yang sama,  $V_k$  menyajikan  $_{xy}$  nilai perkiraannya dalam topeng yang diperoleh untuk kelas  $k$  ( $k \in 1$  untuk wilayah glaukoma dan 0 untuk wilayah nonglaucoma) [28].

### 3. ANALISA DAN PEMBAHASAN

Kami telah mengimplementasikan model menggunakan pustaka Keras dan Ten sorFlow dengan DenseNet-77 dan FPN untuk ekstraksi fitur. Kami menginisialisasi model menggunakan bobot pra-pelatihan yang diperoleh dari dataset COCO dan menggunakan pembelajaran transfer untuk menyempurnakan model pada dataset retina untuk segmentasi OD dan OC. Untuk eksperimen, kami menggunakan rasio 70-30 yang dibagi secara acak menjadi set pelatihan (70%) dan tes (30%).data. dilakukan Eksperimen evaluasi sistem adalah

3.1 Himpunan pada dataset “Online Retinal Fundus Image Database for Glaucoma Analysis” ORIGA [29]. Rincian dataset disajikan pada Tabel 2. Dataset memiliki total 650 gambar di mana 168 adalah sampel glaukoma dan 482 sisanya adalah sampel nonglaucomatous dan dikumpulkan dari “Eye Research Institute, Singapore.” Pada setiap

citra, daerah OD dan OC ditandai oleh ahli menggunakan elips vertikal dan tidak berotasi. Contoh gambar ditunjukkan pada Gambar 4.

3.2 Parameter Evaluasi. Metode yang diusulkan dinilai dengan menggunakan persimpangan di atas serikat pekerja (IOU) seperti yang dijelaskan pada Gambar 5. A menunjukkan persegi panjang GT, dan B menunjukkan persegi panjang yang diperkirakan dengan wilayah ROI. Keputusan pertama untuk wilayah diidentifikasi ketika nilai IOU lebih besar dari 0,5; jika tidak, itu tidak diakui. Presisi rata-rata (AP) sebagian besar digunakan dalam mengevaluasi presisi detektor objek, yaitu R-CNN, SSD, dan YOLO. Penjelasan geometris presisi ditunjukkan pada Gambar 6. Dalam kerangka deteksi daerah glaukoma kami, AP tergantung pada gagasan IOU [30].

3.3 hasil Bagian ini menyajikan detail hasil yang dicapai setelah melakukan eksperimen pada beragam sampel dengan variasi cahaya, warna, ukuran wilayah, dan adanya keburaman. Untuk OD, untuk menunjukkan akurasi pendeteksian kerangka yang disajikan, hasil visual dilaporkan pada Gambar 7. Dapat diamati dari hasil bahwa metode yang diusulkan dapat secara akurat melokalisasi wilayah OD dari area yang sehat meskipun batasnya terputus-putus atau kabur dan artefak dalam gambar fundus. Selain itu, metode Mask-RCNN dapat secara tepat mensegmentasi wilayah OD dengan mengatasi tantangan lokasi, bentuk, dan ukuran.

Selanjutnya, hasil visual untuk wilayah tersegmentasi OC ditunjukkan pada Gambar 8. Dari hasil yang dilaporkan, dapat divisualisasikan bahwa metode kami dapat secara akurat melokalkan dan mensegmentasi wilayah OC dalam kondisi yang berbeda karena serangkaian ekstraksi fitur yang representatif oleh DenseNet-77 dan kekuatan segmentasi Mask-RCNN. Namun, kekuatan lokalisasi dan segmentasinya mungkin sedikit berkurang Jurnal Optik Internasional sampel dengan variasi warna intens yang menghasilkan pencocokan warna dengan daerah yang sehat.

Metode yang diusulkan dapat mengenali OD dan OC secara akurat dengan akurasi rata-rata 0,965 pada dataset ORIGA. Selain itu, teknik yang diusulkan dapat secara tepat membagi OD dan OC dengan mengatasi tantangan keburaman dan variasi lokasi, ukuran, dan bentuk.

Untuk lebih memahami kinerja metode kami, kami telah menggunakan parameter evaluasi yaitu, akurasi, presisi, daya ingat, F-measure, dan IOU. Tabel 3 menunjukkan hasil atau pendekatan yang diusulkan. Kita dapat mengamati bahwa kerangka kerja yang disajikan telah mencapai rata-rata presisi, daya ingat, ukuran-F, dan IOU masing-masing sebesar 0,965, 0,963, 0,97, dan 0,972. Selain itu, matriks kebingungan dari pendekatan yang diusulkan disajikan pada Gambar 9.

3.4 Evaluasi Kerangka Kerja DenseNet-77. Kami melakukan analisis untuk mengevaluasi ketangguhan kerangka kerja DenseNet-77 untuk deteksi penyakit mata dengan membandingkannya dengan pendekatan DL lainnya. Untuk mencapai hal ini, keakuratan Mask-RCNN yang diperkenalkan dengan DenseNet-77 dibandingkan dengan model dasar lainnya, yaitu, Inception-v4 [31], VGG-16 [32], ResNet-101 [33], ResNet-152 [33], dan DenseNet-121 [34].

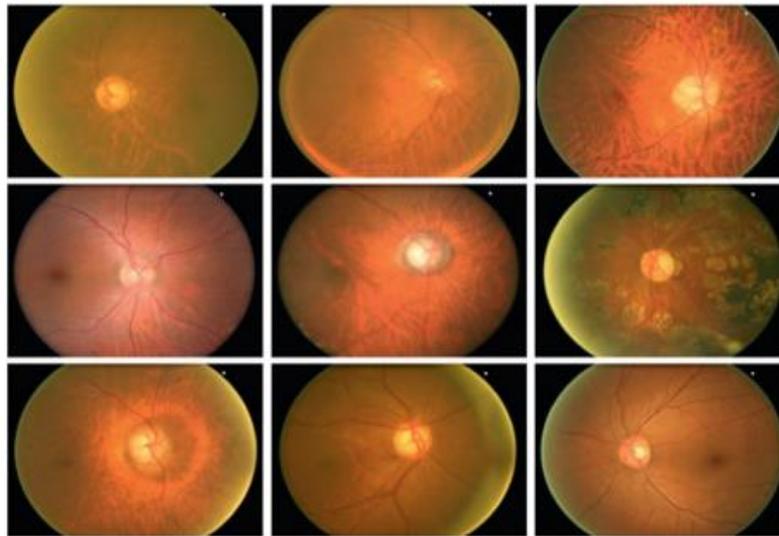
Tabel 4 menunjukkan analisis komparatif metode yang disajikan dengan kerangka kerja lain baik dalam aspek parameter model maupun akurasi deteksi. Hasil analisis komparatif ini menunjukkan bahwa Custom Mask-RCNN dengan DenseNet-77 bekerja lebih

baik daripada Inceptionv4, VGG 16, ResNet-50, ResNet-101, ResNet-152, dan DenseNet-121. Selain itu, dari Tabel 4 terlihat bahwa VGG-16 memiliki parameter model tertinggi, sedangkan ResNet-152 merupakan pendekatan yang paling mahal dalam hal waktu eksekusi. Sebaliknya, kerangka kerja yang disajikan dengan model DenseNet-77 secara ekonomis paling efisien dan hanya mengambil 1067 e alasan utama untuk detik efisien untuk eksekusi. kinerja yang lebih baik daripada model pembelajaran mendalam lainnya dalam hal akurasi dan kemanjuran

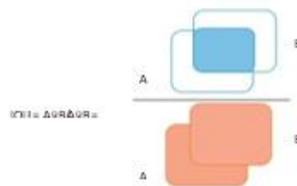
3.5 Evaluasi Model Custom Mask-RCNN. Pada bagian ini, kami telah membandingkan kinerja metodologi yang diperkenalkan dengan metode segmentasi berbasis wilayah lainnya, yaitu, RCNN dan Faster-RCNN melalui database ORIGA, dan hasilnya dilaporkan pada Gambar 10. RCNN secara komputasi kompleks karena menghasilkan wilayah secara acak.

Tabel 2: Detailsetdata.

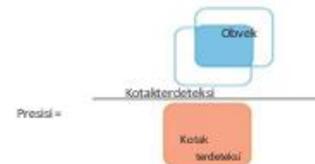
Atribut	Nilai
Jumlahgambar	650
Gambarabunormasi	168
Gambarbiasa	482
Resolusi	3072x2048
Kebenarandasar	wilayahOD dan OC



Gambar 4: Contoh gambar dari Data seORIGA.



Gambar 5: Diagram Venn IOU.



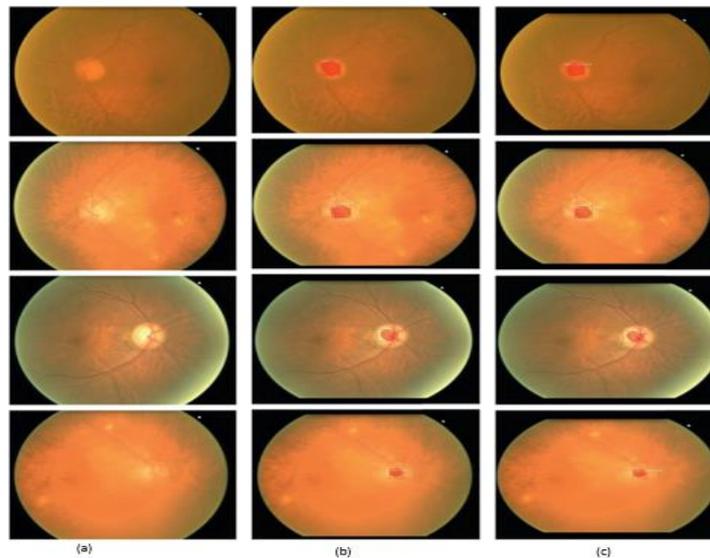
Gambar 6: Representasi presisi geometris.

Gambar 1: Hasil visual segmentasi OD. (a) Memasukkan gambar. (b) Gambar beranotasi. (c) Gambar keluaran

proposal (2000 per gambar) dan menggunakan algoritma pencarian selektif untuk klasifikasi. e Faster-RCNN secara otomatis mengekstrak proposal wilayah menggunakan RPN dan berbagai lapisan konvolusi antara kelas dan jaringan BB untuk mengurangi biaya komputasi. Topeng tradisional RCNN menawarkan keuntungan tambahan dibandingkan Faster-RCNN by7 menyediakan masker segmentasi otomatis juga tetapi tidak dapat menangkap kumpulan fitur yang kuat di bawah serangan pascapemrosesan. Oleh karena itu, Mask-RCNN berbasis DenseNet 77 yang disajikan bekerja dengan baik dibandingkan dengan Mask-RCNN tradisional karena DenseNet dapat menangkap transformasi kompleks dengan lebih akurat yang menghasilkan segmentasi dan lokalisasi otomatis yang lebih baik.

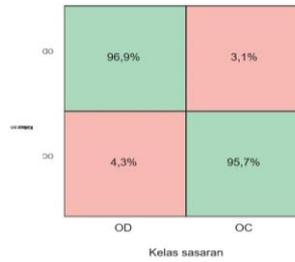
3.6 Analisis perbandingan. Di sini, kami telah membandingkan kinerja model kami dengan pendekatan yang ada pada dataset ORIGA. Teknik yang diusulkan menggunakan fitur mendalam yang lebih diskriminatif dan andal serta memberikan representasi daerah glaukoma yang lebih efektif dibandingkan metode lain. Untuk evaluasi kinerja, kami mengevaluasi pendekatan kami terhadap karya Bajwa et al. [1], Jiang dkk. [21], Xu dkk. [35], dan Fu et al. [8]. teknik-teknik ini Namun, mereka membutuhkan pelatihan intensif dan menunjukkan akurasi yang lebih rendah untuk sampel pelatihan dengan masalah ketidakseimbangan kelas. Hasil perbandingan disajikan pada Tabel 5. mampu mendeteksi glaukoma dari gambar retina. Kerangka kerja kami telah memperoleh rata-rata presisi, perolehan, dan AUC tertinggi, masing-masing, yaitu 0,965, 0,963, dan 0,96, yang menandakan keandalan metode yang diusulkan dibandingkan dengan metode lain. Tidak seperti metode ini, model kami melakukan segmentasi pada ROI yang dilokalkan, yang membatasi ruang segmentasi dan menggunakan lapisan ROIAlign yang pada akhirnya meningkatkan akurasi hasil segmentasi akhir.

3.7 Validasi Dataset Lintas. Untuk mengevaluasi lebih lanjut kinerja dari metode yang diusulkan, kami melatih metode kami pada dataset ORIGA, dan pengujian dilakukan pada dataset HRF [36]. e dataset berisi 45 gambar retina di mana 15 gambar sehat, 15 gambar terkena retinopati diabetic, dan 15 gambar terkena glaukoma. Kami telah memplot plot kotak untuk evaluasi.



Gambar 8: Hasil visualisasi segmentasi OC. (a) Gambar masukan, (b) Gambar referensi, (c) Gambar Keluaran

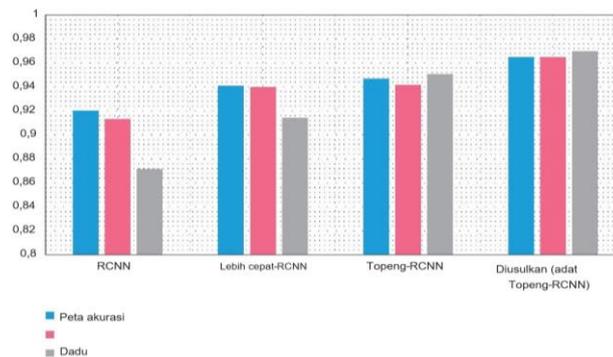
metode	Akurasi	Tabel 5: Hasil metode yang diusulkan.			F-ukuran	AUC
		Precisi	Recall	F1-score		
OD	0,978	0,959	0,969	0,953	0,981	
OC	0,955	0,971	0,957	0,987	0,963	
Rata-rata	0,965	0,965	0,963	0,970	0,972	



Gambar 9: Matriks kebingungan.

Tabel 4: Analisis perbandingan pendekatan yang diusulkan dengan model dasar.

Parameter	Awal-V4	VGG-16	ResNet-101	ResNet-152	DenseNet-121	DenseNet-77
Total parameter (juta)	41,2	119,6	42,5	58,5	7,1	6,2
Kerugian pelatihan	0,0102	0,5069	4,1611e <sup>-04</sup>	2,4844e <sup>-04</sup>	5,6427e <sup>-04</sup>	6,442e <sup>-04</sup>
Ujian kalah	0,0686	0,6055	0,02082	0,0246	0,0159	0,0085
Akurasi latihan	99,74%	83,86%	99,99%	100%	100%	100%
Akurasi tes	98,08%	81,83%	99,66%	99,59%	99,75%	99,983%
Waktu pemrosesan	4042	1051	2766	4366	2165	1067



Gambar 10: Perbandingan dengan metode RCNN lainnya.

Tabel 5: Perbandingan dengan teknik lain.

metode	Mengingat	Presisi	AUC
Bajawa et al. [1]	0,71	—	0,860
Jiang dkk. [21]	—	0,937	0,854
Xu dkk. [35]	0,58	—	0,830
Fu dkk. [8]	0,84	0,92	0,910
Diajukan	0,963	0,965	0,970

## 4. KESIMPULAN

Dalam makalah ini, kami menyajikan teknik pembelajaran mendalam untuk menyesuaikan Mask-RCNN untuk pemisahan OD dan OC yang tepat dan otomatis dari gambar retina. Kami memperkenalkan model DenseNet-77 pada tingkat komputasi fitur Mask-RCNN untuk menghitung poin kunci yang lebih beragam yang membantu melokalkan wilayah OD dan OC secara akurat dalam berbagai kondisi sampel. Kami telah menguji kerangka kerja kami pada basis data yang menantang, yaitu ORIGA, dan melakukan validasi lintas-set data pada basis data HRF untuk menunjukkan ketahanannya.

Hasil menunjukkan bahwa Mask-RCNN yang lebih baik dapat menghitung fitur mendalam dengan representasi efektif dari daerah glaukoma pada sistem yang ada dan berfungsi sebagai alat otomatis baru untuk tujuan diagnostik. Selain itu, hasil kualitatif dan kuantitatif menunjukkan bahwa

Custom Mask-RCNN bekerja lebih baik daripada kerangka dasar. Meskipun pendekatan kami telah menghadirkan akurasi deteksi OD dan OC yang lebih baik, namun, pendekatan ini dapat lebih ditingkatkan dengan menyertakan teknik berbasis DL terbaru lainnya seperti EfficientNet. Selanjutnya, kami berencana untuk memperluas pekerjaan kami ke kelainan medis lainnya.

## UCAPAN TERIMA KASIH

Terima kasih kepada semua individu yang telah bersedia menjadi responden dan berpartisipasi dalam penelitian ini. Partisipasi mereka telah memberikan data yang berharga untuk analisis dan temuan penelitian dan tidak lupa juga kami berterima kasih kepada rekan penelitian yang telah memberikan saran, masukan, dan dukungan selama proses penelitian. Kontribusi mereka dalam diskusi dan kolaborasi telah memperkaya penelitian ini.

## REFERENCES

- Aldy Prasetya, A. D. (2022). *Sistem Pakar Untuk Mendiagnosa Kerusakan Mata Akibat Soflens Menggunakan Metode Forward Chaining*. BISIK : Jurnal Ilmu Komputer, Hukum, Kesehatan Dan Sosial Humaniora.
- H. Fu, J. C. (2018). *Disc-aware ensemble network for glaucoma screening from fundus image*. IEEE Transactions on Medical Imaging.
- H. Fu, J. C. (2018). *Joint optic disc and cup segmentation based on multi-label deep network and polar transformation*. IEEE Transactions on Medical Imaging.
- J. Martins, J. S. (2020). *Offline computer-aided diagnosis for Glaucoma detection using fundus images targeted at mobile devices*. Computer Methods and Programs in Biomedicine.
- L. Li. (2019). *A large-scale database and a CNN model for attention-based glaucoma detection*. IEEE Transactions on Medical Imaging.
- M. N. Bajwa, M. I. (2019). *Two-stage framework for optic disc localization and glaucoma classification in retinal fundus images using deep learning*. BMC Medical Informatics and Decision Making.
- Nath, P. E. (2020). *Glaucoma assessment from color fundus images using convolutional neural network*. International Journal of Imaging Systems and Technology.
- Pratt, a. Y. (2018). *Dense fully convolutional segmentation of the optic disc and cup in colour fundus for glaucoma diagnosis*. Symmetry.
- R. Hemelings, B. E.-B. (2020). *Accurate prediction of glaucoma from colour fundus images with a convolutional neural network that relies on active and transfer learning*. Acta Ophthalmologica.
- Rosyani, P. &. (2023). *Ekstraksi Fitur Wajah Menggunakan Metode Viola Jones dengan Tools Cascade Detector*. JURIKOM (Jurnal Riset Komputer).
- Shanthamalar, R. G. (2020). *Improved image processing techniques for optic disc segmentation in retinal fundus images*. Biomedical Signal Processing and Control.
- T. Nazir, A. I. (2020). *Diabetic retinopathy lesions detection using faster-RCNN from retinal images*.
- T. Nazir, A. I. (2020). *Retinal image analysis for diabetes-based eye disease detection using deep learning*. Applied Sciences.
- Y. Jiang, L. D. (2019). *JointRCNN: a region-based convolutional neural network for optic disc and cup segmentation*. IEEE Transactions on Biomedical Engineering.
- Y. Wang, H. L. (2019). *Multi-scale DenseNets-based aircraft detection from remote sensing images*.
- Z. Lu and D. Chen. (2020). *Weakly supervised and semi-supervised semantic segmentation for optic disc of fundus image*. Symmetry.