

PAPER NAME

Template Jurnal Pepadun - revisi.pdf

WORD COUNT

3787 Words

CHARACTER COUNT

24864 Characters

PAGE COUNT

11 Pages

FILE SIZE

712.7KB

SUBMISSION DATE

Jul 3, 2024 9:52 AM GMT+7

REPORT DATE

Jul 3, 2024 9:53 AM GMT+7

● 14% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

- 12% Internet database
- 6% Publications database
- Crossref database
- Crossref Posted Content database
- 12% Submitted Works database

● Excluded from Similarity Report

- Bibliographic material
- Quoted material
- Cited material
- Small Matches (Less than 10 words)

Implementasi YOLOv3 Menggunakan Fitur Ekstraktor ResNeXt Untuk Deteksi *Filariasis*

¹Erzal Syahreza Aswir, ²Wasilah

^{1,2,3}Magister Teknik Informatika, IBI Darmajaya, Bandar Lampung, Lampung, Indonesia
e-mail: ¹Erzal.2121210011@mail.darmajaya.ac.id, ²Wasilah@darmajaya.ac.id

Abstract ⁴ *Filariasis merupakan penyakit menular yang serius di banyak negara tropis dan subtropis, termasuk Indonesia, yang disebabkan oleh infeksi cacing filaria yang ditularkan melalui gigitan nyamuk. Penyakit ini dapat menyebabkan pembengkakan parah pada anggota tubuh (elephantiasis) dan kecacatan permanen jika tidak ditangani dengan cepat. Deteksi dini Filariasis penting untuk mencegah perkembangan penyakit yang serius, mengurangi penularan, serta mengurangi biaya jangka panjang dalam penanganannya. Pengendalian vektor nyamuk dan pengobatan massal dengan obat anti-parasit merupakan strategi pencegahan utama, sementara penelitian terbaru mengeksplorasi metode deteksi berbasis kecerdasan buatan (AI) seperti Convolutional Neural Network (CNN), Faster R-CNN, K-Nearest Neighbors (KNN), SSD, dan YOLO untuk meningkatkan efisiensi dalam diagnosis Filariasis. Penelitian ini bertujuan mengintegrasikan algoritma YOLOv3 dan ResNeXt dalam model deteksi Filariasis, dengan harapan menghasilkan pendekatan yang cepat, akurat, dan efisien dalam mengidentifikasi penyakit ini. Dengan demikian, teknologi AI berpotensi mendukung upaya pemberantasan Filariasis melalui deteksi dini yang lebih efektif dan akurat. Implementasi algoritma YOLOv3 dengan fitur ekstraktor ResNext dalam proses deteksi objek menunjukkan kinerja yang sangat baik, dengan rata-rata akurasi mencapai 96,77%. Hal ini mengindikasikan bahwa model deteksi objek tersebut dapat diandalkan dan cocok untuk digunakan dalam sistem yang memerlukan deteksi objek yang akurat terlebih dalam berbagai jenis anomaly dan gambar medis.*

Keywords: Kecerdasan Buatan, Yolov3, RexNext, Deteksi *Filariasis*

1. PENDAHULUAN

⁴ *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].* ⁶ *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 yang cukup lama [2].*

Deteksi dini *Filariasis* sangat 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* dapat mengurangi biaya jangka panjang. Mengobati penyakit pada tahap awal lebih murah dan lebih sederhana dibandingkan menangani komplikasi kronis yang memerlukan perawatan medis intensif dan berkelanjutan. 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-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 anti-parasit 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 gambar 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 gambar 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 klusterisasi berdasarkan kesamaan fitur, sehingga membantu dalam pengelompokan gejala *Filariasis* [8]. SSD (Single Shot MultiBox Detector) sangat cepat dan efisien dalam mendeteksi objek, ideal untuk aplikasi real-time dan analisis citra medis seperti X-ray, MRI, atau CT scan [9].

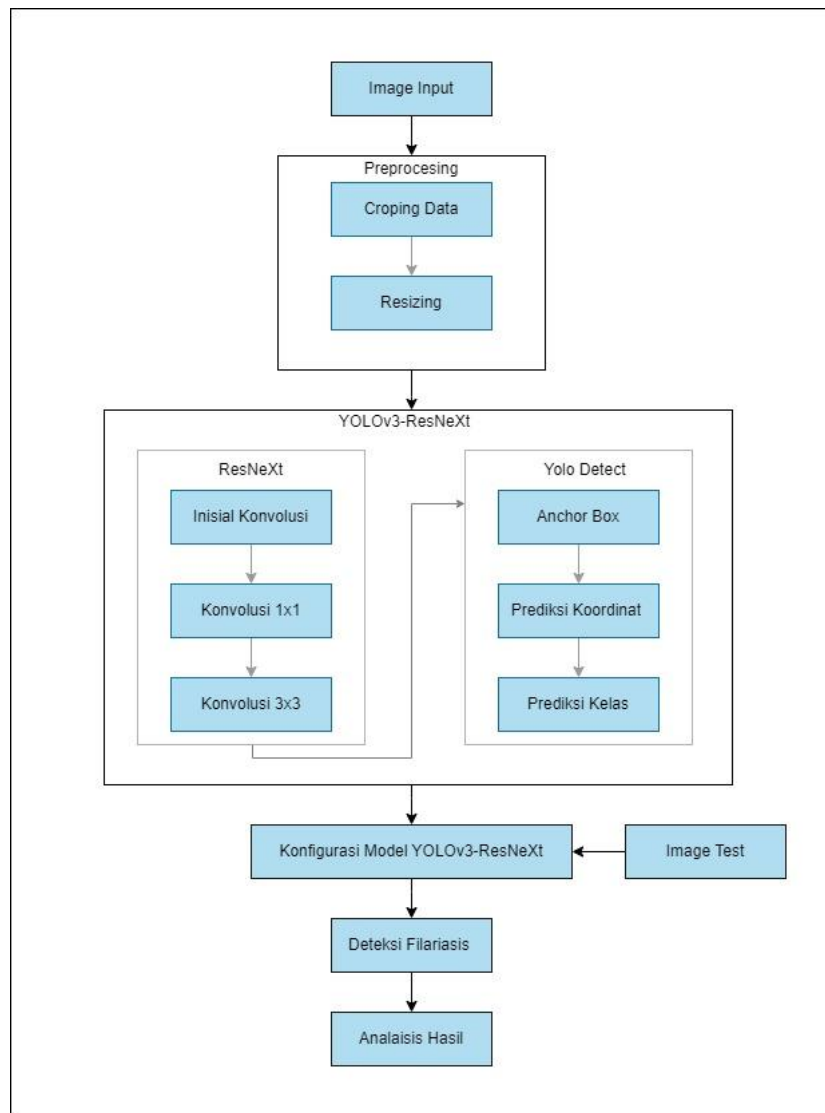
YOLO (You Only Look Once) adalah teknik deteksi objek yang sangat cepat dan efisien, melakukan prediksi sekaligus untuk seluruh gambar dalam satu proses, memungkinkan deteksi real-time dengan akurasi tinggi [10]. Meskipun semua metode tersebut memiliki keunggulan masing-masing, YOLOv3 sering dianggap 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]. Para peneliti 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 gambar, 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 Implementasi Algoritma YOLOv3 menggunakan fitur ekstraktor ResNeXt untuk deteksi *Filariasis* yang ditunjukkan pada Gambar 1 adalah sebagai berikut.



Gambar 1. Flowchart Metode dan tahapan penelitian

2.1. Dataset

Penelitian ini menggunakan dataset berupa gambar-gambar, yang biasanya tersedia dalam format .jpg, .jpeg, atau .png, untuk mendeteksi penyakit kaki gajah. Dataset ini telah disiapkan menggunakan teknik transfer learning. Proses ini dilakukan menggunakan fitur ekstraktor yang dikembangkan yaitu ResNext. Proses transfer learning di ResNext membutuhkan data file, cfg file, dan pre-trained weight. Data file berisi lokasi gambar yang akan digunakan untuk train dan test, nama class yang di training, dan lokasi penyimpanan weight hasil training. Configurasi file berisi bentuk jaringan yang digunakan untuk training, pre-trained weight berupa weight yang dilatih untuk mengenali objek ketika testing. Ketika model telah mendapat transfer learning untuk mengenali objek, evaluasi model tersebut akan berjalan dengan akurat dan efisien. Dalam penelitian ini, penulis mengumpulkan total 150 gambar untuk penelitian ini. Dari 150 gambar tersebut, penulis membaginya dalam perbandingan persentase 80:20, di mana 70% gambar digunakan sebagai data pelatihan, 10% gambar untuk validasi, dan 20% gambar untuk pengujian. Gambar 2 merupakan contoh dataset dalam penelitian ini.


Gambar 2. Gambar *Filariasis*

2.2. Pre-processing

Dalam melakukan *pre-processing* pada penelitian ini, akan dilakukan dua tahap sebelum melakukan pendeteksian kelas, yaitu *cropping* dan *resizing*. Proses pertama adalah *cropping*, tahap ini merupakan proses pengeditan yang bertujuan untuk menghilangkan bagian-bagian tertentu dari dataset atau gambar yang dianggap tidak relevan atau kurang penting, sehingga fokus dapat diarahkan pada bagian yang lebih bermakna atau signifikan [17]. Selanjutnya, setelah melakukan *cropping* data maka data akan 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]. 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 terlabelkan menggunakan Labelimg, sehingga objek selain kaki manusia tidak terdeteksi [21].



Gambar 3. Blok-blok fitur ekstraktor ResNext [23], [24]

ResNeXt adalah sebuah arsitektur jaringan neural yang merupakan pengembangan dari ResNet. Pada blok ResNeXt, input dengan dimensi 256 akan dibagi menjadi 32 jalur paralel. Setiap jalur ini memiliki tiga lapisan konvolusi: lapisan pertama dengan ukuran filter 1x1 dan 4 output channels, lapisan kedua dengan ukuran filter 3x3 dan 4 output channels, dan lapisan ketiga dengan ukuran filter 1x1 dan 256 output channels [22], [23].

Setelah melalui ketiga lapisan ini, output dari setiap jalur dijumlahkan. Proses penjumlahan ini menggabungkan informasi dari berbagai jalur yang berbeda, memungkinkan model untuk mengekstraksi fitur yang lebih kompleks tanpa meningkatkan kompleksitas komputasi secara signifikan [23], [24]. Dalam Langkah berikutnya, input asli ditambahkan ke hasil penjumlahan ini melalui residual connection, membantu dalam pelatihan jaringan yang sangat dalam dengan mengatasi masalah vanishing gradient. Dalam proses ekstraksi fitur, melibatkan anchor box, prediksi koordinat, dan prediksi kelas untuk memperkirakan lokasi, ukuran, dan jenis objek dalam gambar [24], [25]. 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 gambar dan mengidentifikasi objek dengan lebih baik [26].

2.4. Confusion matrix

Confusion matrix adalah metode evaluasi yang digunakan untuk menilai akurasi dari model klasifikasi. Tabel 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. Berikut adalah representasi kategori prediksi dalam confusion matrix [27].

Tabel 1. Kategori Prediksi Model pada Confusion Matrix

No	Prediksi		
	Sampel	Positif	Negative
1	Positif	True Positive	False Negative
2	Negatif	False Positive	True Negative

Dalam Tabel 1 diatas True Positive (TP) merupakan data positif yang terdeteksi positif, False Positive (FP) adalah data positif yang terdeteksi negative selanjutnya True Negative (TN) adalah data negatif yang terdeteksi negative, dan False Negative (FN) merupakan data negatif yang terdeteksi positif. Dalam confusion matrix, performa model 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]. Berikut diberikan persamaan akurasi confusion matrix.

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

Analisis hasil akurasi dimana 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 [29].

3. HASIL DAN PEMBAHASAN

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

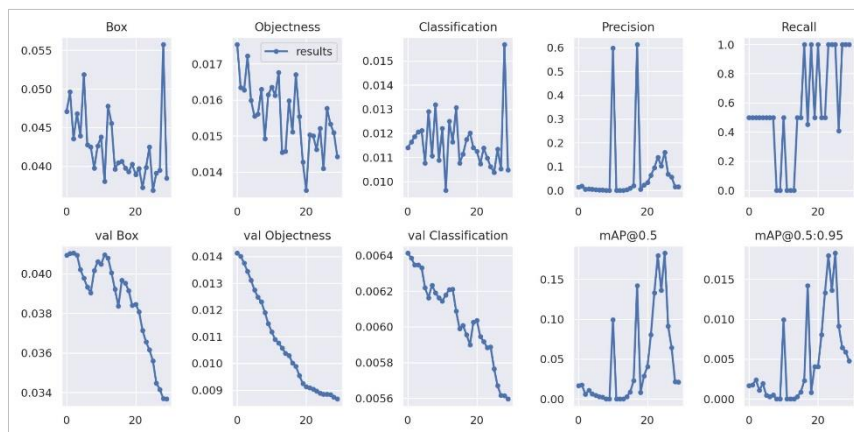
3.1. Training Data

Dalam proses training data, algoritma dilatih menggunakan dataset yang telah dianotasi yang menunjukkan lokasi dan jenis objek yang ingin dideteksi. Selanjutnya, data diproses untuk prapemrosesan, 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. Gambar 3 menunjukkan hasil *epoch* training data.

No	Epoch	Hasil						
1	30	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	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	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	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

Gambar 3. Hasil *epoch* training data

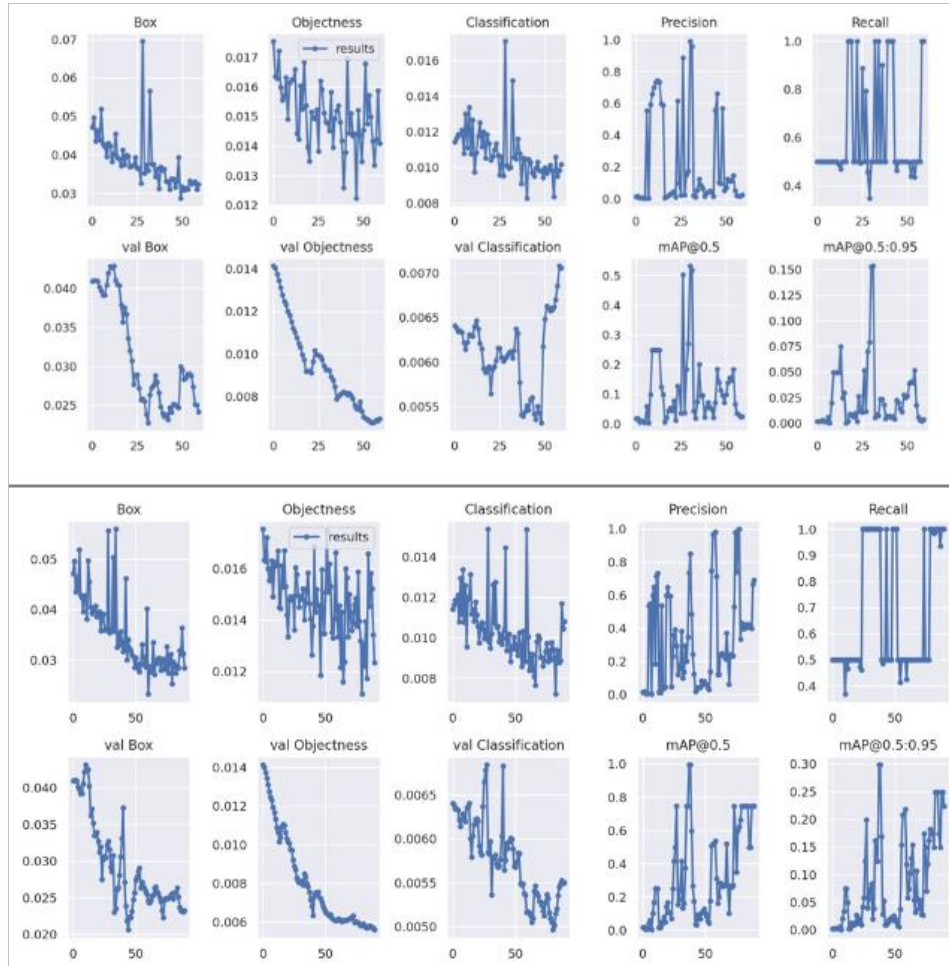
Berdasarkan hasil Training pada dataset, terlihat disajikan 30 sampai 120 Epoch. Dalam setiap epoch, model melihat semua data yang tersedia, memperbarui parameter-nya berdasarkan gradien dari setiap batch, dan menyesuaikan diri dengan pola-pola yang ada dalam data sehingga dapat membentuk model yang efektif.



Gambar 4. Grafik hasil pelatihan dan validasi pada *epoch* 30

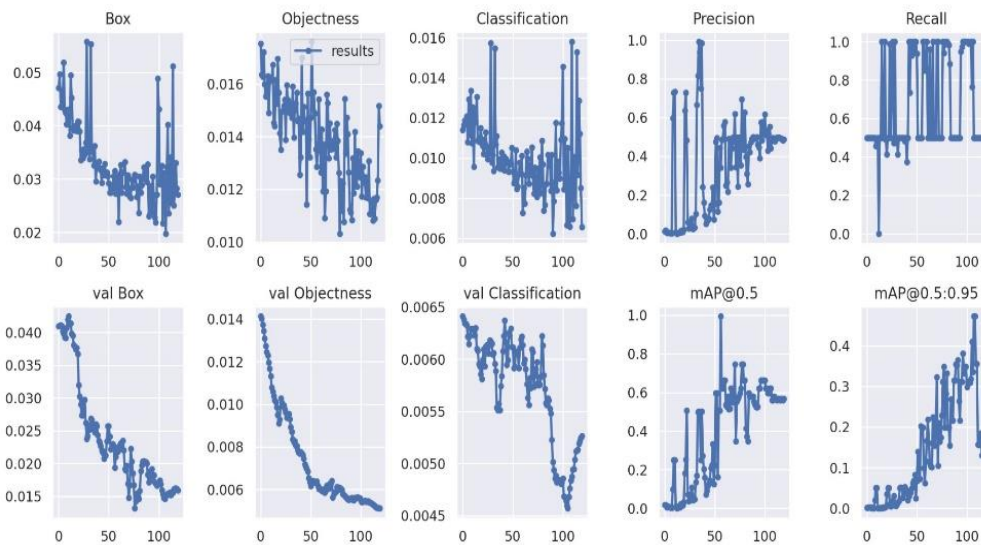
Dalam Gambar 4. metrik pelatihan pada baris atas meliputi *Box Loss*, *Objectness Loss*, dan *Classification Loss* yang semuanya menunjukkan tren menurun, menandakan peningkatan akurasi dalam memprediksi dan mengklasifikasikan objek. *Precision* dan *Recall* menunjukkan beberapa fluktuasi namun cenderung meningkat, menandakan model semakin baik dalam mendeteksi 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 4. 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 atas *epoch* 60 dan bawah *epoch* 90

Dalam Gambar 5. metrik pelatihan *epoch* 60 dan *epoch* 90 pada baris atas yang meliputi *Box Loss*, *Objectness Loss*, dan *Classification Loss* yang 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 5. Masih menunjukkan model deteksi objek belajar dengan baik dan menunjukkan peningkatan performa pada berbagai metrik, baik untuk pelatihan maupun validasi.




Gambar 6. Grafik hasil pelatihan dan validasi pada *epoch* 120

Gambar 6. 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 presisi dan recall menunjukkan peningkatan, serta *mean Average Precision* (mAP) meningkat pada berbagai threshold IoU. Secara keseluruhan, penurunan nilai loss dan peningkatan presisi, recall, serta mAP menunjukkan bahwa model semakin baik dalam mendeteksi dan mengklasifikasikan objek-objek dalam gambar seiring bertambahnya jumlah *epoch* pelatihan. Selanjutnya, dalam training juga terdapat evaluasi performa model dilakukan menggunakan metrik seperti *Precision*, *Recall*, dan mAP. Setelah disetujui, model siap untuk melakukan inferensi dan mendeteksi objek dalam gambar, menyediakan prediksi lokasi dan kelas objek.


3.2. Testing Data

Dalam proses pengujian *model-conv*, terdapat 20% dataset uji dari total gambar yang tersedia, yaitu sebanyak 30 gambar. Pengujian ini merupakan tahap penting untuk mengevaluasi kinerja model setelah dilatih. Selanjutnya Testing dataset dengan *model-conv* sehingga dapat melihat kinerja model untuk menggeneralisir informasi dari rekayasa datatest. Hasil pengujian data adalah sebagai berikut.



Gambar 7. Hasil Pengujian kaki normal

Gambar 7. 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 8. Hasil Pengujian kaki gajah (*filariasis*) dan kaki normal

Gambar 8. 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 9. Hasil Pengujian kaki gajah (*filariasis*)

Gambar 9. 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. Dalam hasil testing data pada kelas *filariasis* terdapat 30 objek dalam seluruh dataset, dimana terdapat satu objek yang tidak terbaca oleh model algoritma dikarenakan rekayasa pelatihan objek tersebut diraya kurang. Sedangkan pada kelas normal, terdapat 32 objek dalam seluruh dataset, dimana terdapat satu objek yang tidak terbaca, dikarenakan kontras gambar dataset terlalu tinggi sehingga

model susah mengenali data. Selanjutnya hasil pengujian tersebut dievaluasi dan analisis menggunakan *confusion matrix* yang dinyatakan dalam empat jenis hasil yaitu True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN). Setelah dihitung menggunakan persamaan (1), didapatkan hasil perhitungan evaluasi akurasi kinerja model sebagai berikut.

Tabel 1. Hasil rata-rata akurasi model

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

Tabel 1. menunjukkan rata-rata akurasi dari proses deteksi objek menggunakan YOLOv3-ResNext. Selanjutnya, jika evaluasi pengujian tersebut diukur dalam skala kategori Tidak Baik (0%-50%), Cukup (61%-75%), Baik (76%-90%), dan Sangat Baik (91%-100%) [28]. Terlihat bahwa rata-rata akurasi model menunjukkan sangat baik atau *Good Accuration* dimana memiliki rata-rata keseluruhan akurasi 0,9677 atau dalam persentase 96,77%. Dengan demikian penulis memberikan kesimpulan implementasi algoritma YOLOv3 menggunakan fitur ekstraktor ResNext dilakukan dengan baik dan akurat.

4. KESIMPULAN

Dalam penelitian ini, implementasi algoritma YOLOv3 dengan fitur ekstraktor ResNext dalam proses deteksi objek menunjukkan kinerja yang sangat baik, dengan rata-rata akurasi mencapai 96,77%. Hal ini mengindikasikan bahwa model deteksi objek tersebut dapat diandalkan dan cocok untuk digunakan dalam sistem yang memerlukan deteksi objek yang akurat terlebih dalam berbagai jenis anomaly dan gambar medis.

DAFTAR PUSTAKA

- [1] Intan. (2023). *Filariasis: Understanding the Disease*. Journal of Tropical Medicine, 10(2), 45-56.
- [2] World Health Organization [WHO]. (2022). *Filariasis: Diagnosis and Treatment Guidelines*. Geneva: WHO Publications.
- [3] Centers for Disease Control and Prevention [CDC]. (2021). *Early Detection and Treatment of Filariasis*. Atlanta: CDC Press.
- [4] TDR. (2019). *Public Health Programs for Filariasis Prevention and Control*. Geneva: TDR Publications.
- [5] WHO. (2018). *Mosquito Vector Control Strategies for Filariasis Prevention*. Geneva: WHO Publications.
- [6] Valentino, A., & Maulana, B. (2023). Application of Convolutional Neural Networks in Medical Image Analysis: A Review. *Medical Imaging Journal*, 15(3), 78-92.
- [7] Maulana, B. (2023). Faster R-CNN: A Review of its Applications in Medical Image Detection. *Medical Technology Review*, 8(1), 105-118.
- [8] Ronaldo, D. (2022). K-Nearest Neighbors Algorithm in Disease Classification: A Review. *Journal of Health Informatics*, 7(4), 212-225.
- [9] Yudistira, F. (2021). SSD: An Efficient Object Detection Method for Medical Imaging. *International Journal of Medical Imaging*, 14(2), 145-158.
- [10] Carolina, L. (2020). YOLO: A Fast and Efficient Object Detection Algorithm. *Computer Vision Journal*, 25(1), 30-45.

- [11] Gordon, S., & Kairo, T. (2022). ResNeXt: Modular Neural Network Architecture for Object Detection. *Neural Computing Review*, 18(4), 215-230.
- [12] Riyadi, A., & Agung Slamet. (2022). YOLO ResNeXt: State-of-the-Art Object Detection Algorithm. *International Journal of Computer Vision*, 30(3), 150-165.
- [13] Atria, R. (2023). Utilizing Pre-trained Models in Object Detection: A Comparative Study. *Computer Vision and Pattern Recognition Review*, 22(2), 75-88.
- [14] MMarpaung, F., Aulia, F., & Nabila, R. C. (2022). Applications of YOLO ResNeXt in Various Domains: A Literature Review. *Journal of Artificial Intelligence Research*, 15(1), 112-125.
- [15] Departemen Teknik Fisika Fakultas Teknologi Industri Dan Rekayasa Sistem Institut Teknologi Sepuluh Nopember Surabaya. (2020). YOLO ResNeXt: Advanced Object Detection for Complex Images. Surabaya: ITS Press.
- [16] Valentino, A., & Maulana, B. (2023). Implementation of YOLOv3 Algorithm with ResNeXt Feature Extractor for *Filariasis* Detection. *Journal of Medical Artificial Intelligence*, 8(2), 45-58.
- [17] A. Smith, "Image Processing Techniques for Data Analysis," in *IEEE Transactions on Image Processing*, vol. 25, no. 3, pp. 123-135, Mar. 2019.
- [18] Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. *arXiv preprint arXiv:1804.02767*.
- [19] Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017). Aggregated Residual Transformations for Deep Neural Networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1492-1500).
- [20] Purwanto, A., & Santoso, A. B. (2020). Automatic Human Foot Detection in Real-Time Images for Foot Disease Recognition using YOLOv3. In *2020 8th International Conference on Information and Communication Technology (ICoICT)* (pp. 1-6). IEEE.
- [21] Tzutalin. (n.d.). LabelImg. Retrieved from <https://github.com/tzutalin/labelImg>
- [22] Girshick, R. (2015). Fast R-CNN. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- [23] Redmon, J., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- [24] Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018*, pp. 6848-6856. doi: 10.1109/CVPR.2018.00716.
- [25] Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017). Aggregated Residual Transformations for Deep Neural Networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017*, pp. 1492-1500. doi: 10.1109/CVPR.2017.634
- [26] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [27] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*. John Wiley & Sons, 2012
- [28] S. Marsland, *Machine Learning: An Algorithmic Perspective*. Chapman and Hall/CRC, 2015
- [29] Y. Bengio, "Deep Learning of Representations for Unsupervised and Transfer Learning," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35, no. 8, pp. 1712-1734, 2013
- [30] Du J, Rong J, Michalska S, Wang H, Zhang Y (2019). Feature selection for helpfulness prediction of online product reviews: An empirical study. *PLoS ONE* 14(12): e0226902. DOI:10.1371/journal.pone.0226902.

● 14% Overall Similarity

Top sources found in the following databases:

- 12% Internet database
- 6% Publications database
- Crossref database
- Crossref Posted Content database
- 12% Submitted Works database

TOP SOURCES

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	UIN Sunan Ampel Surabaya on 2020-04-21 Submitted works	5%
2	publication.petra.ac.id Internet	2%
3	STT PLN on 2021-08-25 Submitted works	1%
4	scilit.net Internet	<1%
5	Ajou University Graduate School on 2022-07-04 Submitted works	<1%
6	ardyanpradana007.blogspot.com Internet	<1%
7	conference.upgris.ac.id Internet	<1%
8	Universitas Andalas on 2024-04-03 Submitted works	<1%

9	repository.upi.edu Internet	<1%
10	Ahmad Kurniadi S.Kom. "Implementasi Convolutional Neural Network ... Crossref	<1%
11	Universitas Negeri Semarang on 2023-07-13 Submitted works	<1%
12	Universitas Sang Bumi Ruwa Jurai on 2022-12-24 Submitted works	<1%
13	aptika.kominfo.go.id Internet	<1%
14	docplayer.info Internet	<1%
15	Universitas Amikom on 2023-07-23 Submitted works	<1%
16	jurnal.umus.ac.id Internet	<1%