TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

Penerapan Faster RCNN + ResNet 50 untuk Mengidentifikasi Spesies dan Stadium Parasit Plasmodium Malaria

Alifia Revan Prananda[1,*], Suamanda Ika Novichasari[1], Bagus Fatkhurrozi[2], Muhammad Nurkholis Abdillah[3], Eka Legya Frannita[4], Zharifa Nur Majidah[1], Fadhila Syahida Wibowo[1]

[1] Program Studi Teknologi Informasi, Fakultas Teknik, Universitas Tidar, Magelang, Indonesia
[2] Program Studi Teknik Mekatronika, Fakultas Teknik, Universitas Tidar, Magelang, Indonesia
[3] Program Studi Teknik Elektro, Fakultas Teknik, Universitas Tidar, Magelang, Indonesia
[4] Program Studi Teknologi Pengolahan Produk Kulit, Politeknik ATK Yogyakarta, Yogyakarta, Indonesia
Email: [1,*]revan@untidar.ac.id, [2] manda@untidar.ac.id, [3] bagusf@untidar.ac.id,
[4] mnurkholisabdillah@untidar.ac.id, [5]eka.legya@atk.ac.id, [6]zharifanurmajidah@student.untidar.ac.id,
[7]fadhila.syahida.wibowo@student.untidar.ac.id
Email Penulis Korespondensi: revan@untidar.ac.id

Abstrak−Malaria merupakan salah satu penyakit berbahaya yang disebabkan oleh infeksi dari parasit Plasmodium. Proses pemeriksaan penyakit malaria biasanya dilakukan dengan pengamatan terhadap sampel darah pasien menggunakan mikroskop. Semua proses pemeriksaan tersebut dilakukan secara manual yang berpotensi menimbulkan berbagai macam permasalahan seperti kesalahan diagnosis, kesalahan dalam menginterpretasi parasit hingga hasil yang subjektif. Tujuan dari penelitian ini adalah untuk pengembangkan metode yang mampu melakukan deteksi kandidat parasit secara otomatis dan mampu mengidentifikasi spesies serta stadium dari parasit tersebut. Penelitian ini menggunakan citra mikroskop digital sejumlah 488 raw data atau citra dimana di dalamnya terdapat 539 objek parasit. Skema deteksi yang diusulkan terdiri dari beberapa langkah yakni tahap augmentasi data menggunakan geometric transformation, tahap training dan testing model, kemudian tahap evaluasi. Untuk tahap training dan testing model, penelitian ini mengimplementasikan arsitektur Faster RCNN + ResNet 50. Arsitektur ini berhasil memperoleh mAP sebesar 0,603. Arsitektur ini juga berhasil memperoleh akurasi sebesar 93,91%, sensitivitas sebesar 66,20%, spesifisitas sebesar 96,10%, PPV sebesar 60,14%, dan NPV sebesar 97,30% dalam mengidentifikasi jenis-jenis spesies dan stadium parasite plasmodium. Hasil ini menunjukkan bahwa arsitektur yang digunakan memiliki perfoma yang baik dalam mendeteksi lokasi parasite plasmodium dan mengidentifikasi jenis spesies dan stadium dari plasmodium tersebut.

Kata Kunci: Malaria; Deteksi Otomatis; Object Detection; Deep Learning

Abstract−Malaria is one of the epidemic health diseases and is well-known as a serious infectious disease. The malaria examination process had occurred by analyzing the digital microscopic images using a microscope. Those examination procedures were conducted manually, which lead to some hurdles such as misinterpretation, misdiagnosis and may produce subjective results. This research aims to develop a method for detecting the Plasmodium parasite and identifying the species and stage of Plasmodium parasite. The proposed method was performed into 488 raw data comprising of 538 parasites. The proposed method was started by conducting a data augmentation process for balancing the number of data, training model, testing model, evaluation. In this study, both the training and testing processes were performed by applying Faster RCNN + ResNet-50. The result of the testing process shows that Faster RCNN + ResNet-50 successfully achieved mAP of 0,603. It also achieved accuracy of 93.91%, sensitivity of 66.20%, specificity of 96.10%, PPV of 60.14% and NPV of 97.30%. This result indicates that the proposed method is powerful for detecting Plasmodium parasites and identifying all species and stadiums.

Keywords: Malaria; Automated Detection; Object Detection; Deep Learning

1. PENDAHULUAN

Penyakit Malaria termasuk dalam golongan penyakit endemis karena telah lama ditemukan dan menyebar di seluruh daerah. Jumlah penderita Malaria di Indonesia juga berada pada angka yang cukup besar. Pada tahun 2024, Kementerian Kesehatan menyebutkan bahwa kasus Malaria di Indonesia mencapai 418.546 kasus positif, 377.662 kasus diobati standar, dan 120 kasus meninggal yang tersebar ke sejumlah 229 kabupaten/kota (Kementerian Kesehatan RI, 2024). Banyaknya jumlah kasus di Indonesia bagian timur disebabkan oleh kurangnya kesadaran masyarakat untuk menjaga lingkungan, kurang pengetahuan masyarakat terhadap penyakit Malaria, dan kurangnya jumlah tenaga medis untuk menangani pasien Malaria (Wahab et al., 2020) (Ferdiana et al., 2021)(Fitri et al., 2023).

Teknik identifikasi yang dilakukan secara visual melalui mikroskop merupakan teknik standar (gold standard) paramedis untuk mengidentifikasi spesies dan stadium parasit Malaria, melalui sediaan/preparat darah (Poostchi et al., 2018). Saat ini pemeriksaan miskropkopis menjadi standar dalam diagnosis Malaria, karena cukup sensitif terhadap kehadiran parasit dan biaya yang rendah (Prananda et al., 2019). Akan tetapi teknik ini seringkali memiliki kelemahan yang dipengaruhi oleh kondisi alat yang digunakan, teknik pewarnaan sediaan darah, serta tingkat keahlian/kepakaran dan pengalaman yang dimiliki oleh spesialis (WHO, 2019a)(WHO, 2019b) Hal ini mengakibatkan tingginya tingkat subjektivitas pakar dalam melakukan diagnosis penyakit dan sangat memungkinkan terjadinya kesalahan. Selain itu teknik tersebut cukup memakan waktu dan akurasinya sangat bergantung pada tingkat keahlian paramedis terutama ketika diagnosis dilakukan pada tahap awal infeksi (WHO, 2019a)(Kementerian Kesehatan Republik Indonesia, 2019)(Prananda et al., 2021).

Selain teknik visual menggunakan mikroskop terdapat berbagai teknik seperti menggunakan Polymerase Chain Reaction (PCR), Quantitative Buffy Coat (QBC), dan Rapid Diagnosis Test (RDT). QBC melibatkan pewarnaan parasit deoxyribonucleic acid (DNA) dalam tabung mikrohematokrit dengan pewarna fluorescent dan deteksi selanjutnya

Copyright © 2025 the author, Page 55
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

dengan mikroskop epi-fluorescent. Teknik QBC dinilai sederhana, handal dan user-friendly, namun memerlukan instrumentasi khusus dan lebih mahal jika dibandingkan dengan mikroskop cahaya konvensional, dan lemah pada penentuan spesies dan jumlah parasit. Pada RDT dan PCR semua didasarkan pada prinsip sama dan mendeteksi antigen Malaria dalam darah yang mengalir disepanjang membran yang mengandung antibodi anti-Malaria sehingga pada RDT dan PCR tidak diperlukan peralatan laboratorium. RDT dan PCR merupakan diagnosis Malaria yang cepat namun harus digunakan bersama dengan metode lain untuk mengkonfirmasi hasil, ciri infeksi dan memantau pengobatan. Kelemahan dari teknik ini adalah membutuhkan biaya yang besar dan tidak semua klinisi mampu menggunakan teknik ini (Kementerian Kesehatan Republik Indonesia, 2017) (Supranelfy et al., 2018).

Melihat kelemahan-kelemahan di atas maka perlu dikembangkan teknik identifikasi yang bisa membantu klinisi atau teknisi labratorium untuk menghasilkan diagnosis yang lebih cepat dan akurat. Karena keterlambatan diagnosis dan kesalahan penanganan penyakit Malaria dapat meningkatkan kemungkinan terjadinya resistensi anti Malaria dan risiko kematian pada pasien (Selasa, 2017). Sebuah komputerisasi sistem yang mengadopsi pengetahuan dan keterampilan dari klinisi atau teknisi laboratorium diusulkan dalam penelitian ini guna untuk menyelesaikan masalah-masalah yang dijabarkan pada paragraph sebelumnya. Melalui sistem yang dikembangkan, diharapkan diagnosis terhadap deteksi parasit Malaria dapat dilakukan lebih cepat dan lebih akurat dengan biaya yang terminimalisir.

Beberapa penelitian terdahulu tentang pemanfaatan artificial intelligence baik dalam bentuk deep learning maupun machine learning sudah banyak dilakukan oleh beberapa peneliti terdahulu. Namun, beberapa penelitian terdahulu hanya fokus pada objek tertentu. Sebagai contoh penelitian yang dilakukan oleh Tyassari dkk (Tyassari et al., 2023) yang mengusulkan pemanfaatannya deep learning untuk mengindentifikasi jenis stadium malaria. Penelitian ini hanya fokus pada salah satu stadium saja yakni stadium Tropozoid. Padahal untuk melakukan diagnosis malaria terdapat tiga jenis stadium yang harus diidentifikasi. Penelitian lain dilakukan oleh Sukumarran dkk (Sukumarran et al., 2024) yakni tentang pemanfaat object detection method menggunakan YOLO untuk mengidentifikasi jenis-jenis spesies dari malaria. Penelitia ini hanya fokus pada jenis spesies malaria saja, padahal untuk dapat melakukan diagnosis malaria diperlukan identifikasi spesies dan stadium. Berdasarkan tabel di atas, penelitian-penelitian terdahulu (Tyassari et al., 2023)(Sukumarran et al., 2024)(Muazzaz & Goni, 2024)(Kumar et al., 2024)(Anugrah et al., 2023)(Aluvala et al., 2024) lebih banyak fokus pada jenis-jenis spesies malaria saja. Padahal keputusan diagnosis dan rekomendasi penanganan ditentukan dari bagaimana stadium malaria tersebut. Selain itu penelitian-penelitian terdahulu lebih banyak menggunakan data dalam bentuk ROI (Region of Interest) yang merupakan data sekunder berupa square image dari plasmodium. Berdasarkan uraian dari penelitian sebelumnya, maka penelitian ini memberikan kontribusi berupa pengembangan meotode object detection yang mampu mengidentifikasi jenis spesies dan jenis stadium sehingga hasil identifikasi dapat langsung dimanfaatkan oleh tenaga medis. Selain itu, penelitian ini menggunakan red blood cell (RBC) dataset yang diambil langsung dari rumah sakit sehingga keakuratan model yang dihasilkan lebih real sesuai dengan kondisi di rumah sakit.

2. METODOLOGI PENELITIAN

2.1 Object Detection

Object detection adalah suatu teknik dalam bidang visi komputer (computer vision) yang digunakan untuk mengidentifikasi dan menentukan lokasi objek-objek tertentu dalam sebuah gambar atau video. Berbeda dengan klasifikasi gambar yang hanya mengidentifikasi jenis objek dalam satu gambar secara keseluruhan, object detection tidak hanya mengenali jenis objek, tetapi juga memberikan koordinat lokasi objek tersebut dalam bentuk bounding box. Teknologi ini memanfaatkan algoritma pembelajaran mesin, terutama deep learning, dan sering digunakan dalam berbagai aplikasi seperti sistem keamanan, kendaraan otonom, analisis video, serta pengenalan wajah dan barang (Chibuta & Acar, 2020). Dalam penelitian ini, metode object detection digunakan untuk mengidentifikasi jenis spesies dan jenis stadium sehingga hasil identifikasi dapat langsung dimanfaatkan oleh tenaga medis.

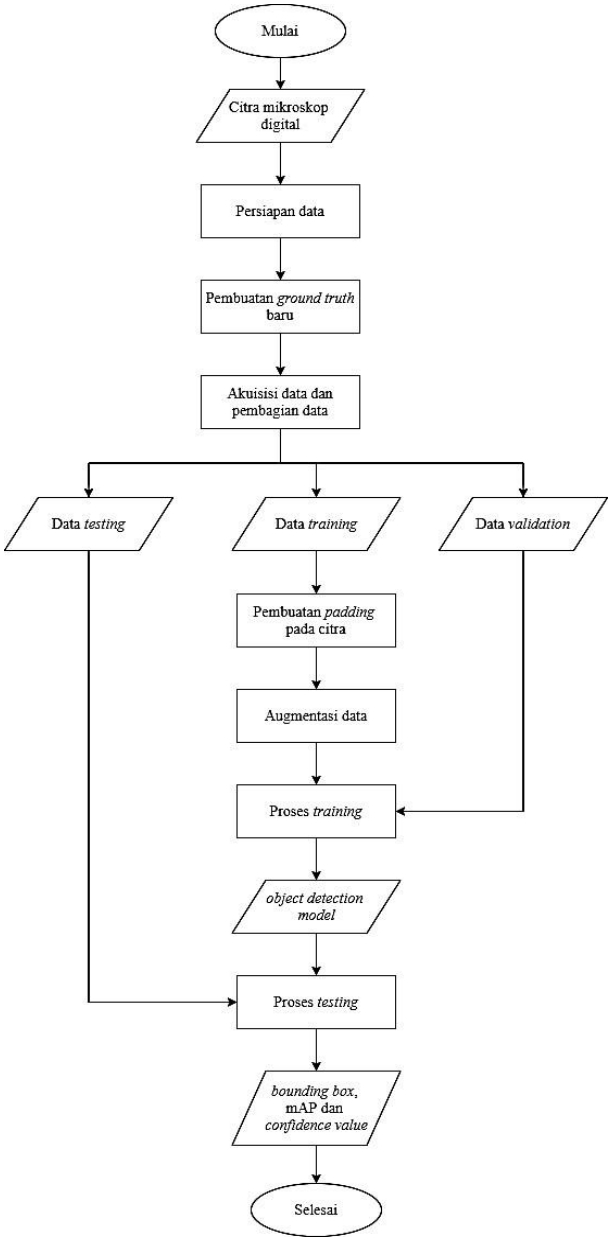
2.2 Perancangan Metode Object Detection

Penelitian ini terdiri atas tiga tahapan utama yakni persiapan, pengembangan metode, dan evaluasi. Tahap persiapan merupakan tahap yang bertujuan untuk mengumpulkan informasi-informasi penting yang berkaitan dengan penelitian seperti studi literatur. Kegiatan ini berfungsi untuk membantu dalam memahami permasalahan dan metode-metode atau pendekatan yang digunakan pada penelitian sebelumnya. Setelah memperoleh gambaran mengenai masalah yang diangkat dan kemungkinan solusi yang dapat digunakan untuk menyelesaikan masalah tersebut, kemudian dilakukan diskusi dengan dokter/tenaga medis terkait untuk mendapatkan masukan dan informasi dari sisi medis agar pengembangan metode yang dilakukan mampu bekerja sesuai dengan hasil yang diharapkan oleh dokter/tenaga medis.

Tahap kedua merupakan tahap pengembangan metode. Tahap pengembangan metode terdiri dari beberapa proses. Proses-proses tersebut digambarkan pada diagram flowchart pada Gambar 1.

Copyright © 2025 the author, Page 56
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187



Gambar 1. Diagram alur penelitian

Pada Gambar 1 disebutkan langkah-langkah pengembangan sistem yang dilakukan dalam penelitian ini. Sesuai dengan tujuan penelitian ini, penelitian ini dilakukan untuk mengembangkan metode deteksi parasit Plasmodium dan identifikasi spesies serta stadium pada parasit Plasmodium. Proses pengembangan diawali dengan proses persiapan data. Proses ini bertujuan untuk menganalisis karakteristik data yang digunakan. Hal ini dilakukan karena metode yang diterapkan harus sesuai dengan data yang digunakan agar performa metode yang dikembangkan dapat mencapai hasil maksimal. Setelah karakteristik data diketahui dan proses persiapan data selesai, tahap selanjutnya adalah tahap pembuatan ground truth baru. Ground truth yang disediakan oleh dokter/tenaga medis adalah ground truth manual yang digambar menggunakan software paint. Ground truth ini tidak dapat digunakan untuk masukan pada arsitektur deep learning. Oleh karena itu, dilakukan pembuatan ground truth baru menyesuaikan spesifikasi masukan yang dibutuhkan oleh deep learning.

Setelah ground truth baru selesai dibuat, proses dilanjutkan dengan tahap akuisisi data dan pembagian data. Dalam proses ini dilakukan pengecekan data untuk memastikan data yang sudah digunakan sudah benar. Selanjutnya data dibagi menjadi tiga bagian yakni data training, data validation dan data testing dengan proporsi 80:10:10. Data training digunakan untuk proses training, data validation digunakan untuk memvalidasi model pada saat proses training yang mana hasil performanya disimpan sebagai bobot pada tiap epoch untuk dijadikan masukan pada epoch selanjutnya, sedangkan data testing merupakan data yang digunakan untuk memvalidasi model yang telah terbentuk dari hasil training. Setelah pembagian data selesai kemudian dilakukan pelatihan data menggunakan arsitektur Faster RCNN dengan backbone ResNet-50. Dari hasil pelatihan, selanjutnya akan didapatkan model dimana model tersebut digunakan

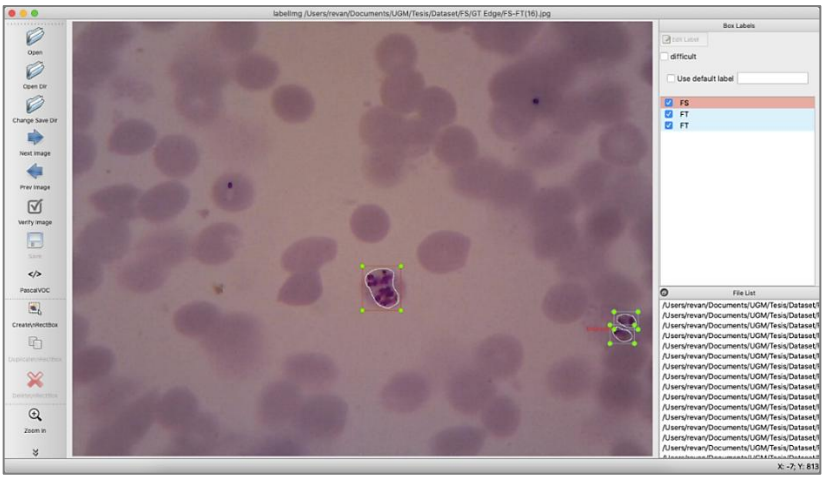
Copyright © 2025 the author, Page 57
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

untuk proses testing bersama dengan data testing. Setelah proses testing selesai, hasil deteksi selanjutnya dievaluasi dengan menghitung mean average precision (mAP) dan confidence value.

2.3 Persiapan Data dan Augmentasi Data

Tahap pertama dalam penelitian ini adalah tahap persiapan data. Tahap persiapan merupakan tahap yang bertujuan untuk menyiapkan data dan memastikan data yang digunakan dalam penelitian sudah tepat dan sesuai dengan metode yang dipilih. Dalam tahap ini ada beberapa yang dilakukan. Tahap awal dilakukan converting format file menjadi JPG sesuai dengan spesifikasi masukan pada arsitektur Faster RCNN. Setelah converting format file selesai dilakukan, tahap selanjutnya dilakukan pembuatan ground truth baru. Proses pembuatan ground truth baru ini dilakukan karena ground truth yang diberikan oleh dokter belum sesuai dengan spesifikasi masukan arsitektur Faster RCNN. Ground truth yang dibutuhkan dalam arsitektur Faster RCNN adalah ground truth berupa koordinat objek dan label (kelas) parasit Plasmodium. Oleh karena itu, dilakukan proses labelling dan pembuatan koordinat objek parasit Plasmodium. Proses pembuatan ground truth ini dilakukan dengan menggunakan tools LabelImg. LabelImg merupakan sebuah tools yang berfungsi untuk membantu proses anotasi objek. Contoh interface labelImg dan proses pembuatan ground truth dapat dilihat pada Gambar 2. Hasil dari proses pembuatan ground truth menggunakan LabelImg adalah file xml yang didalamnya terdapat nama file citra, koordinat objek dan label (kelas) dari objek. Contoh bentuk file xml dari hasil pembuatan ground truth menggunakan tools LabelImg dapat dilihat pada Gambar 2. Selain membuat ground truth baru, beberapa file pendukung lainnya seperti file CSV, file .pbtxt dan file .record juga dibuat sesuai dengan kebutuhan arsitektur Faster RCNN. File CSV merupakan file yang berisi komponen data seperti ID data, filename, box size (width dan height), label (kelas), box position (koordinat xmin, ymin, xmax dan ymax). File .pbtxtx merupakan file yang berisi labelmap untuk setiap kelas. Labelmap merupakan file nama label (kelas) dan jumlah kelas yang ada dalam data serta mendefinisikan tampilan label yang diinginkan pada saat hasil deteksi ditampilkan.



Gambar 2. *Interface* LabelImg dan contoh proses pembuatan *ground truth*.

FS-FT(16)

FS-FT(16).xml

```
<annotation>
    <folder>GT Edge</folder>
    <filename>FS-FT(16).jpg</filename>
    <path>/Users/revan/Documents/UGM/Tesis/Dataset/FS/GT Edge/FS-FT(16).jpg</path>
    <source>
        <database>Unknown</database>
    </source>
    <size>
        <width>1280</width>
        <height>960</height>
        <depth>3</depth>
    </size>
    <segmented>0</segmented>
    <object>
        <name>FS</name>
        <pose>Unspecified</pose>
        <truncated>0</truncated>
        <difficult>0</difficult>
        <bndbox>
            <xmin>640</xmin>
            <ymin>540</ymin>
            <xmax>725</xmax>
            <ymax>638</ymax>
        </bndbox>
    </object>
```

Gambar 3. Contoh isi *file* xml dari hasil pembuatan *ground truth* menggunakan LabelImg

Setelah data ground truth berupa xml dan data-data atau komponen-komponen yang lain selesai dibuat, selanjutnya dilakukan pengecekan dan akuisisi terhadap semua file-file tersebut. Beberapa penyesuaian juga dilakukan mengikuti kebutuhan arsitektur Faster RCNN. Data yang sudah siap selanjutnya dibagi menjadi tiga kelompok data. Ketiga kelompok data tersebut adalah data training, data validation dan data testing. Data training terdiri dari 80% citra dari total data, data validation terdiri atas 10% dan data testing terdiri atas 10%. Proporsi pembagian data ini

Copyright © 2025 the author, Page 58
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

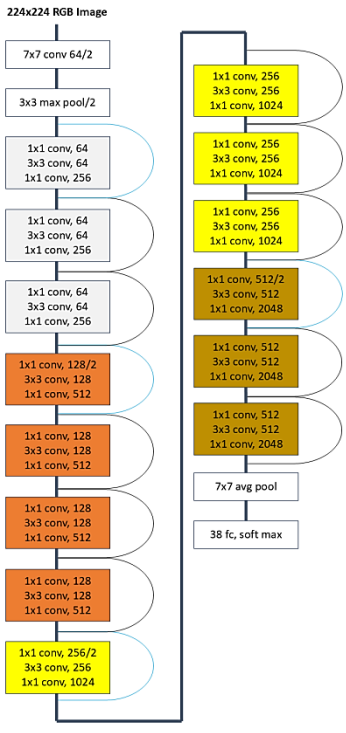
menyesuaikan jumlah data yang tidak terlalu banyak agar dalam masing-masing kelompok sudah memuat semua kelas dalam jumlah yang cukup. Data training selanjutnya dilakukan augmentasi untuk mendapatkan performa model yang baik. Augmentasi dilakukan dengan menerapkan proses rotasi dengan sudut 90^0, 180^0, 270^0 dan flip (horizontal dan vertical). Sebelum melakukan tahap augmentasi data, dilakukan proses padding terlebih dahulu karena data yang digunakan memiliki ukuran yang belum simetris. Proses padding dilakukan dengan menggunakan mencari nilai piksel maksimum dari setiap kolom matriks, kemudian ditambah ke sisi atas atau bawah citra. Nilai piksel maksimum dipilih karena nilai tersebut merupakan nilai yang paling mirip dengan background. Proses padding ini menghasilkan citra baru berukuran 1024x1024. Citra hasil penerapan padding selanjutnya dilakukan augmentasi menggunakan rotasi dan flip.

2.4 Proses Training dan Testing

Dalam penelitian ini, proses training menggunakan Faster RCNN + ResNet-50 dilakukan dengan menggunakan arsitektur pada Gambar 4 dengan beberapa konfigurasi lebih lanjut menyesuaikan karakteristik data seperti yang terdeskripsi pada Tabel 1 dan Tabel 2.

Tabel 1. Konfigurasi model Faster RCNN + ResNet-50

No	Configuration Name	Value
1.	Image Resizer:	
	Keep Aspect Ratio Resizer	Min dimension : 600 Max dimension : 1024
2.	Feature Extractor:	
	Type	Faster RCNN ResNet50
	First stage feature stride	16
3.	First Stage Anchor Generator (Grid Anchor):	
	Scales	[0.25, 0.5, 1.0, 2.0]
	Height Stride	16
	Width Stride	16
4.	First Stage NMS Score Threshold	0.0
5.	First Stage NMS IoU Threshold	0.7
6.	Maxpool Kernel Size	2
7.	Maxpool Stride	2
8.	Second Stage Box Predictor	
	Use Dropout	False
9.	Second Stage Post Processing	
	Batch Non Max Suppression	
	IoU Threshold	0.6
	Score Converter	Softmax



Gambar 4. Arsitektur backbone ResNet-50

This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

Tabel 2. Konfigurasi *training* Faster RCNN + ResNet-50

No	Configuration Name	Value
1.	Momentum Optimizer:	
	Initial Learning Rate	0.0003

2.5 Evaluasi

Dalam penelitian ini, proses evaluasi dilakukan dalam dua langkah yakni dengan mengevaluasi hasil deteksi dan mengevaluasi hasil klasifikasi 12 kelas. Proses evaluasi hasil deteksi dilakukan dengan menghitung mAP dan recall. Sedangkan untuk evaluasi hasil klasifikasi dilakukan dengan menghitung akurasi, sensitivitas, spesifisitas, positive predictive value dan negative predictive value. Kelima evaluation metric tersebut dihitung untuk semua backbone baik pada proses training maupun testing. Hasil akhir selanjutnya dibandingkan untuk mencari metode dengan performa paling baik.

Dalam perhitungan evaluasi deteksi dengan menghitung mAP dan recall, penelitian ini menggunakan persamaan (2-1) dan (2-2) seperti yang dijelaskan pada bab sebelumnya dimana dalam menentukan true positive (TP), penelitian ini menggunakan parameter intersection over union (IoU). IoU merupakan pengukuran area yang overlap antara objek terdeteksi dengan data ground truth. Pengukuran ini perlu dilakukan untuk mengevaluasi seberapa besar nilai overlap TP terhadap ground truth. Hal ini perlu dipastikan agar lokasi hasil deteksi tepat dan presisi pada objek yang benar. Dalam penelitian ini, nilai IoU yang digunakan adalah 0,5 atau 50% yang mana dapat diartikan jika area overlap antara lokasi objek yang terdeteksi dengan ground truth sudah lebih dari atau sama dengan 50% maka objek tersebut dapat dihitung sebagai TP.

$$\boldsymbol{mAP} = \frac{\mathbf{1}}{\boldsymbol{N}} \sum_{\boldsymbol{i=1}}^{\boldsymbol{N}} \boldsymbol{AP_i} \quad (1)$$

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

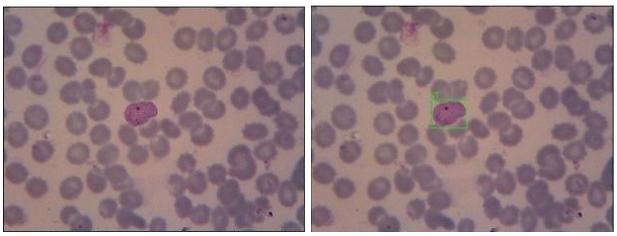
3. HASIL DAN PEMBAHASAN

3.1 Dataset

Data yang digunakan dalam penelitian ini berupa citra mikroskop digital sediaan darah tipis untuk kasus malaria yang didapatkan dari Departemen Parasitologi, Fakultas Kedokteran, Kesehatan Masyarakat, dan Keperawatan Universitas Gadjah Mada. Jumlah data yang digunakan dalam penelitian ini sejumlah 488 citra. Data Plasmodium yang digunakan terdistribusi dalam empat spesies yakni Plasmodium Vivax, Plasmodium Falciparum, Plasmodium Ovale dan Plasmodium Malariae. Masing-masing spesies terdiri dari tiga stadium yakni tropozoit, skizon dan gametosit. Sehingga total terdapat 12 kelas (kombinasi spesies dan stadium). Rincian data yang digunakan dapat dilihat pada Tabel 3.

Tabel 3. Rincian data parasit *Plasmodium*

No.	Nama kelas	Jumlah data
1.	Falciparum gametosit	46
2.	Falciparum skizon	48
3.	Falciparum tropozoit	32
4.	Vivax gametosit	32
5.	Vivax skizon	34
6.	Vivax tropozoit	37
7.	Ovale gametosit	59
8.	Ovale skizon	37
9.	Ovale tropozoit	32
10.	Malariae gametosit	42
11.	Malariae skizon	57
12.	Malariae tropozoit	32



(a) (b)

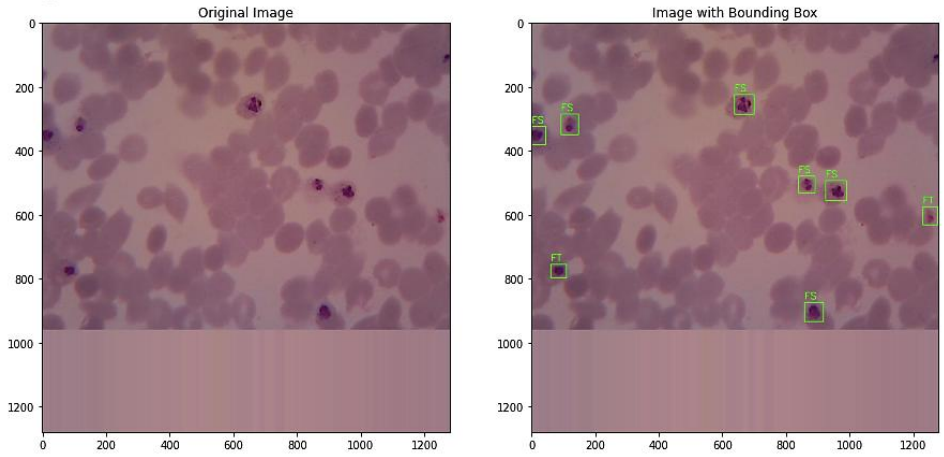
Gambar 5. Contoh data: (a) citra asli dan (b) citra *ground truth*

Copyright © 2025 the author, Page 60
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

3.2 Hasil

Dalam penelitian ini, proses augmentasi data diawali dengan proses penambahan padding pada citra. Hal ini dikarenakan ukuran citra yang kurang simetris, sehingga padding dilakukan untuk mempermudah proses augmentasi data. Proses padding dilakukan dengan menambahkan piksel di sisi bawah citra sehingga membentuk citra baru dengan ukuran 1024x1024. Nilai piksel yang ditambahkan merupakan nilai maksimum setiap kolom dalam matriks. Nilai piksel tersebut diambil karena nilai tersebut merupakan nilai yang paling mendekati background. Hasil padding data dapat dilihat pada Gambar 6. Proses padding tidak hanya dilakukan pada citra asli saja melainkan citra ground truth juga seperti yang ditunjukkan pada Gambar 6. Dari gambar tersebut terlihat hasil padding hampir menyerupai background sehingga tidak mempengaruhi atau membiaskan hasil deteksi yang dilakukan oleh metode deteksi yang diusulkan.



(a) (b)

Gambar 6. Contoh hasil padding: (a) padding pada citra asli dan (b) padding pada citra asli ditambahkan ground truth

Citra hasil *padding* pada Gambar 6 ini selanjutnya digunakan sebagai masukan untuk proses augmentasi data. Proses augmentasi data dilakukan dengan metode *flip* (*horizontal* dan *vertical*) dan rotasi dengan sudut 90^0, 180^0, 270^0. Visualisasi hasil augmentasi data untuk metode *flip* (*horizontal* dan *vertical*) dapat dilihat pada Gambar 4.3. Sedangkan visualisasi hasil penerapan metode rotasi dengan sudut 90^0, 180^0, 270^0 ditunjukkan pada Gambar 4.4. Pada hasil tersebut dapat dilihat bahwa metode *flip* (*horizontal* dan *vertical*) dan rotasi dengan sudut 90^0, 180^0, 270^0 dapat digunakan untuk melakukan augmentasi data dengan baik. Hasil augmentasi juga baik, dalam artian tidak merubah karakteristik citra secara signifikan seperti tujuan proses augmentasi yang sudah dijelaskan di bab sebelumnya. Semua citra tersebut selanjutnya digunakan untuk proses *training* menggunakan arsitektur Faster RCNN dengan eksperimen pada enam *backbone* Faster RCNN yang berbeda untuk mencari model terbaik yang mampu mendeteksi parasit *Plasmodium* dengan nilai *mean average precision* (mAP) tertinggi dan *confidence value* tertinggi pada setiap kelas parasit *Plasmodium* yang dideteksi.

Proses augmentasi data ini berhasil memperoleh hasil citra baru sebanyak 2232 citra dari akumulasi 12 kelas. Dalam satu citra terdiri atas beberapa objek. Sehingga total akumulasi objek setelah proses augmentasi data sebesar 3234 objek parasit Plasmodium. Rincian hasil augmentasi dapat dilihat pada Tabel 4. Sedangkan hasil citra dapat dilihat pada Gambar 7.

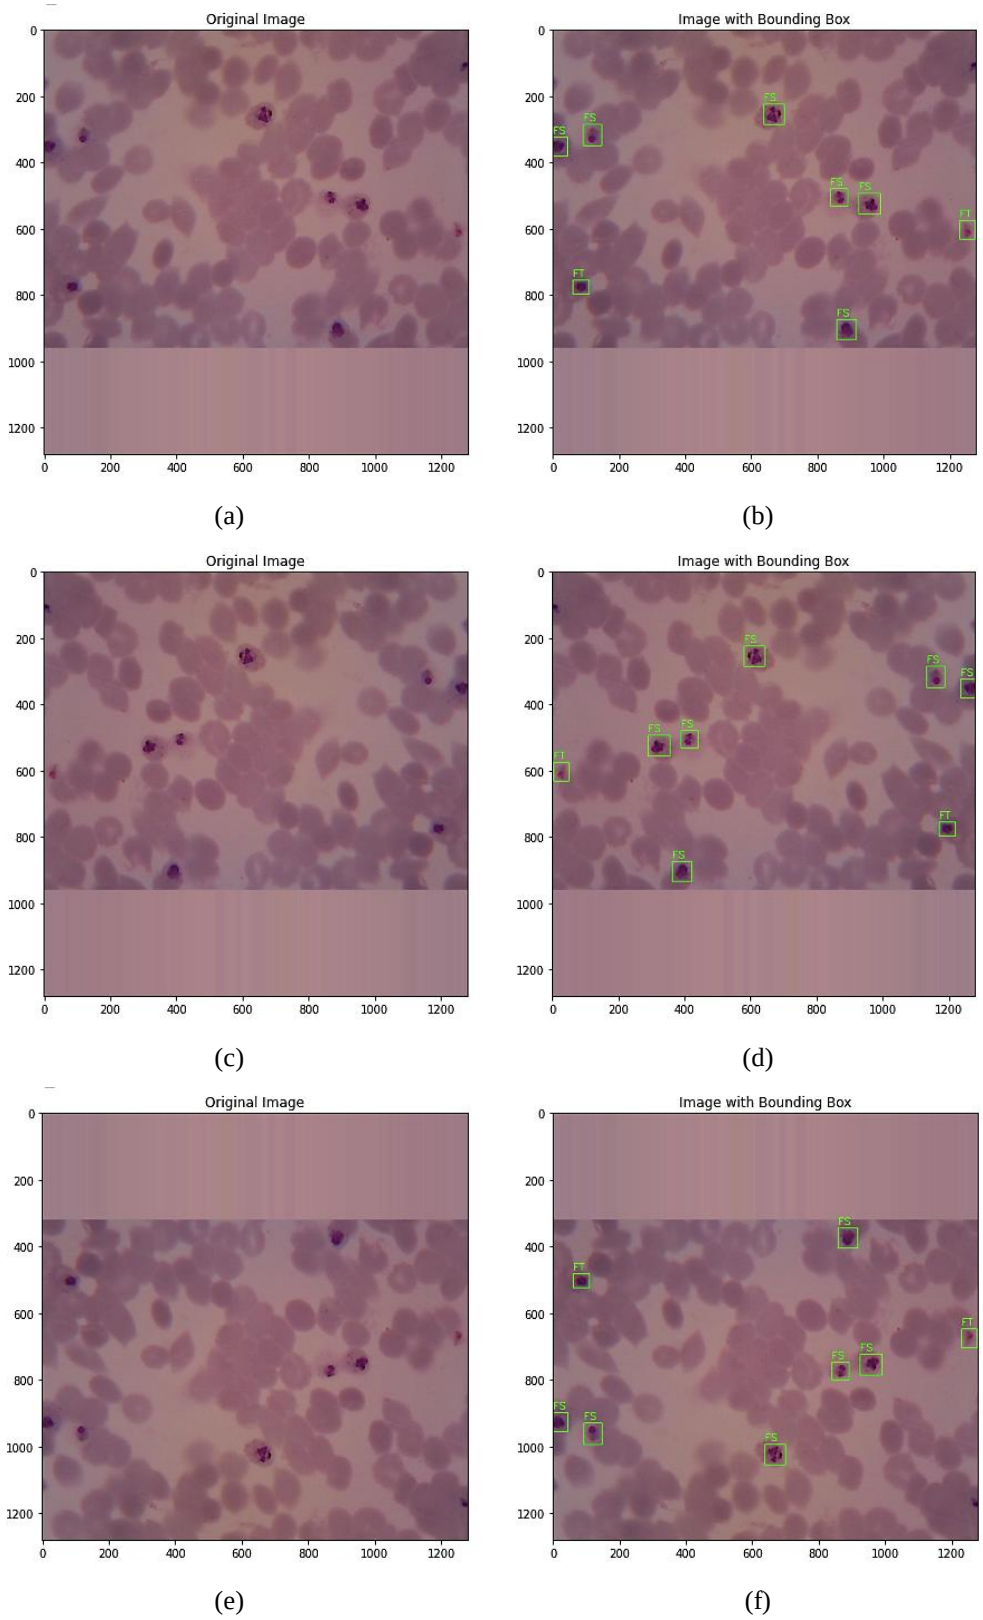
Tabel 4. Rincian hasil proses augmentasi data

No.	Kelas	Definisi kelas	Jumlah sebelum proses augmentasi	Jumlah sesudah augmentasi
1.	FT	Falcifarum Tropozoit	136	816
2.	FG	Falcifarum Gametosit	42	252
3.	FS	Falcifarum Skizon	108	648
4.	VT	Vivax Tropozoit	67	402
5.	VG	Vivax Gametosit	24	144
6.	VS	Vivax Skizon	49	294
7.	MT	Malariae Tropozoit	35	210
8.	MG	Malariae Gametosit	41	246
9.	MS	Malariae Skizon	59	354
10.	OT	Ovale Tropozoit	32	192
11.	OG	Ovale Gametosit	63	378
12	OS	Ovale Skizon	30	180
		Total	539	3234

Copyright © 2025 the author, Page 61
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

Seluruh data tersebut selanjutnya digunakan sebagai data masukan untuk proses *training* menggunakan arsitektur Faster RCNN.



Gambar 7. Hasil proses augmentasi data mengunakan metode flip: (a) citra hasil padding, (b) ground truth citra (a), (c) hasil flip horizontal, (d) ground truth citra (c), (e) flip vertikal dan (f) ground truth dari citra (e).

Proses training menggunakan ResNet-50 dilakukan dalam dua session. Session 1 untuk proses training dari step 0-120.000 sedangkan session 2 untuk proses training dari step 120.000-240.000. Berikut adalah hasil training menggunakan Faster RCNN + ResNet-50:

a. Hasil training step 0-120.000

Copyright © 2025 the author, Page 62
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

Berikut adalah hasil mAP, recall, accuracy, sensitivity, specificity, PPV, NPV, loss dan visualisasi beserta confidence value hasil deteksi untuk training pada step 0-120.000. Tabel 5 memperlihatkan hasil mAP dan AR pada IoU 50. Hasil yang diperoleh cukup baik dengan mAP dan AR mendekati 0,6 atau 60%. Angka ini cukup tinggi mengingat rata-rata mAP untuk kasus object detection adalah 0,73 atau 73%.

Tabel 5. Hasil deteksi proses *training* pada *step* 0-120.000

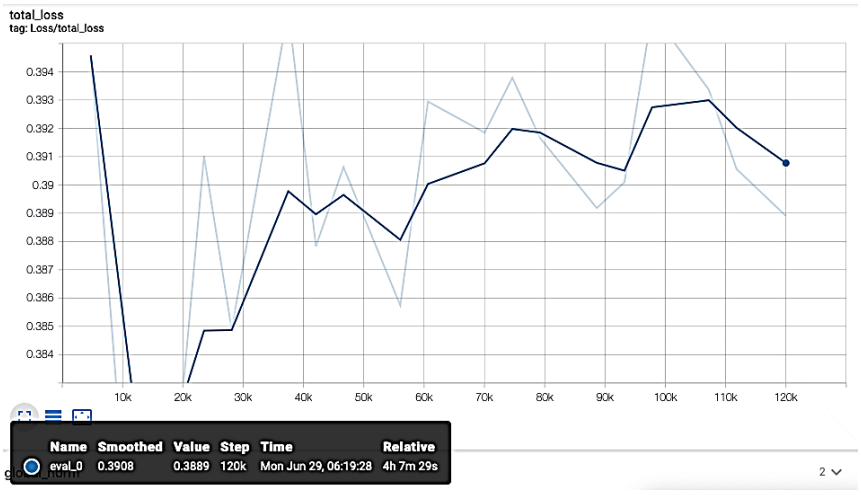
Komponen	mAP (IoU:50)	AR (100)
Hasil	0,5921	0,5633

Hasil lebih rinci dapat diamati pada Tabel 6. Pada tabel tersebut terlihat bahwa rata-rata akurasi pada setiap kelas adalah lebih dari 90% yang menandakan bahwa ResNet memiliki hasil training yang sangat baik. Akan tetapi terdapat beberapa kelas yang memiliki nilai PPV dan sensitivitas cukup rendah yang artinya kelas tersebut cukup sulit untuk dideteksi.

Tabel 6. Hasil klasifikasi proses *training* pada *step* 0-120.000

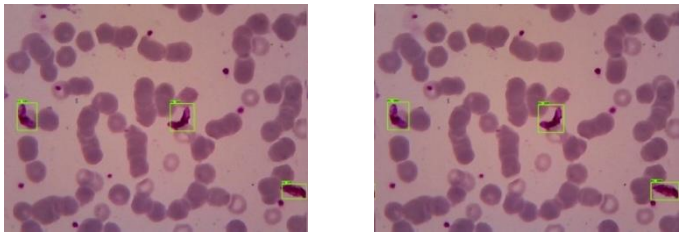
Kelas	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)	PPV (%)	NPV (%)
FG	94,94	100	94,52	60,00	100
FS	97,47	93,33	98,44	93,33	98,44
FT	97,47	92,31	98,48	92,31	98,48
MG	97,47	33,33	100	100	97,44
MS	97,47	50,00	100	100	97,40
MT	93,67	0,00	98,67	0,00	94,87
OG	93,67	75,00	94,67	42,86	98,61
OS	94,94	75,00	96,00	50,00	98,63
OT	96,15	25,00	100	100	96,10
VG	93,67	75,00	94,67	42,86	98,61
VS	89,87	50,00	92,00	25,00	97,18
VT	92,41	60,00	94,59	42,86	97,22
Rata-rata	94,93	60,75	96,84	62,43	97,75

Selanjut pada Gambar 8 terlihat hasil loss selama proses training berlangsung. Berdasarkan gambar tersebut terlihat bahwa loss yang dihasilnya cukup rendah. Berikut adalah *loss* dari hasil *training* pada *session* 1:



Gambar 8. Loss pada session 1

Selanjutnya untuk visualisasi hasil deteksi dapat dilihat pada Gambar 9 dan Gambar 10, berikut.

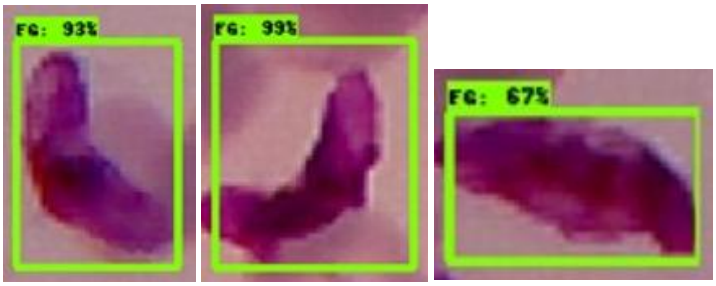


(a) (b)

Gambar 9. Hasil visualisasi training pada *session* 1: (a) hasil deteksi dan (b) *ground truth*

Copyright © 2025 the author, Page 63
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187



(a) (b) (c)

Gambar 10. Hasil deteksi *session* 1: (a) citra utuh, (b) objek 1 sebelah kiri atas, (c) objek 2 sebelah kanan atas dan (d) objek 3 sebelah kanan bawah

b. Hasil training step 120.000-240.000

Berikut adalah hasil mAP, recall, accuracy, sensitivity, specificity, PPV, NPV, loss dan visualisasi beserta confidence value hasil deteksi untuk training pada step 120.000-240.000. Tabel 7 memperlihatkan hasil mAP dan AR pada IoU 50. Hasil yang diperoleh kurang lebih sama dengan hasil training pada step 0-120.000. Hal ini menunjukkan adanya kestabilan hasil yang mengindikasikan nilai mAP dan AR maksimum yang dapat diperoleh.

Tabel 7. Hasil deteksi proses *training* pada *step* 120.000-240.000

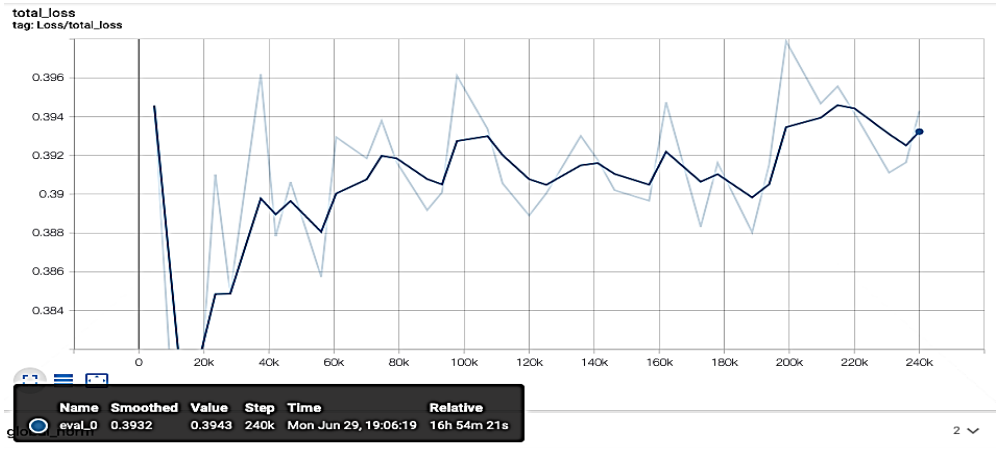
Komponen	mAP (IoU:50)	AR (100)
Hasil	0,5921	0,5633

Hasil lebih rinci dapat diamati pada Tabel 8. Pada tabel tersebut terlihat bahwa rata-rata akurasi pada setiap kelas adalah lebih dari 90% yang menandakan bahwa ResNet memiliki hasil training yang sangat baik.

Tabel 8. Hasil klasifikasi proses *training* pada *step* 120.000-240.000

Kelas	*Accuracy* (%)	*Sensitivity* (%)	*Specificity* (%)	PPV (%)	NPV (%)
FG	94,87	100	94,44	60,00	100
FS	97,44	93,33	98,41	93,33	98,41
FT	98,72	92,31	100	100	98,48
MG	97,44	33,33	100	100	97,40
MS	97,44	50,00	100	100	97,37
MT	93,59	0,00	98,65	0,00	94,81
OG	93,59	75,00	94,59	42,86	98,59
OS	94,87	75,00	95,95	50,00	98,61
OT	96,10	25,00	100	100	96,05
VG	93,59	75,00	94,59	42,86	98,59
VS	89,74	50,00	91,89	25,00	97,14
VT	92,31	60,00	94,52	42,86	97,18
Average	94,97	60,75	96,92	63,08	97,72

Selanjut pada Gambar 12 terlihat hasil loss selama proses training berlangsung. Berdasarkan gambar tersebut terlihat bahwa loss yang dihasilnya cukup rendah. Berikut adalah loss dari hasil training pada session 2:

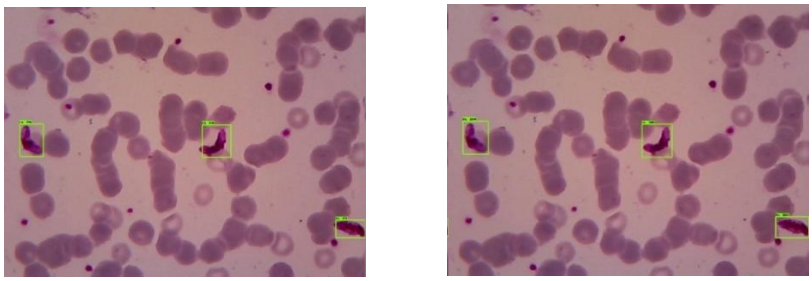


Gambar 11. Loss pada session 2

Selanjutnya berikut adalah visualisasi hasil deteksi:

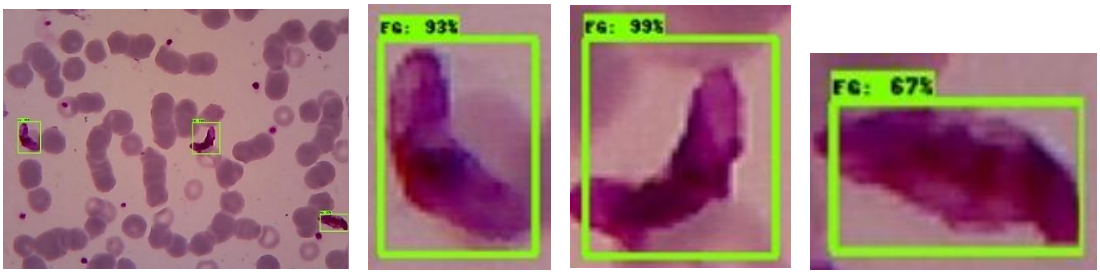
Copyright © 2025 the author, Page 64
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187



(a) (b)

Gambar 13. Hasil visualisasi training pada session 2: (a) hasil deteksi dan (b) ground truth



(a) (b) (c) (d)

Gambar 12. Hasil deteksi session 2: (a) citra utuh, (b) objek 1 sebelah kiri atas, (c) objek 2 sebelah kanan atas dan (d) objek 3 sebelah kanan bawah

c. Hasil Testing

Selanjutnya, dilakukan perhitungan evaluasi pada proses klasifikasi dengan menghitung lima komponen evaluasi yakni mAP, accuracy, sensitivity, specificity, PPV, NPV. Tabel 9 memperlihatkan hasil mAP dan AR pada IoU 50 pada proses testing. Hasil yang diperoleh meningkat dari hasil training baik pada step 0-120.000 dan step 120.000-240.000. Hal ini menunjukkan bahwa metode yang digunakan memiliki performa yang cukup baik dalam mendeteksi parasite plasmodium.

Tabel 9. mAP pada proses testing

Metode	mAP (IoU:50)	AR (100)
ResNet-50	0,603	0,516

Hasil lebih rinci terdapat pada Tabel 10 yang menunjukan hasil klasifikasi pada masing-masing kelas. Akurasi yang diperoleh cukup baik dimana mayoritas akurasi mencapai lebih dari 85%, bahkan terdapat akurasi hingga 100%. Namun untuk nilai PPV dan sensitivitas, nilai yang diperoleh masih terdapat nilai yang cukup rendah.

Tabel 10. Hasil klasifikasi proses testing menggunakan ResNet-50

Kelas	*Accuracy* (%)	*Sensitivity* (%)	*Specificity* (%)	PPV (%)	NPV (%)
FG	95,52	75,00	96,83	60,00	98,39
FS	94,03	85,71	95,00	66,67	98,28
FT	89,55	63,64	94,64	70,00	92,98
MG	92,54	20,00	98,39	50,00	93,85
MS	95,52	25,00	100	100	95,45
MT	98,51	100	98,41	80,00	100
OG	89,55	25,00	93,65	20,00	95,16
OS	94,03	100	93,75	42,86	100
OT	100	100	100	100	100
VG	94,03	50,00	96,83	50,00	96,83
VS	88,06	50,00	90,48	25,00	96,61
VT	95,52	100	95,24	57,14	100
Average	93,91	66,20	96,10	60,14	97,30

3.2 Pembahasan

Berdasarkan hasil training maupun testing yang disajikan pada Tabel 5 hingga Tabel 10, dapat disimpulkan bahwa arsitektur Faster RCNN dengan backbone ResNet 50 memiliki performa yang sangat baik dalam mendeteksi lokasi parasite plasmodium dan mengidentifikasi jenis spesies dan stadium dari plasmodium tersebut. Arsitektur ResNet-50 juga memiliki performa klasifikasi yang cukup baik yakni dengan akurasi sebesar 93,91%, sensitivitas sebesar 66,20%, spesifisitas sebesar 96,10%, PPV sebesar 60,14%, dan NPV sebesar 97,30%. Meskipun memiliki performa yang

Copyright © 2025 the author, Page 65
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

relative baik, berdasarkan hasil analisis ditemukan bahwa arsitektur Faster RCNN cukup sulit untuk mendeteksi kelas MT (Malariae Tropozoit) sehingga pada kelas ini paling banyak terjadi kesalahan klasifikasiHal ini dikarenakan memiliki karakteristik yang cukup sulit untuk dikenali karena memiliki ukuran yang sangat kecil. Selain itu objek pada kelas MT juga memiliki karakteristik yang mirip dengan objek lain baik itu kelas lain maupun artefak

4. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan sebuah arsitektur yang mampu melakukan deteksi otomatis terhadap parasite plasmodium serta mampu mengidentifikasi jenis-jenis spesies dan stadium dari parasite plasmodium. Pendekatan yang diusulkan dalam penelitian ini berhasil melakukan deteksi otomatis kandidat-kandidat parasit plasmodium dalam citra mikroskopis digital serta mengidentifikasi jenis spesies dan stadiumnya. Alur penelitian diawali dengan proses augmentasi data. Proses augmentasi yang dilakukan dalam penelitian ini menggunakan *geometric transformation* yakni rotasi pada sudut 90^0, 180^0 dan 270^0 dan *flip* (*horizontal* dan *vertical*) berhasil menghasilkan data baru yang semula berjumlah 539 menjadi 3234 data. Arsitektur deep learning yang dikembangkan dalam penelitian ini adalah Faster RCNN dengan backbone ResNet 50. Arsitektur ini berhasil memperoleh mAP sebesar 0,603 pada IoU 50%. Arsitektur ini juga berhasil memperoleh akurasi sebesar 93,91%, sensitivitas sebesar 66,20%, spesifisitas sebesar 96,10%, PPV sebesar 60,14%, dan NPV sebesar 97,30% dalam mengidentifikasi jenis-jenis spesies dan stadium parasite plasmodium. Hasil ini menunjukkan bahwa arsitektur yang digunakan memiliki perfoma yang baik dalam mendeteksi lokasi parasite plasmodium dan mengidentifikasi jenis spesies dan stadium dari plasmodium tersebut.

UCAPAN TERIMAKASIH

Penelitian ini didanai oleh Lembaga Penelitian dan Pengabdian Masyarakat Universitas Tidar Tahun Pendanaan 2025. Peneliti mengucapkan terimakasih kepada Departemen Parasitologi, Fakultas Kedokteran,Kesehatan Masyarakat, dan Keperawatan Universitas Gadjah Mada atas kolaborasi riset dengan menyediakan dataset yang dibutuhkan selama penelitian serta peneliti berterimakasih kepada Jurusan Teknik Elektro, Mekatronika, dan Informasi Universitas Tidar atas segala bentuk fasilitas yang mendukung penelitian.

REFERENCES

Aluvala, S., Bhargavi, K., Deekshitha, J., Suresh, B., Rao, G. N., & Sravani, A. (2024). A Web-Based Approach for Malaria Parasite Detection Using Deep Learning in Blood Smears. *2024 2nd World Conference on Communication & Computing (WCONF)*, 1–6. https://doi.org/10.1109/WCONF61366.2024.10692067

Anugrah, R., Usman, K., & Novamizanti, L. (2023). Classification of Malaria in Red Blood Cell Microscopic Images Using Deep Learning with EfficientNet Architecture and SVM. *2023 IEEE 8th International Conference on Recent Advances and Innovations in Engineering (ICRAIE)*, 1–6. https://doi.org/10.1109/ICRAIE59459.2023.10468300

Chibuta, S., & Acar, A. C. (2020). Real-time Malaria Parasite Screening in Thick Blood Smears for Low-Resource Setting. *Journal of Digital Imaging*, *33*(3), 763–775. https://doi.org/10.1007/s10278-019-00284-2

Ferdiana, A., Utsamani, C., Luthfi, A., Edi, S., & and Probandari, A. (2021). Finding the right balance: implementation of public–private partnership in artemisinin-based combination therapy provision in Manokwari, Indonesia. *Journal of Pharmaceutical Policy and Practice*, *14*(sup1), 90. https://doi.org/10.1186/s40545-021-00347-2

Fitri, L. E., Aulia Rahmi, P., Nuning, W., Agustina Tri, E., Alif Raudhah Husnul, K., Hafshah Yasmina, A., & and Huwae, J. T. R. (2023). Antimalarial Drug Resistance: A Brief History of Its Spread in Indonesia. *Drug Design, Development and Therapy*, *17*(null), 1995–2010. https://doi.org/10.2147/DDDT.S403672

Kementerian Kesehatan Republik Indonesia. (2017). Buku Saku Penatalaksanaan Kasus Malaria. In *Ikatan Dokter Indonesia*. Ikatan Dokter Indonesia. https://doi.org/10.22435/jek.v13i3Sep.5115.201-209

Kementerian Kesehatan Republik Indonesia. (2019). *Data Malaria di Indonesia*.

Kementerian Kesehatan RI. (2024). *Kasus malaria di Indonesia*. Direktorat Jenderal Pencegahan Dan Pengendalian Penyakit Kementerian Kesehatan RI. http://p2p.kemkes.go.id/kasus-malaria-di-indonesia-menurun-ntt-jadi-provinsi-pertama-di-kawasan-timur-berhasil-eliminasi-malaria/

Kumar, A., Nelson, L., Rasher, S., & Surendran, R. (2024). MosquitoNet Based Deep Learning Approach for Malaria Parasite Detection Using Cell Images. *2024 International Conference on Automation and Computation (AUTOCOM)*, 164–169. https://doi.org/10.1109/AUTOCOM60220.2024.10486136

Muazzaz, H. A., & Goni, O. F. (2024). Detection of Malaria Parasite Using Lightweight CNN Architecture and Smart Android Application. *2024 IEEE International Conference on Power, Electrical, Electronics and Industrial Applications (PEEIACON)*, 1–6. https://doi.org/10.1109/PEEIACON63629.2024.10800616

Poostchi, M., Silamut, K., Maude, R. J., Jaeger, S., & Thoma, G. (2018). Image analysis and machine learning for detecting malaria. *Translational Research*, *194*, 36–55. https://doi.org/https://doi.org/10.1016/j.trsl.2017.12.004

Prananda, A. R., Nugroho, H. A., & Ardiyanto, I. (2019). Enumeration of Plasmodium Parasites on Thin Blood Smear Digital Microscopic Images. *2019 5th International Conference on Science in Information Technology (ICSITech)*,

This Journal is licensed under a Creative Commons Attribution 4.0 International License


TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 55-67
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7187

223–228. https://doi.org/10.1109/ICSITech46713.2019.8987492

Prananda, A. R., Nugroho, H. A., & Frannita, E. L. (2021). Plasmodium Parasite Detection Using Combination of Image Processing and Deep Learning Approach. *Lecture Notes in Electrical Engineering*, *746*, 627–637.

Selasa, P. (2017). Implementation of Malaria Elimination Policy at Kupang City Public Health Center Implementasi Kebijakan Eliminasi Malaria di Pusat Kesehatan Masyarakat Kota Kupang. *Jurnal Info Kesehatan*, *15*(1), 97–109.

Sukumarran, D., Loh, E. S., Khairuddin, A. S. M., Ngui, R., Sulaiman, W. Y. W., Vythilingam, I., Divis, P. C. S., & Hasikin, K. (2024). Automated Identification of Malaria-Infected Cells and Classification of Human Malaria Parasites Using a Two-Stage Deep Learning Technique. *IEEE Access*, *12*, 135746–135763. https://doi.org/10.1109/ACCESS.2024.3459411

Supranelfy, Y., Warni, S. E., Inzana, N., & Suryaningtyas, N. H. (2018). Penemuan Kasus Malaria Berdasarkan Pemeriksaan Mikroskopis di Kota Lubuklinggau dan Kabupaten Musi Rawas. *ASPIRATOR - Journal of Vector-Borne Disease Studies*, *10*(1), 27–36. https://doi.org/10.22435/asp.v10i1.15

Tyassari, W., Jusman, Y., Payana, N. D., Kanafia, S. N. A. M., & Mohamed, Z. (2023). Clasification of Malaria Images in Thropozoid Stages Using Deep Learning Models. *2023 International Conference on Modeling & E-Information Research, Artificial Learning and Digital Applications (ICMERALDA)*, 30–34. https://doi.org/10.1109/ICMERALDA60125.2023.10458185

Wahab, A., Shaukat, A., Ali, Q., Hussain, M., Khan, T. A., Khan, M. A. U., Rashid, I., Saleem, M. A., Evans, M., Sargison, N. D., & Chaudhry, U. (2020). A novel metabarcoded 18S ribosomal DNA sequencing tool for the detection of Plasmodium species in malaria positive patients. *Infection, Genetics and Evolution*, *82*, 104305. https://doi.org/https://doi.org/10.1016/j.meegid.2020.104305

WHO. (2019a). *World malaria report 2019*. https://www.who.int/news-room/feature-stories/detail/world-malaria-report-2019

WHO. (2019b). *World malaria report 2019* (1st ed.).

Copyright © 2025 the author, Page 67
This Journal is licensed under a Creative Commons Attribution 4.0 International License