

Implementasi YOLOv3 Menggunakan Fitur Ekstraktor ResNeXt Untuk Deteksi Filariasis

*¹Erzal Syahreza Aswir dan ²Wasilah

^{1,2}Teknik Informatika, IBI Darmajaya, Bandar Lampung, Lampung, Indonesia
e-mail: *erzal.2121210011@mail.darmajaya.ac.id, ²wasilah@darmajaya.ac.id

Abstract — *Filariasis is a serious infectious disease prevalent in many tropical and subtropical countries, including Indonesia, caused by infection from filarial worms transmitted through mosquito bites. The disease can lead to severe limb swelling (elephantiasis) and permanent disability if not treated promptly. Early detection of Filariasis is crucial in preventing the progression of serious illness, reducing transmission, and lowering long-term treatment costs. Vector control and mass treatment with antiparasitic drugs are the main prevention strategies, while recent research explores AI-based detection methods, such as Convolutional Neural Networks (CNN), Faster R-CNN, K-Nearest Neighbors (KNN), SSD, and YOLO, to improve diagnostic efficiency for Filariasis. This study aims to integrate YOLOv3 and ResNeXt algorithms into a Filariasis detection model, with the hope of producing a fast, accurate, and efficient approach to identifying this disease. As a result, AI technology has the potential to support efforts in eradicating Filariasis through more effective and accurate early detection. The implementation of the YOLOv3 algorithm with ResNeXt as a feature extractor in object detection processes demonstrated excellent performance, with an average accuracy of 96.77%. This indicates that the object detection model is reliable and suitable for use in systems requiring accurate object detection, particularly in various types of anomalies and medical images.*

Keywords: Artificial Intelligence; YOLOv3; RexNeXt; Filariasis Detection.

1. PENDAHULUAN

Filariasis merupakan penyakit menular yang disebabkan oleh infeksi cacing filaria yang ditularkan melalui gigitan nyamuk. Penyakit ini umumnya menyerang sistem limfatik, yang mengalirkan limfa atau getah bening dalam tubuh manusia. Sistem limfatik berasal dari plasma darah yang keluar dari sistem kardiovaskular [1]. *Filariasis* merupakan masalah kesehatan yang serius di banyak negara tropis dan subtropis, termasuk Indonesia. Penyakit ini menyebabkan pembengkakan parah pada anggota tubuh (*elephantiasis*) yang dapat mengakibatkan kecacatan permanen jika tidak ditangani dengan cepat. Diagnosis *Filariasis* membutuhkan pemeriksaan mikroskopis sampel darah oleh tenaga medis terlatih, yang memerlukan waktu cukup lama [2].

Deteksi dini *Filariasis* penting untuk mencegah perkembangan penyakit menjadi kondisi kronis yang serius dan mengurangi penularan penyakit. *Filariasis* ditularkan melalui gigitan nyamuk yang membawa larva cacing filaria. Dengan deteksi dan pengobatan dini, risiko penularan ke orang lain dapat dikurangi secara signifikan [3]. Dari sisi biaya kesehatan, penanganan dini *Filariasis* mengurangi biaya jangka panjang, mengobati penyakit pada tahap awal lebih murah dan sederhana dibandingkan menangani komplikasi kronis yang memerlukan perawatan medis intensif. Deteksi dini juga mendukung program kesehatan masyarakat dalam upaya pemberantasan *Filariasis*. Program ini bertujuan mengurangi prevalensi penyakit dan melindungi masyarakat dari risiko infeksi. Dengan deteksi dini, program ini dapat berjalan lebih efektif dan efisien [4].

Dalam upaya pencegahan *Filariasis*, pengendalian vektor nyamuk sangat penting. Penggunaan kelambu berinsektisida saat tidur dan repelen nyamuk dalam bentuk *lotion* atau semprotan saat berada di luar rumah sangat dianjurkan. Pemberian obat pencegahan massal (*Mass Drug Administration*, MDA) dengan obat antiparasit seperti *Diethylcarbamazine* (DEC) dapat membunuh larva cacing filaria dalam tubuh manusia. Orang yang sudah terinfeksi perlu didiagnosis dan diobati dengan benar untuk mencegah perkembangan penyakit lebih lanjut. *Monitoring* dan evaluasi berkala terhadap populasi nyamuk di daerah endemik juga diperlukan untuk mengukur keberhasilan pengendalian nyamuk [5].

Penelitian deteksi *Filariasis* dapat menggunakan beberapa metode AI seperti CNN, Faster R-CNN, KNN, SSD, dan YOLO. Metode-metode ini dapat memeriksa apakah seseorang terjangkit *Filariasis* atau tidak. *Convolutional Neural Network* (CNN) efektif dalam menganalisis dan klasifikasi citra medis seperti *X-ray*, MRI, atau citra lainnya [6]. CNN dirancang untuk mengenali pola dan fitur dalam data visual yang dapat menjelaskan identifikasi penyakit, serta mampu secara otomatis mengekstrak fitur penting dari citra medis tanpa intervensi manusia, yang sangat berguna untuk mengidentifikasi struktur kompleks seperti mikro-*Filariasis*. Faster R-CNN menggabungkan jaringan proposal wilayah (*Region Proposal Network*, RPN) dengan CNN untuk menghasilkan dan mengklasifikasikan daerah proposal yang mengandung tanda-tanda penyakit secara efisien [7], unggul dalam mendeteksi *Filariasis* karena mampu melakukan deteksi objek dengan cepat dan akurat. *K-Nearest Neighbors* (KNN) dapat digunakan untuk klasifikasi dan klasterisasi berdasarkan kesamaan fitur, sehingga membantu dalam pengelompokan gejala *Filariasis* [8]. *Single Shot MultiBox Detector* (SSD) sangat cepat dan efisien dalam mendeteksi objek, ideal untuk aplikasi *real-time* dan analisis citra medis seperti *X-ray*, MRI, atau *CT-scan* [9].

YOLO (*You Only Look Once*) adalah teknik deteksi objek yang sangat cepat dan efisien, melakukan prediksi sekaligus untuk seluruh citra dalam satu proses, memungkinkan deteksi *real-time* dengan akurasi tinggi [10]. Meskipun semua metode tersebut memiliki keunggulan masing-masing, YOLOv3 sering dianggap lebih unggul dalam mendeteksi *Filariasis* karena kecepatan tinggi, akurasi, dan efisiensi komputasinya. Selanjutnya, ResNeXt adalah arsitektur jaringan saraf yang dikembangkan dengan konsep modularitas dan agregasi transformasi residual. ResNeXt terbukti meningkatkan akurasi dalam mendeteksi objek dengan kompleksitas dan komputasi yang lebih rendah dibandingkan jaringan lainnya [11].

Penelitian yang memanfaatkan YOLO ResNeXt dianggap berkualitas karena kemampuannya yang cepat dan akurat dalam mendeteksi objek. Algoritma tersebut mampu menangani beragam jenis objek dengan tingkat fleksibilitas yang tinggi, membuatnya relevan dalam sejumlah bidang aplikasi seperti visi komputer dan pengolahan citra medis [12]. Keefektifan YOLO ResNeXt dalam ranah penelitian terletak pada ketersediaan model-model pra-dilatihnya, yang mengakselerasi proses penelitian dan pengembangan di bidang visi komputer serta pengolahan citra [13]. Penelitian terdahulu juga mengakui kebermanfaatan penggunaan YOLO ResNeXt karena relevansinya yang luas dalam berbagai bidang, menjadikannya alat yang berharga dalam menyelesaikan tantangan deteksi objek di berbagai domain aplikasi [14]. Keunggulan utama YOLO ResNeXt adalah kemampuannya mengatasi berbagai jenis objek yang kompleks dalam citra, menjadikannya pilihan yang ideal untuk skenario-skenario deteksi objek yang menantang [15].

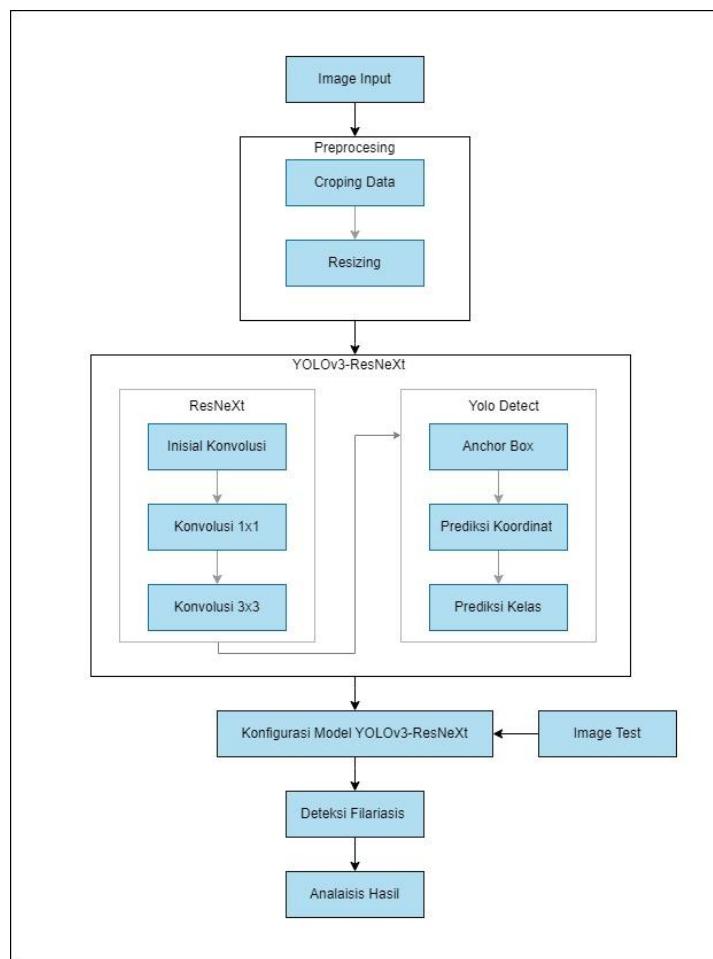
Implementasi algoritma YOLOv3 dengan fitur ekstraktor ResNeXt bertujuan meningkatkan akurasi dan efisiensi deteksi *Filariasis*. Kombinasi ini diharapkan menghasilkan model yang cepat dan akurat dalam mendeteksi keberadaan *Filariasis*, dengan kemampuan mengenali gejala kaki gajah dengan tingkat akurasi yang tinggi [16]. Penelitian ini berfokus pada pengembangan model deteksi *Filariasis* dengan mengintegrasikan algoritma YOLOv3 dengan fitur ekstraktor ResNeXt, serta mengevaluasi performa model yang diusulkan dari segi akurasi, kecepatan, dan efisiensi komputasi. Penggunaan teknologi ini bertujuan mendukung diagnosis dini dan penanganan tepat waktu, sehingga dapat mengurangi dampak kesehatan dan sosial yang disebabkan oleh *Filariasis* di daerah endemik. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknologi diagnostik berbasis kecerdasan buatan untuk *Filariasis*, mempercepat upaya pemberantasan penyakit melalui deteksi dini yang lebih efisien dan akurat.

2. METODOLOGI PENELITIAN

Desain struktur metodologi penelitian ini menggunakan fitur ekstraktor ResNeXt untuk deteksi *Filariasis* yang ditunjukkan pada Gambar 1.

2.1. Dataset

Penelitian ini menggunakan *dataset* berupa citra yang tersedia dalam format .jpg, .jpeg, atau .png, untuk menganalisis gejala penyakit kaki gajah (*Filariasis*). *Dataset* ini telah disiapkan menggunakan teknik *transfer learning*. Penelitian ini mengumpulkan total sebanyak 150 data citra yang dilakukan pembagian data dalam perbandingan persentase 80:20, di mana 70% citra digunakan sebagai data pelatihan, 10% citra untuk validasi, dan 20% citra untuk pengujian. Gambar 2 merupakan contoh data citra dalam penelitian ini.



Gambar 1. Flowchart metode dan tahapan penelitian.



Gambar 2. Citra Filariasis.

2.2. Pre-processing

Dalam melakukan *pre-processing*, pada penelitian ini dilakukan dua tahap sebelum melakukan pendekstian kelas, yaitu *cropping* dan *resizing*. Proses pertama adalah *cropping*, tahap ini merupakan proses pengeditan yang bertujuan untuk menghilangkan bagian-bagian tertentu dari *dataset* atau citra yang dianggap tidak relevan atau kurang penting, sehingga fokus dapat diarahkan pada bagian yang lebih bermakna atau signifikan [17]. Selanjutnya dilakukan *resizing* untuk mengubah ukuran citra menjadi 416 x 410 piksel dengan memperkecil dimensi citra secara horizontal dan/atau vertikal. Langkah ini bertujuan untuk mempercepat dan mempermudah proses *training*.

2.3. YOLOv3-ResNeXt

Penelitian ini menerapkan YOLOv3 karena kemudahannya dalam kompleksitas dan penggunaannya, serta akurasi data yang lebih tinggi dibandingkan versi sebelumnya [18]. Penelitian ini menggunakan *backbone* ResNeXt dalam YOLOv3 meningkatkan akurasi deteksi melalui penggunaan "kardinalitas", yang menawarkan jalur konvolusi paralel untuk meningkatkan ekstraksi fitur [19]. Dalam pengujian deteksi, YOLOv3 berhasil mengenali objek kaki manusia dan gejala penyakit kaki manusia dengan menggunakan sistem kecerdasan buatan [20]. Algoritma ini difokuskan pada deteksi kaki manusia dengan *dataset* yang telah dilabelkan menggunakan *Labeling*, sehingga objek selain kaki manusia tidak terdeteksi [21]. Selanjutnya, proses ekstraksi fitur kompleks dilakukan menggunakan konvolusi 1x1 dan 3x3 dalam ResNeXt untuk mengatur dimensi dan menggabungkan informasi saluran konvolusi [22]. Tahap berikutnya melibatkan *anchor box*, prediksi koordinat, dan prediksi kelas untuk memperkirakan lokasi, ukuran, dan jenis objek dalam citra [23]. Dengan memanfaatkan fitur ekstraktor ResNeXt, YOLOv3 dapat mengenali objek dengan akurasi yang lebih tinggi, karena *backbone* tersebut membantu dalam ekstraksi fitur yang lebih baik, sehingga memperbaiki kemampuan algoritma untuk memahami konteks citra dan mengidentifikasi objek dengan lebih baik [24].

2.4. Confusion matrix

Confusion matrix adalah metode evaluasi yang digunakan untuk menilai akurasi dari model klasifikasi. Matriks ini memuat informasi mengenai jumlah prediksi yang dilakukan oleh model dan dibagi menjadi empat kategori utama: *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN). Analisis pengujian dalam *confusion matrix* yaitu *True Positive* (TP) merupakan data positif yang berhasil dideteksi sebagai positif oleh model. *False Positive* (FP) adalah data negatif yang salah dideteksi sebagai positif. *True Negative* (TN) adalah data negatif yang berhasil dideteksi sebagai negatif. *False Negative* (FN) adalah data positif yang salah dideteksi sebagai negatif. Tabel 1 berikut adalah representasi kategori prediksi dalam *confusion matrix* [25].

Tabel 1. Kategori prediksi model pada *confusion matrix*.

Actual	Prediction	
	Positive	Negative
Positive	True Positive	False Negative
Negative	False Positive	True Negative

Berdasarkan *confusion matrix* seperti pada Tabel 1, performa model dapat dievaluasi melalui beberapa metrik seperti akurasi, presisi, *recall*, dan *specificity*. Akurasi adalah metrik pengukuran yang paling umum digunakan untuk mengevaluasi efektivitas model klasifikasi. Akurasi mengukur seberapa akurat model dalam memprediksi data yang benar dengan membagi jumlah prediksi yang benar ($TP + TN$) dengan total jumlah prediksi ($TP + TN + FP + FN$), kemudian dikalikan dengan 100% untuk mendapatkan persentase [26]. Analisis hasil akurasi diukur dengan persentase total prediksi yang benar, yang diperoleh dengan membagi jumlah prediksi yang benar (TP dan TN) dengan total jumlah prediksi. Semakin tinggi nilai akurasi, semakin baik performa model dalam memprediksi objek [27].

3. HASIL DAN PEMBAHASAN

Pada bab hasil dan pembahasan, terdapat beberapa subbab yang akan dibahas diantaranya hasil pelatihan algoritma, pengujian *dataset*, evaluasi hasil pengujian, dan analisis kinerja algoritma YOLOv3-ResNext.

3.1. Training Data

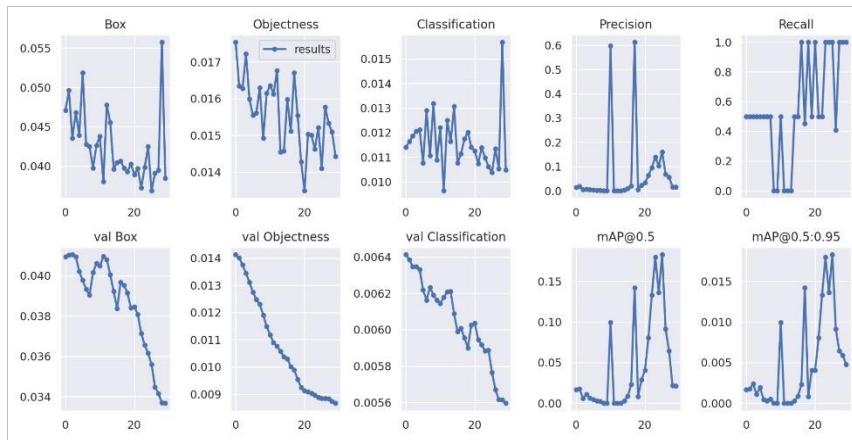
Dalam proses *training data*, algoritma dilatih menggunakan dataset yang telah dianotasi yang menunjukkan lokasi dan jenis objek yang ingin dideteksi. Selanjutnya, data diproses pada tahap *pre-processing*, termasuk *resizing*, normalisasi, dan augmentasi untuk meningkatkan variasi. Model menyiapkan *file* konfigurasi yang biasa disebut *model-conv* yang digunakan untuk menentukan parameter pelatihan seperti lokasi data, jumlah kelas, dan konfigurasi model YOLOv3-ResNext. Selanjutnya model menginisialisasi dengan menggunakan

bobot awal yang telah dilatih pada *dataset*. Pelatihan dilakukan dengan mengoptimalkan parameter model melalui algoritma *backpropagation* dengan stokastik gradien pada data pelatihan. Setelah pelatihan, model divalidasi menggunakan *dataset* yang berbeda untuk memastikan kinerjanya sesuai dengan harapan. Tabel 2 menunjukkan hasil *epoch training data*.

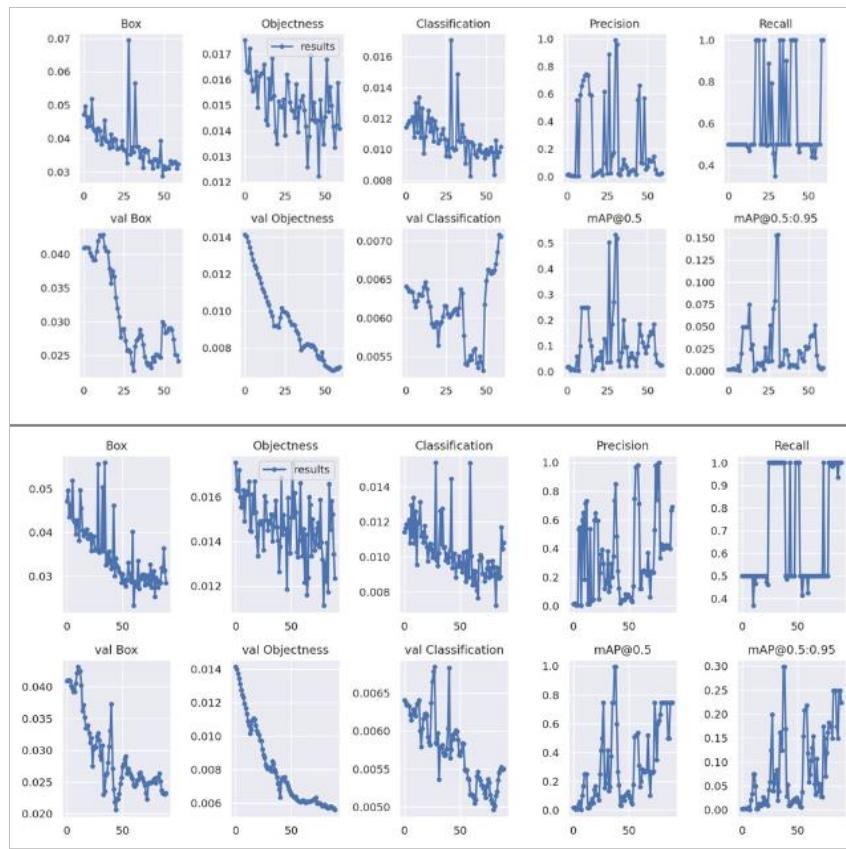
Tabel 2. Hasil *epoch training data*.

No	Epoch	Hasil																												
1	30	<table border="1"> <thead> <tr> <th>Class</th> <th>Images</th> <th>Labels</th> <th>P</th> <th>R</th> <th>mAP@.5</th> <th>mAP@.5:.95:</th> </tr> </thead> <tbody> <tr> <td>all</td> <td>2</td> <td>2</td> <td>0.0157</td> <td>1</td> <td>0.0213</td> <td>0.00478</td> </tr> <tr> <td>Filariasis</td> <td>2</td> <td>1</td> <td>0.0211</td> <td>1</td> <td>0.0321</td> <td>0.00642</td> </tr> <tr> <td>Normal</td> <td>2</td> <td>1</td> <td>0.0104</td> <td>1</td> <td>0.0105</td> <td>0.00315</td> </tr> </tbody> </table>	Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:	all	2	2	0.0157	1	0.0213	0.00478	Filariasis	2	1	0.0211	1	0.0321	0.00642	Normal	2	1	0.0104	1	0.0105	0.00315
Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:																								
all	2	2	0.0157	1	0.0213	0.00478																								
Filariasis	2	1	0.0211	1	0.0321	0.00642																								
Normal	2	1	0.0104	1	0.0105	0.00315																								
2	60	<table border="1"> <thead> <tr> <th>Class</th> <th>Images</th> <th>Labels</th> <th>P</th> <th>R</th> <th>mAP@.5</th> <th>mAP@.5:.95:</th> </tr> </thead> <tbody> <tr> <td>all</td> <td>2</td> <td>2</td> <td>0.0236</td> <td>1</td> <td>0.0249</td> <td>0.0037</td> </tr> <tr> <td>Filariasis</td> <td>2</td> <td>1</td> <td>0.0236</td> <td>1</td> <td>0.0255</td> <td>0.00255</td> </tr> <tr> <td>Normal</td> <td>2</td> <td>1</td> <td>0.0237</td> <td>1</td> <td>0.0243</td> <td>0.00486</td> </tr> </tbody> </table>	Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:	all	2	2	0.0236	1	0.0249	0.0037	Filariasis	2	1	0.0236	1	0.0255	0.00255	Normal	2	1	0.0237	1	0.0243	0.00486
Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:																								
all	2	2	0.0236	1	0.0249	0.0037																								
Filariasis	2	1	0.0236	1	0.0255	0.00255																								
Normal	2	1	0.0237	1	0.0243	0.00486																								
3	90	<table border="1"> <thead> <tr> <th>Class</th> <th>Images</th> <th>Labels</th> <th>P</th> <th>R</th> <th>mAP@.5</th> <th>mAP@.5:.95</th> </tr> </thead> <tbody> <tr> <td>all</td> <td>2</td> <td>2</td> <td>0.691</td> <td>1</td> <td>0.746</td> <td>0.224</td> </tr> <tr> <td>Filariasis</td> <td>2</td> <td>1</td> <td>0.461</td> <td>1</td> <td>0.498</td> <td>0.0498</td> </tr> <tr> <td>Normal</td> <td>2</td> <td>1</td> <td>0.922</td> <td>1</td> <td>0.995</td> <td>0.398</td> </tr> </tbody> </table>	Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95	all	2	2	0.691	1	0.746	0.224	Filariasis	2	1	0.461	1	0.498	0.0498	Normal	2	1	0.922	1	0.995	0.398
Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95																								
all	2	2	0.691	1	0.746	0.224																								
Filariasis	2	1	0.461	1	0.498	0.0498																								
Normal	2	1	0.922	1	0.995	0.398																								
4	120	<table border="1"> <thead> <tr> <th>Class</th> <th>Images</th> <th>Labels</th> <th>P</th> <th>R</th> <th>mAP@.5</th> <th>mAP@.5:.95:</th> </tr> </thead> <tbody> <tr> <td>all</td> <td>2</td> <td>2</td> <td>0.998</td> <td>0.5</td> <td>0.663</td> <td>0.63</td> </tr> <tr> <td>Filariasis</td> <td>2</td> <td>1</td> <td>0.997</td> <td>1</td> <td>0.995</td> <td>0.995</td> </tr> <tr> <td>Normal</td> <td>2</td> <td>1</td> <td>1</td> <td>0</td> <td>0.332</td> <td>0.265</td> </tr> </tbody> </table>	Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:	all	2	2	0.998	0.5	0.663	0.63	Filariasis	2	1	0.997	1	0.995	0.995	Normal	2	1	1	0	0.332	0.265
Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:																								
all	2	2	0.998	0.5	0.663	0.63																								
Filariasis	2	1	0.997	1	0.995	0.995																								
Normal	2	1	1	0	0.332	0.265																								

Berdasarkan hasil *training* pada *dataset*, dapat dilihat bahwa disajikan 30 sampai 120 *epoch*. Dalam setiap *epoch*, model melihat semua data yang tersedia, memperbarui parameternya berdasarkan gradien dari setiap *batch*, dan menyesuaikan diri dengan pola-pola yang ada dalam data sehingga dapat membentuk model yang efektif.

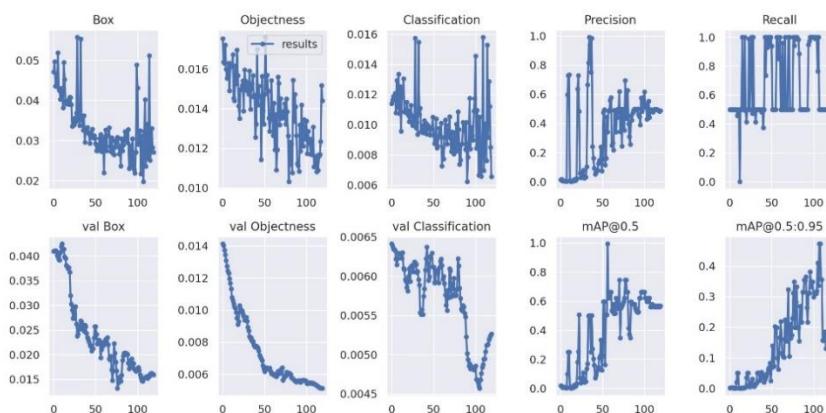
Gambar 3. Grafik hasil pelatihan dan validasi pada *epoch* 30.

Pada Gambar 3, metrik pelatihan pada baris atas meliputi *Box Loss*, *Objectness Loss*, dan *Classification Loss* yang semuanya menunjukkan tren menurun, menandakan peningkatan akurasi dalam memprediksi dan mengklasifikasikan objek. *Precision* dan *Recall* menunjukkan beberapa fluktuasi namun cenderung meningkat, menandakan model semakin baik dalam mendekripsi objek dengan lebih sedikit kesalahan. *mAP@0.5* dan *mAP@0.5:0.95* juga meningkat, menunjukkan performa keseluruhan model yang semakin baik. Selanjutnya, dalam metrik validasi pada baris bawah, yaitu *val Box Loss*, *val Objectness Loss*, dan *val Classification Loss*, semuanya menurun, yang menunjukkan model dapat menggeneralisasi dengan baik pada data baru. *mAP* pada validasi juga menunjukkan peningkatan, mengindikasikan performa yang baik pada data yang tidak dilihat selama pelatihan. Analisis secara keseluruhan, grafik Gambar 3 menunjukkan model deteksi objek belajar dengan baik dan menunjukkan peningkatan performa pada berbagai metrik, baik untuk pelatihan maupun validasi.



Gambar 4. Grafik hasil pelatihan dan validasi atas epoch 60 dan bawah epoch 90.

Pada Gambar 4, metrik pelatihan *epoch 60* dan *epoch 90* pada baris atas meliputi *Box Loss*, *Objectness Loss*, dan *Classification Loss* semuanya masing-masing menunjukkan tren menurun, menandakan peningkatan akurasi dalam memprediksi dan mengklasifikasikan objek. *Precision* dan *Recall* menunjukkan beberapa fluktuasi namun cenderung meningkat, menandakan model semakin baik dalam mendeteksi objek dengan lebih sedikit kesalahan. Selanjutnya, dalam metrik validasi pada baris bawah, yaitu *val Box Loss*, *val Objectness Loss*, dan *val Classification Loss*, semuanya menurun, yang menunjukkan model dapat menggeneralisasi dengan baik pada data baru. *mAP* pada validasi juga menunjukkan peningkatan, mengindikasikan performa yang baik pada data yang tidak dilihat selama pelatihan. Analisis secara keseluruhan, grafik Gambar 4 masih menunjukkan model deteksi objek belajar dengan baik dan menunjukkan peningkatan performa pada berbagai metrik, baik untuk pelatihan maupun validasi.

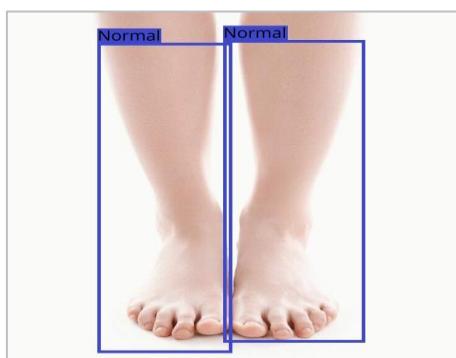


Gambar 5. Grafik hasil pelatihan dan validasi pada epoch 120.

Gambar 5 menampilkan grafik hasil pelatihan model yang mengukur performa melalui beberapa metrik. Grafik-grafik tersebut menunjukkan penurunan nilai loss untuk *bounding box*, *objectness*, dan klasifikasi, baik pada data pelatihan maupun validasi. Selain itu, grafik *precision* dan *recall* menunjukkan peningkatan, serta *Mean Average Precision* (mAP) meningkat pada berbagai *threshold IoU*. Secara keseluruhan, penurunan nilai loss dan peningkatan *precision*, *recall*, serta mAP menunjukkan bahwa model semakin baik dalam mendeteksi dan mengklasifikasikan objek-objek dalam citra seiring bertambahnya jumlah *epoch* pelatihan. Setelah disetujui, model siap untuk melakukan inferensi dan mendeteksi objek dalam citra, menyediakan prediksi lokasi dan kelas objek.

3.2. Testing Data

Dalam proses pengujian *model-conv*, terdapat 20% *dataset* uji dari total citra yang tersedia, yaitu sebanyak 30 citra. Pengujian ini merupakan tahap penting untuk mengevaluasi kinerja model setelah dilatih. Selanjutnya dilakukan *testing dataset* dengan *model-conv* sehingga dapat dilihat kinerja model untuk menggeneralisir informasi dari rekayasa data *testing*. Hasil pengujian data tersedia pada Gambar 6 sampai Gambar 8 berikut.



Gambar 6. Hasil pengujian kaki normal.

Gambar 6 menampilkan hasil pengujian yang menunjukkan kondisi kaki normal, memberikan gambaran jelas mengenai kemampuan model dalam mengidentifikasi kaki yang sehat. Hasil ini mencerminkan akurasi model dalam mendeteksi kondisi normal pada *dataset* yang digunakan.



Gambar 7. Hasil pengujian kaki gajah (*filariasis*) dan kaki normal.

Gambar 7 menunjukkan hasil pengujian dengan foto kaki gajah (*filariasis*) dan kaki normal. Hasil pengujian tersebut terlihat bahwa model dapat membedakan antara kaki yang terkena penyakit kaki gajah (*filariasis*) dan

kaki yang normal. Hasil ini menunjukkan kemampuan model dalam mengidentifikasi perbedaan antara kedua kondisi tersebut sangat baik.



Gambar 8. Hasil pengujian kaki gajah (*filariasis*).

Gambar 8 menampilkan hasil pengujian yang menunjukkan kondisi kaki gajah (*filariasis*), model memiliki informasi mengenai wawasan mendalam dan rekayasa data dalam mendeteksi dan membedakan kaki yang terkena penyakit kaki gajah (*filariasis*) dan kaki yang normal. Hasil ini menggambarkan seberapa akurat model dalam mengidentifikasi kondisi patologis pada dataset yang digunakan, serta menunjukkan efektivitas algoritma dalam menangani kasus medis spesifik seperti kaki gajah.

3.3. Evaluasi dan Analisis Hasil Pengujian

Dalam hasil pengujian terlihat bahwa model YOLOv3-ResNext dapat mendeteksi dengan baik sesuai dengan *bounding boxes* dan prediksi objek. Pada hasil *testing* data pada kelas *filariasis* terdapat 30 objek dalam seluruh *dataset*, terdapat satu objek yang tidak terbaca oleh model algoritma karena rekayasa pelatihan objek tersebut kurang. Di sisi lain, pada kelas normal terdapat 32 objek dalam seluruh *dataset*, yang mana terdapat satu objek yang tidak terbaca karena kontras citra *dataset* terlalu tinggi sehingga model susah mengenali data. Selanjutnya hasil pengujian tersebut dievaluasi dan dianalisis menggunakan *confusion matrix* yang dinyatakan dalam empat parameter yaitu *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN). Setelah dihitung menggunakan persamaan akurasi, didapatkan hasil perhitungan evaluasi akurasi kinerja model sebagaimana pada Tabel 3 berikut.

Tabel 3. Hasil rata-rata akurasi model.

Class	Akurasi
<i>Filariasis</i>	0,9667
<i>Normal</i>	0,9687

Tabel 3 menunjukkan rata-rata akurasi dari proses deteksi objek menggunakan YOLOv3-ResNext. Selanjutnya, hasil evaluasi pengujian tersebut diukur dalam skala kategori Tidak Baik (0%-60%), Cukup (61%-75%), Baik (76%-90%), dan Sangat Baik (91%-100%) [28]. Berdasarkan skala tersebut, dapat dilihat bahwa rata-rata akurasi model menunjukkan sangat baik dengan memiliki rata-rata keseluruhan akurasi 0,9677 atau dalam persentase 96,77%. Dengan demikian dapat disimpulkan bahwa implementasi algoritma Yolov3 menggunakan fitur ekstraktor ResNext pada penelitian ini dilakukan dengan baik dan akurat.

4. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa penggunaan algoritma YOLOv3 dengan fitur ekstraktor ResNeXt mampu meningkatkan akurasi deteksi objek hingga rata-rata 96,77%, membuktikan keandalannya bahkan pada citra kompleks. Optimalisasi langkah *pre-processing*, seperti *cropping* dan *resizing*, juga berperan dalam mendukung performa model. Hasil riset ini tidak hanya relevan untuk kebutuhan diagnostik medis, seperti deteksi filariasis, tetapi juga memiliki potensi aplikasi yang lebih luas, termasuk deteksi *real-time* dan integrasi dengan sistem kesehatan berbasis komunitas. Dengan inovasi teknologi yang didukung pemahaman medis yang kuat, hasil penelitian ini diharapkan memberikan kontribusi positif dalam bidang kesehatan, komputer, dan sektor lainnya.

DAFTAR PUSTAKA

- [1] J. G. Sumboh, N. A. Laryea, J. Otchere, C. S. Ahorlu, & D. K. de Souza, “Towards Understanding the Microepidemiology of Lymphatic Filariasis at the Community Level in Ghana”, *TropicalMed*, vol. 9, no. 5, 107, 2024, <https://doi.org/10.3390/tropicalmed9050107>
- [2] K. Tameemi & R. Kabakli, “Lymphatic Filariasis: An Overview”, *Asian Journal of Pharmaceutical and Clinical Research*, vol 12, no. 12, 2019, <https://doi.org/10.22159/ajpcr.2019.v12i12.35646>.
- [3] T. E. Newman, & A. L. Juergens, *Filariasis* dalam *StatPearls [Internet]*, Treasure Island (FL): StatPearls Publishing, 2023, Tersedia di: <https://www.ncbi.nlm.nih.gov/books/NBK556012/>.
- [4] E. A. Ottesen, P. J. Hooper, M. Bradley, & G. Biswas, *The global programme to eliminate lymphatic filariasis: health impact after 8 years* dalam *Institute of Medicine (US) Forum on Microbial Threats. The Causes and Impacts of Neglected Tropical and Zoonotic Diseases: Opportunities for Integrated Intervention Strategies*, Washington (DC): National Academies Press (US), 2011. Tersedia di: <https://www.ncbi.nlm.nih.gov/books/NBK62519/>.
- [5] World Health Organization [WHO], *Lymphatic filariasis - managing morbidity and preventing disability: an aide-mémoire for national programme managers, second edition*, Geneva: WHO Publications, 2021,
- [6] H. Jia, J. Zhang, K. Ma, X. Qiao, L. Ren & X. Shi, “Application of convolutional neural networks in medical images: a bibliometric analysis”, *Quantitative Imaging in Medicine and Surgery*, vol. 14, no. 5, pp. 3501-3518, 2024, <https://doi.org/10.21037/qims-23-1600>.
- [7] P. K. Mall, P. K. Singh, S. Srivastav, V. Narayan, M. Paprzycki, T. Jaworska & M. Ganzha, “A comprehensive review of deep neural networks for medical image processing: Recent developments and future opportunities”, *Healthcare Analytics*, vol. 4, 100216, 2023, <https://doi.org/10.1016/j.health.2023.100216>.
- [8] A. Yogianto, A. Homaidi & Z. Fatah, An Implementation of the K-Nearest Neighbors (KNN) Method for Classification of Heart Disease. *G-Tech: Jurnal Teknologi Terapan*, vol. 8, no. 3, 1720-1728, 2024, <https://doi.org/10.33379/gtech.v8i3.4495>.
- [9] O. Bouazizi, C. Azroumahi, A. E. Mourabit, & M. Oussouaddi, “Road Object Detection using SSD-MobileNet Algorithm: Case Study for Real-Time ADAS Applications”, *Journal of Robotics and Control*, vol. 5, no. 2, , 2024, <https://doi.org/10.18196/jrc.v5i2.21145>.
- [10] J. Terven, D. M. C. Esparza, & J. A. R. Gonzalez “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS”, *Machine Learning Knowledge Extraction*, vol. 5, no. 4, pp. 1680-1716, 2023, <https://doi.org/10.3390/make5040083>.
- [11] G.Pant, D.P. Yadav, & A. Gaur, “ResNeXt convolution neural network topology-based deep learning model for identification and classification of Pediastrum”, *Algal Research*, vol. 48, 101932, 2020, <https://doi.org/10.1016/j.algal.2020.101932>.

- [12] D. N. Kiran, K. N. Anuradha, & R. A. Leena, "An Object Detection Using State-Of-Art Deep Learning Yolo Network", *International Journal of Research in Engineering and Science (IJRES)*, vol. 9, no. 12, pp. 1-4, 2021.
- [13] T. Sarkar, M. Rakhra, V. Sharma, S. Takkar & K. Jairath, "Comparative Study of Object Recognition Utilizing Machine Learning Techniques," *International Conference on Communication, Computer Sciences and Engineering (IC3SE)*, Gautam Buddha Nagar, India, 2024, pp. 726-731, <https://doi.org/10.1109/IC3SE62002.2024.10593475>.
- [14] F. Imanuel, S. K. Waruwu, A. Linardy, & A. M. Husein, "Literature Review Application of YOLO Algorithm for Detection and Tracking" *Journal of Computer Networks, Architecture and High-Performance Computing*, vol. 6, no. 3, pp. 1378-1383, 2024, <https://doi.org/10.47709/cnahpc.v6i3.4374>.
- [15] A. S. Editya, T. Ahmad, H. Studiawan, & S. Silalahi, "YOLOFOR: YOLO and Optical Flow For Forensic Analysis of Attacked Drone Case", *ICIC Express Letters, Part B: Applications*, vol. 14, no. 12, pp. 1285-1293, 2023, <https://doi.org/10.24507/icicelb.14.12.1285>.
- [16] B. M. Ihsan, W. L. Puspita, L. Triana, Wahdaniah, Khayan, & C. D. Sucipto, "Identifikasi Mikrofilaria Menggunakan Reaksi Polimerase Berantai Konvensional dan QPCR-HRM", *Journal of Vocational Health Studies*, vol. 8, no. 1, 2024, pp. 42-47, <https://doi.org/10.20473/jvhs.V8.I1.2024.42-47>.
- [17] L. Jiao & J. Zhao, "A Survey on the New Generation of Deep Learning in Image Processing," *IEEE Access*, vol. 7, pp. 172231-172263, 2019, <https://doi.org/10.1109/ACCESS.2019.2956508>.
- [18] J. Redmon, & A. Farhadi, "YOLOv3: An Incremental Improvement", *Computer Vision and Pattern Recognition*, 2018, <https://doi.org/10.48550/arXiv.1804.02767>.
- [19] S. Xie, R. Girshick, P. Dollár, Z. Tu & K. He, "Aggregated Residual Transformations for Deep Neural Networks", *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, pp. 5987-5995, 2017, <https://doi.org/10.1109/CVPR.2017.634>.
- [20] S. A. F. Manssor, S. Sun, & M. A. M. Elhassan, "Real-Time Human Recognition at Night via Integrated Face and Gait Recognition Technologies". *Sensors*, vol. 21, 4323, 2021, <https://doi.org/10.3390/s21134323>.
- [21] Tzutalin. LabelImg. Retrieved from <https://github.com/tzutalin/labelImg>.
- [22] R. Girshick, "Fast R-CNN", *Computer Vision and Pattern Recognition*, 2015, <https://doi.org/10.48550/arXiv.1504.08083>.
- [23] J. Redmon, S. Divvala, R. Girshick, & A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection", *Computer Vision and Pattern Recognition*, 2016, <https://doi.org/10.48550/arXiv.1506.02640>.
- [24] K. He, X. Zhang, S. Ren & J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, pp. 770-778, 2016, <https://doi.org/10.1109/CVPR.2016.90>.
- [25] R. O. Duda, P. E. Hart, & D. G. Stork, *Pattern Classification*. John Wiley & Sons, 2012.
- [26] S. Marsland, *Machine Learning: An Algorithmic Perspective*. Chapman and Hall/CRC, 2015.
- [27] Y. Bengio, "Deep Learning of Representations for Unsupervised and Transfer Learning," *Proceedings of ICML Workshop on Unsupervised and Transfer Learning, PMLR*, vol. 27, pp. 17-36, 2012.
- [28] J. Du, J. Rong, S. Michalska, H. Wang, & Y. Zhang, "Feature selection for helpfulnessprediction of online product reviews: An empiricalstudy", *PLoS ONE*, vol. 14, no. 12, e0226902, 2019, <https://doi.org/10.1371/journal.pone.0226902>.