

Deteksi Cerdas Penyakit Tanaman Kopi Robusta Berbasis Deep Learning Menggunakan Variasi YOLO

Harmiansyah^{1*}, Ella Trilia Oviana¹, Mhd Kadar Fitrawan¹, Pramana Putra¹,
Danar Diptaningsari² dan Meidaliantisyah²

¹Program Studi Teknik Biosistem, Fakultas Teknologi Industri, Institut Teknologi Sumatera
Jl. Terusan Ryacudu, Lampung Selatan, 35365

²Badan Riset dan Inovasi Nasional
Jl. Raya Jakarta-Bogor, KM 46, Cibinong, Bogor, 16915

*Alamat korespondensi: harmiansyah@tbs.itera.ac.id

INFO ARTIKEL	ABSTRACT/ABSTRAK
Diterima: 05-06-2025 Direvisi: 19-12-2025 Dipublikasi: 31-12-2025	Smart detection of robusta coffee plant diseases based on deep learning using YOLO variations
Keywords: Coffee rust, Intelligent detection, Spots, YOLO	Coffee plants have gained popularity due to the unique aroma and flavor of coffee beverages. Amid this popularity, challenges arise in controlling diseases such as leaf spot and leaf rust, which significantly reduce coffee production. Therefore, a high-accuracy intelligent detection system is required to identify types of diseases on coffee plants as an early intervention measure. The objective of this research is to implement various pre-trained YOLO (You Only Look Once) models for detecting diseases in robusta coffee plants based on leaf images. This study utilizes three pre-trained YOLO variants, namely YOLOv5, YOLOv7, and YOLOv8, with hyperparameter settings of 150 epochs, batch size of 16, and learning rate of 0.001, while employing SGD (Stochastic Gradient Descent) as the optimizer. The dataset consists of coffee leaf images captured manually using a smartphone camera with 20 MP resolution, collected from the Tegineneng Natar Experimental Garden, Agricultural Modernization Implementation Center (BRMP), Lampung. The dataset was augmented with techniques including shear, blur, and rotation. Based on the performance results of the YOLO-based object detection models, the best-performing model was YOLOv8, achieving mAP@50 of 99.5% and mAP@50:95 of 94.6%, with a training time of 1.748 hours. Testing using YOLOv8 yielded evaluation metrics of 100% accuracy, 100% precision, 100% recall, and 100% F1-score for the healthy leaf and leaf rust classes. Meanwhile, the leaf spot class obtained 94% accuracy, 100% precision, 94% recall, and 97% F1-score.
Kata Kunci: Bercak, Deteksi pintar, Karat kopi, YOLO	Tanaman kopi menjadi populer karena produk minuman kopi yang memiliki aroma dan rasa unik. Ditengah populernya tanaman kopi terdapat permasalahan dalam pengendalian penyakit seperti bercak daun dan karat daun yang berdampak pada produksi tanaman kopi menurun. Sehingga dibutuhkan sistem deteksi cerdas berakurasi tinggi untuk mengidentifikasi jenis penyakit pada tanaman kopi sebagai langkah penanganan dini. Tujuan pada penelitian ini adalah implementasi menggunakan variasi model pralatih YOLO (You Only Look Once) untuk mendeteksi penyakit tanaman kopi robusta berdasarkan citra daun. Penelitian ini menggunakan 3 jenis model pralatih dari YOLO yaitu YOLOv5, YOLOv7 dan YOLOv8 dengan parameter hyperparameter yaitu 150 epoch, batch size 16 dan learning rate 0,001 sedangkan untuk optimizer yang digunakan adalah SGD (Stochastic Gradient Descent). Dataset penelitian adalah

citra daun tanaman kopi yang didapatkan dari pengambilan manual menggunakan tools handphone dengan spesifikasi kamera 20 MP berlokasi di Kebun Percobaan Tegineneng Natar, Balai Penerapan Modernisasi Pertanian (BRMP) Lampung. Dataset diberi augmentasi berupa shear, blur dan rotation. Berdasarkan hasil kinerja model deteksi objek berbasis YOLO, model terbaik yang didapatkan adalah YOLOv8 dengan nilai mAP@50 sebesar 99,5% dan mAP@50-95 adalah 94,6% dalam waktu training selama 1,748 jam. Testing yang dilakukan menggunakan YOLOv8 menghasilkan nilai evaluasi metrik yaitu nilai akurasi 100%, presisi 100%, recall 100% dan F1 score 100% untuk kelas daun sehat dan daun karat. Sedangkan kelas daun bercak mendapatkan nilai akurasi 94%, presisi 100%, recall 94% dan F1 score 97%.

PENDAHULUAN

Minuman kopi pada era saat ini menjadi salah satu minuman populer, karena memiliki aroma dan rasa yang unik (Araaf *et al.*, 2024). Tanaman kopi ditanam pada daerah tropis serta merupakan salah satu sektor pertanian yang memiliki peran penting dalam perekonomian di beberapa (Fragoso *et al.*, 2025), khususnya di Indonesia. Kopi robusta (*Coffea canephora*) sebagai salah satu jenis kopi dengan produksi terbesar di dunia menghadapi beberapa tantangan, salah satu yang paling signifikan adalah penyakit dan hama yang menyerang tanaman, sehingga mengganggu kualitas dan kuantitas produksi (Fragoso *et al.*, 2025; Naik *et al.*, 2021). Deteksi dini penyakit pada tanaman kopi menjadi solusi untuk mencegah penyebaran serta meminimalkan kerugian yang diakibatkan kuantitas pemanenan kopi yang tidak maksimal (Paulos & Woldeyohannis, 2022). Namun, metode deteksi konvensional yang bergantung pada observasi manual oleh petani masih memiliki keterbatasan dalam hal kecepatan, akurasi, dan skalabilitas, hal ini disebabkan keterbatasan pengetahuan dan informasi yang dimiliki petani terkait serangan hama dan penyakit pada tanaman kopi (Gunawan *et al.*, 2020; Hidayat dkk., 2023).

Sejalan dengan perkembangan teknologi komputer vision, pendekatan otomatis berbasis citra semakin menunjukkan potensinya dalam bidang pertanian cerdas (*smart agriculture*) (Yao & Huang, 2024). Mengingat hal ini, muncul alternatif yang lebih cepat dan akurat, seperti penerapan teknik deep learning, yang terbukti sangat efektif dalam analisis gambar, menyediakan cara otomatis dan berkinerja tinggi untuk mendeteksi penyakit dan hama secara real time (Yao & Huang, 2024). Salah satu algoritma yang populer dalam tugas deteksi objek adalah You Only Look Once (YOLO), yang menawarkan

kecepatan tinggi dan akurasi yang baik dalam mendeteksi objek secara real-time (Gope *et al.*, 2024). Algoritma ini telah mengalami beberapa evolusi dari YOLOv3 hingga versi terbaru seperti YOLOv5, YOLOv7, dan YOLOv8, masing-masing dengan peningkatan arsitektur, mekanisme pelatihan, dan kemampuan multitugas (Gope *et al.*, 2024). Ye *et al.* melaporkan penggunaan model seri YOLO memiliki keunggulan signifikan di bidang deteksi objek, terutama dalam pemantauan tanaman, deteksi hama, klasifikasi tanaman, penilaian kematangan buah, dan tugas lainnya (Ye *et al.*, 2025).

Inovasi-inovasi ini memungkinkan YOLO berhasil diterapkan di berbagai bidang, termasuk pertanian presisi, di mana deteksi otomatis penyakit dan hama dapat memberikan respons yang lebih cepat dan efektif terhadap ancaman yang membahayakan produksi pertanian (Abid *et al.*, 2024; Cheng *et al.*, 2024). Kombinasi presisi tinggi dan kecepatan deteksi menjadikan YOLO alat yang ideal untuk membantu petani mengidentifikasi serangan penyakit atau hama pada tanaman sejak dini, meningkatkan pengelolaan tanaman, dan mengurangi penggunaan pestisida dan input lainnya secara berlebihan.


Beberapa penelitian menggunakan model YOLO pada pertanian telah menunjukkan keefektifan dalam mendeteksi penyakit dan hama pada berbagai tanaman seperti Harmiansyah dkk. mengimplementasikan YOLO untuk mendeteksi hama dan penyakit pada tanaman mangga (Harmiansyah *et al.*, 2024a). Penelitian lainnya melaporkan bahwa YOLO digunakan untuk mendeteksi kematangan pada tandan buah segar (TBS) kelapa sawit (Harmiansyah dkk., 2024b).

Penelitian ini bertujuan untuk mengembangkan sistem deteksi cerdas berbasis deep learning untuk mengidentifikasi berbagai penyakit pada tanaman kopi robusta menggunakan variasi

model YOLO. Dengan membandingkan performa antara beberapa versi YOLO, penelitian ini diharapkan dapat memberikan solusi praktis dan efektif dalam mendukung upaya pengendalian penyakit tanaman secara dini dan tepat sasaran, sekaligus mendukung transformasi pertanian tradisional menuju sistem pertanian cerdas berbasis teknologi.

BAHAN DAN METODE

Pengambilan data citra daun pada penelitian ini dilakukan di Kebun Percobaan Tegineneng Natar, Balai Penerapan Modernisasi Pertanian (BRMP) Lampung. Alat yang digunakan pada penelitian ini yaitu handphone *smartphone* dengan spesifikasi kamera 20 MP yang digunakan untuk mengambil citra gambar daun, laptop, google collaboratory, dan roboflow. Objek pada penelitian ini yaitu daun kopi varietas robusta. Penelitian ini memiliki beberapa tahapan penelitian yang disajikan pada Gambar 1.




Gambar 1. Tahapan penelitian

Pengumpulan Dataset Citra Daun Kopi

Dataset didapatkan dengan pengambilan citra gambar daun di kebun percobaan milik BRMP Lampung yang berlokasi di Tegineneng, Natar. Dataset dikelompokkan menjadi 3 klasifikasi berdasarkan jenis penyakit yang menyerang daun kopi dan daun sehat. Klasifikasi daun tanaman kopi dilakukan dengan melakukan pengamatan lapangan berdasarkan tanda-tanda serangan penyakit pada tanaman kopi serta melakukan konfirmasi kepada ahli penyakit tanaman kopi. Klasifikasi dataset pada penelitian ini meliputi bercak daun, karat daun dan daun sehat dengan masing-masing jumlah dataset

berjumlah 1000 sehingga total keseluruhan dataset yang dikumpulkan berjumlah 3000 dataset. Penyakit karat daun memiliki gejala yang dapat diamati pada permukaan atas dan bawah daun, ditandai dengan bercak-bercak bubuk berwarna kuning jingga, daun yang terinfeksi akan muncul bercak kuning, lalu berubah menjadi coklat (Harmiansyah dkk., 2023a; Sugiarti, 2019; Siska dkk., 2018) sedangkan penyakit bercak daun memiliki gejala bercak berwarna kuning yang memiliki lingkaran, gejala tersebut tidak beraturan dan muncul secara acak (Sugiarti, 2019). Ketiga klasifikasi dataset dapat dilihat pada Gambar 2.

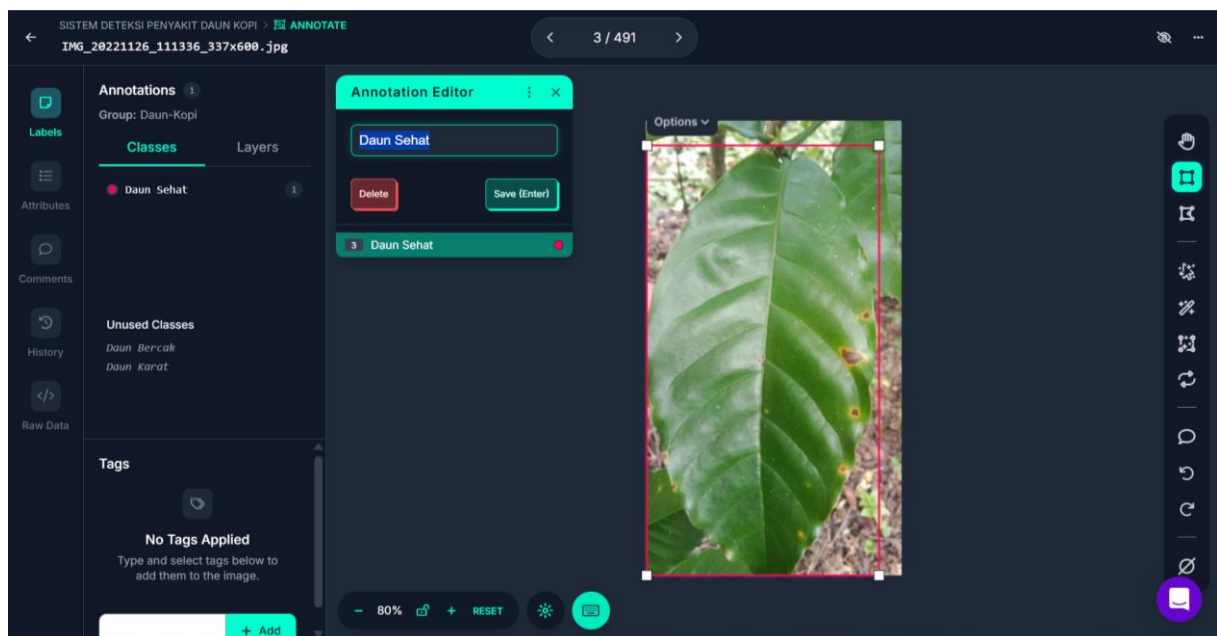


Gambar 2. Contoh kelas penyakit daun kopi: a) daun sehat, b) bercak daun, dan c) karat daun

Anotasi/Labeling Dataset

Anotasi/labeling merupakan proses pemberian tanda atau identifikasi pada dataset berbentuk persegi atau persegi panjang yang digunakan untuk menandai lokasi dan ukuran suatu objek di dalam citra. Proses

anotasi menggunakan platform roboflow, anotasi memberikan tanda berbentuk *bounding box* berbasis koordinat ground-truth pada objek dataset daun kopi robusta (Gambar 3) (Harmiansyah *et al.*, 2023b).



Gambar 3. Proses anotasi/pemberian label pada dataset (pada daun bercak) menggunakan roboflow

Anotasi gambar digunakan untuk pelabelan posisi dan kelas pada objek dalam gambar penyakit dan gambar sehat (Aziz & Ernawan, 2023). Penelitian ini menggunakan 3 kelas yang akan diberikan label/annotasi untuk semua 3000 data gambar daun kopi. Hal ini untuk memenuhi kebutuhan model untuk mempelajari kelas (daun sehat, daun bercak, daun karat). Gambar yang digunakan adalah *single*

object agar dapat menghindari kotak pembatas yang dapat saling beririsan antar label/annotasi (Mots'oeqli, 2024).

Pengolahan Data

Penelitian ini menggunakan 3 model pra-latih YOLO dengan 3 versi yaitu YOLOV5, YOLOV7, dan YOLOV8 sebagai instrumen perlakuan. Penelitian ini

menggunakan beberapa perlakuan lainnya seperti augmentasi, preprocessing, optimizer dan hyperparameter. Instrumen penelitian secara detail dapat dilihat pada Tabel 1.

Proses pengolahan data pada penelitian ini merujuk Gambar 3, yaitu training, validasi dan testing. Dataset dibagi menjadi 3 yaitu 90% dataset

untuk training, 5% dataset untuk validasi dan 5% data untuk testing. Pembagian ini merujuk pada penelitian sebelumnya (Meilita & Yustanti, 2024) yang melaporkan bahwa diperlukan 90% dataset untuk training memperoleh nilai F1 score tertinggi yaitu 0,747.

Tabel 1. Instrumen percobaan penelitian

No	Model Pra-Latih	Augmentasi	Preprocessing	Optimizer	Hyperparameter
1	YOLOV5	Shear	Auto Orient	SGD	150 <i>epoch</i>
2	YOLOV7	Blur	Resize 640 x 640		Batch Size 16
3	YOLOV8	Rotation			Learning Rate 0.001

Metrik Evaluasi

Metrik memperkirakan kinerja model pembelajaran mesin dengan membandingkan hasil dengan tujuan yang diinginkan. Berdasarkan (Ye *et al.*, 2025), metrik yang umum digunakan dalam tugas deteksi objek seperti presisi, presisi rata-rata rata-rata, recall, dan F1-Score digunakan untuk mengevaluasi model YOLO.

Presisi

Mengukur seberapa akurat model dalam memprediksi kelas positif. Presisi tinggi berarti sedikit prediksi positif yang salah, presisi dihitung menggunakan persamaan berikut ini (Ye *et al.*, 2025):

$$precision = \frac{TP}{TP + FP}$$

Dimana TP (true positif) merujuk kejadian yang diidentifikasi dengan benar sebagai positif, sementara FP (false positive) mewakili kejadian yang diidentifikasi secara salah sebagai positif.

Recall

Recall mengukur kemampuan model untuk mengidentifikasi semua contoh positif suatu kelas dengan benar, dikenal juga sebagai sensitivitas atau tingkat deteksi. Dengan kata lain, recall menunjukkan proporsi contoh positif yang benar-benar telah diidentifikasi dengan benar oleh model dalam kaitannya dengan jumlah total contoh positif yang ada dalam data. Recall dihitung menggunakan persamaan berikut (Upadhyay *et al.*, 2025):

$$Recall = \frac{TP}{TP + FN}$$

Dimana FN (false negative) instansi yang salah diidentifikasi sebagai negatif

Average Precision (AP)

Average precision (AP) dapat dihitung menggunakan persamaan:

$$AP = \int_0^1 P(R)$$

Dimana P(R) merepresentasikan presisi sebagai fungsi *recall*.

Mean Average Precision (mAP)

Mean Average Precision (mAP) merupakan metrik evaluasi yang merepresentasikan rata-rata nilai presisi dari seluruh kelas pada berbagai ambang batas Intersection over Union (IoU). Dalam penelitian ini digunakan dua indikator, yaitu mAP@0.5 dan mAP@0,5–0,95. Nilai mAP@0.5 mengklasifikasikan suatu prediksi sebagai benar apabila tingkat tumpang tindih antara bounding box hasil prediksi dan ground truth mencapai minimal 50%. Sementara itu, mAP@0,5–0,95 dihitung sebagai nilai rata-rata mAP pada rentang ambang IoU mulai dari 0,5 hingga 0,95 dengan interval tertentu. Secara matematis, nilai mAP diperoleh dari rata-rata Average Precision (AP) pada setiap kelas, di mana AP diturunkan dari kurva Precision–Recall (Salsabila dkk., 2025).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

Dimana N merepresentasikan jumlah kelas dan AP_i adalah presisi rata-rata kelas i

Intersection over Union (IoU)

Intersection over Union (IoU) mengukur tumpang tindih antara kotak yang diprediksi oleh model dan kotak aktual. Dihitung sebagai rasio antara luas perpotongan $|A \cap B|$ dari dua kotak dan luas gabungan $|A \cup B|$ di antara keduanya. Nilai IoU berkisar dari 0 hingga 1, di mana 1 menunjukkan

kecocokan sempurna antara prediksi dan kebenaran dasar (Fragoso *et al.*, 2025). IoU dihitung menggunakan persamaan di bawah ini:

$$IoU = \frac{|A \cap B|}{|A \cup B|}$$

F1-Score

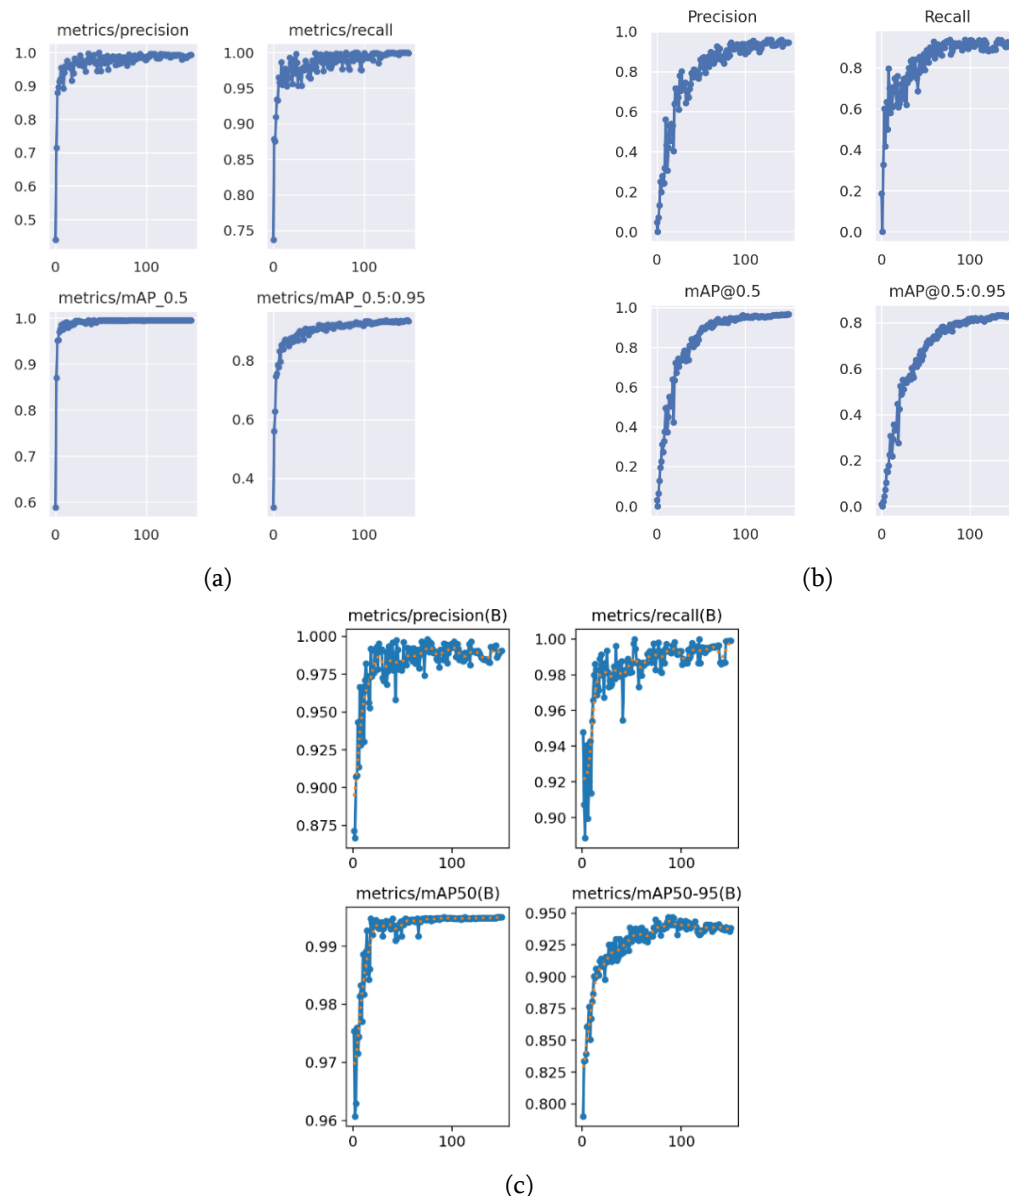
F1 score merupakan indikator yang dievaluasi untuk mengintegrasikan antara presisi dan recall, yang dapat menyelaraskan presisi dan recall dari model. Semakin tinggi F1 score menggambarkan model semakin tangguh (Chen *et al.*, 2021). Nilai F1-score dihitung menggunakan persamaan berikut (Albuquerque & Guedes, 2024):

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

HASIL DAN PEMBAHASAN

Training Configuration

Dataset training menggunakan 3 model YOLO dengan pengaturan parameter yang sama untuk setiap model YOLO yang digunakan, pengaturan parameter dari proses training yaitu untuk optimizer SGD sedangkan untuk *hyperparameter* yang digunakan meliputi batch size 16, learning rate 0.001 serta 150 *epoch* dengan jumlah dataset berjumlah 3000 *image*. Hasil evaluasi performa model deteksi objek menunjukkan peningkatan signifikan pada metrik-metrik utama selama proses pelatihan.



Gambar 4. YOLO training configuration, a) YOLOv5, b) YOLOv7, c) YOLOv8

Hasil dari training configuration dapat dilihat pada Gambar 4 yang merepresentasikan kinerja model saat proses training. Untuk YOLOv5 dan YOLOv8 memiliki presisi yang meningkat dratis diawal *epoch* (repetisi) mendekati nilai 1 kemudian

stabil. Hal ini merepresentasikan bahwa model telah mempelajari cara menghasilkan prediksi yang sangat akurat tanpa banyak false positive. Setelah *epoch* tertentu, presisi tidak lagi meningkat secara signifikan.

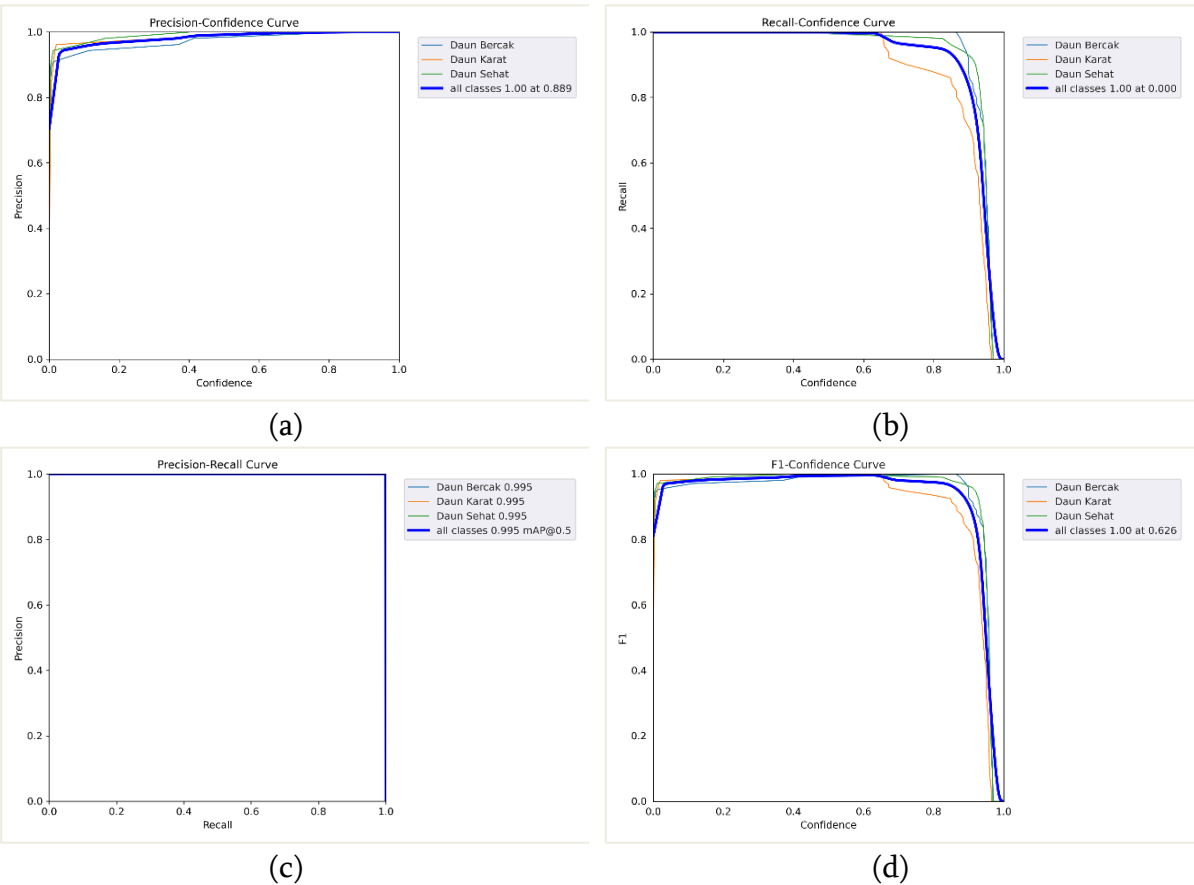
Tabel 2. Nilai evaluasi metrik model YOLO

No	Model	Epoch	Waktu Training (Jam)	Presisi	Recall	mAP@50	mAP @50-95
1	YOLOv5	150	1,748	0,995	0,997	0,995	0,937
2	YOLOv7	150	7,499	0,946	0,913	0,966	0,837
3	YOLOv8	150	2,200	0,985	0,996	0,995	0,946

Evaluasi metrik untuk ketiga model YOLO dapat dilihat pada Tabel 2. YOLOv8 secara umum memiliki performa terbaik dibandingkan YOLOv5 dan YOLOv7 dikarenakan YOLOv8 menggunakan strategi pelatihan dan augmentasi data yang lebih baik, seperti *Task-Aligned Assigner* untuk alokasi label dan *Dynamic Label Assignment* yang membantu meningkatkan presisi dan recall. Model YOLO memiliki performa yang baik pada 150 *epoch* (repetisi)(Gope *et al.*, 2024).

Validasi Model

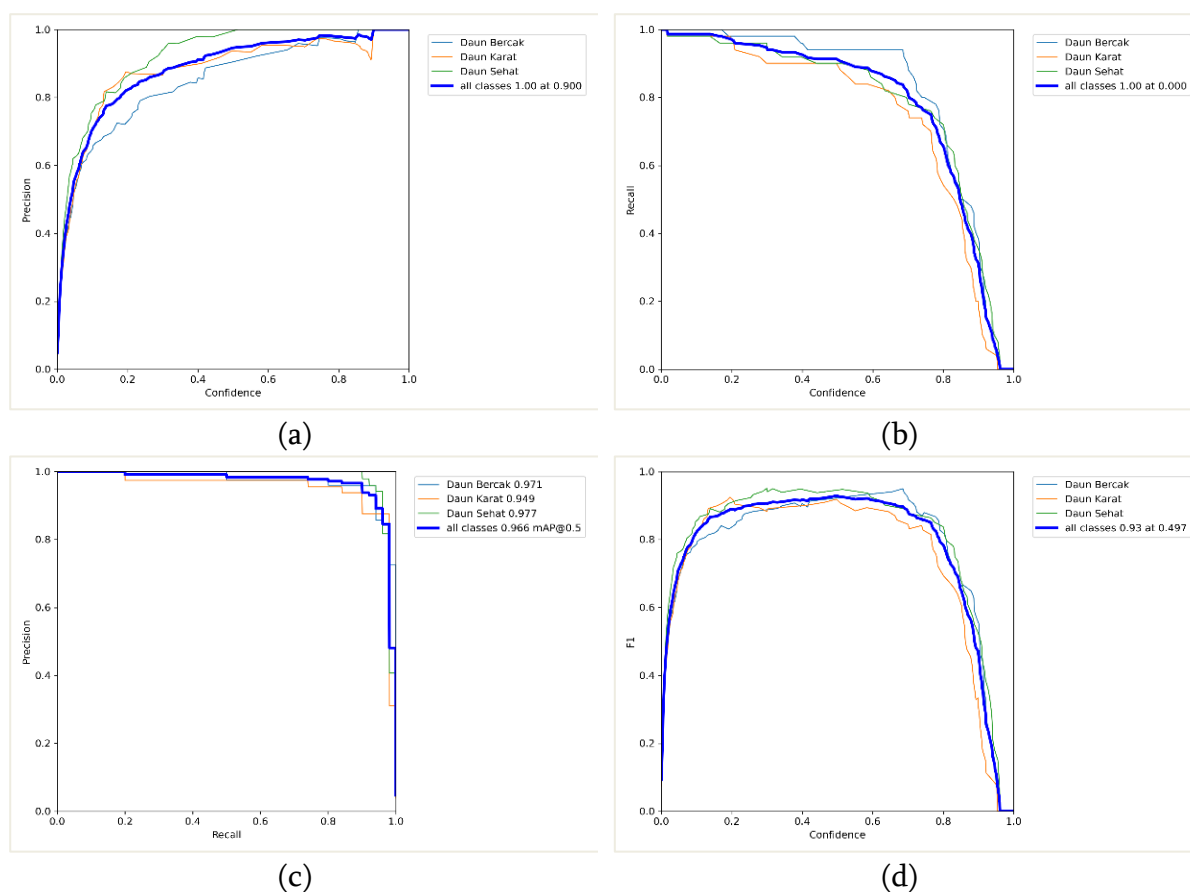
Paraemeter dalam evaluasi model pada penelitian ini yaitu presisi *confidence*, recall *confidence*, F1 *confidence* dan presisi recall. Evaluasi matrik dilakukan berdasarkan jenis model YOLO untuk menganalisis kemampuan model dalam memprediksi 3 kelas objek.



Gambar 5 Performa evaluasi model YOLOv5: a) grafik presisi-*confidence*, b) grafik recall-*confidence*, c) grafik presisi-recall, dan d) grafik F1-*confidence*.

Berdasarkan Gambar 5a, nilai *confidence* model YOLOv5 adalah 0,889 untuk mencapai presisi 1,00 untuk semua kelas. Hal ini merepresentasikan bahwa YOLOv5 memiliki performa yang sangat baik. Threshold rendah menghasilkan lebih banyak false positives (presisi rendah), sedangkan threshold tinggi meningkatkan presisi tetapi dapat mengurangi recall. Untuk nilai recall *confidence* dapat lihat pada Gambar 5b, nilai *confidence* yaitu 0,00 untuk mencapai recall 1,00 untuk semua kelas. Pada Gambar 5c, grafik presisi recall yang digunakan untuk mengevaluasi kinerja model klasifikasi, terutama dalam konteks keseimbangan antara *presisi*

(ketepatan) dan *recall* (daya tangkap). Nilai yang didapatkan adalah 0.995 pada nilai mAP@0,5. Hal ini menunjukkan bahwa model memiliki akurasi yang sangat tinggi dalam mendeteksi objek dengan IoU threshold 0,5. sedangkan untuk nilai F1 *confidence* dapat dilihat pada Gambar 5d yaitu sebesar 0,626 untuk mencapai nilai F1 1,00. Nilai-nilai ini menggambarkan model memiliki kinerja yang baik saat proses training (mempelajari dataset). Hasil ini menggambarkan YOLOv5 mampu membedakan antara kelas daun kopi sehat dan berpenyakit dengan baik.



Gambar 6 Performa evaluasi model YOLOv7: a) grafik presisi-*confidence*, b) grafik recall-*confidence*, c) grafik presisi-recall, dan d) grafik F1-*confidence*.

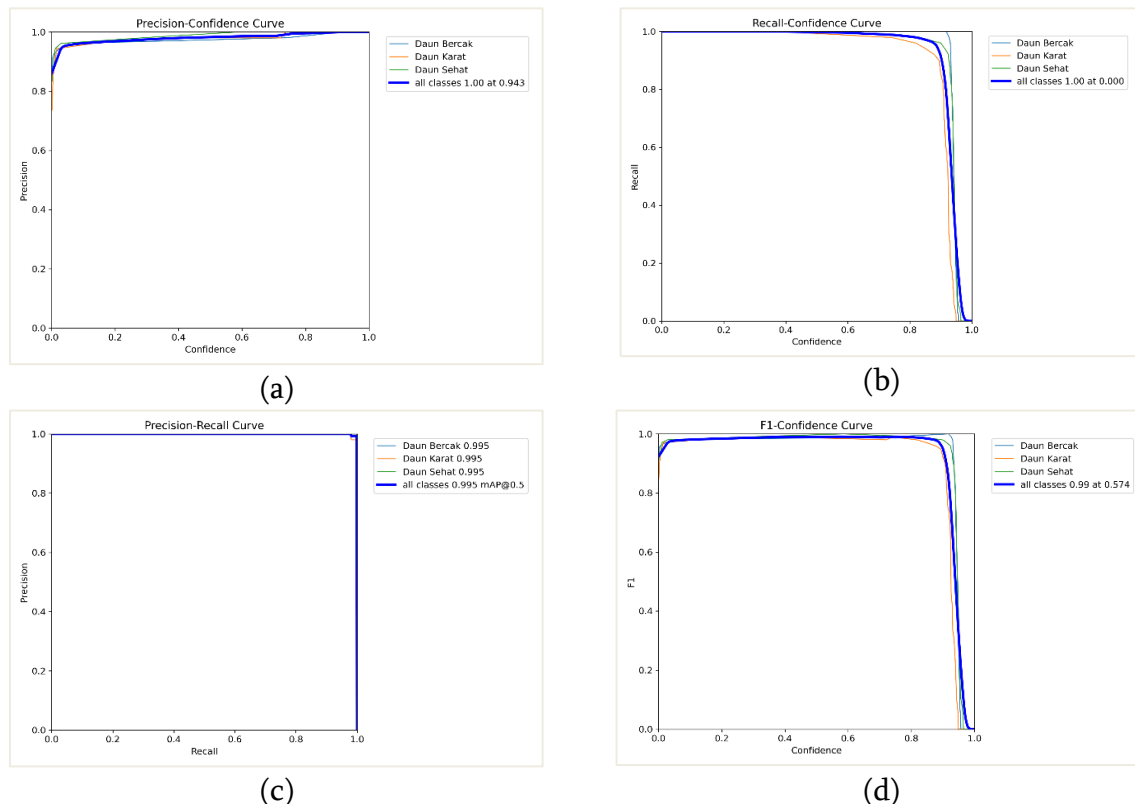
Gambar 6a merepresentasikan nilai *confidence* YOLOv7 dengan nilai 0,900 untuk presisi 1,00 untuk semua kelas. Grafik recall *confidence* dapat dilihat pada Gambar 6b dengan nilai *confidence* 0,00 untuk mencapai nilai recall 1,00 pada semua kelas. Grafik presisi-recall pada Gambar 6c menunjukkan untuk semua kelas, nilai mAP@0,5 (mean Average Presisi at IoU=0,5) yaitu 0,965. Hal ini menunjukkan bahwa model secara keseluruhan

memiliki akurasi deteksi yang tinggi pada level IoU 0,5.

Gambar 6d adalah representasi dari grafik *confidence*-F1 Score yang digunakan untuk menilai kinerja model klasifikasi dalam menentukan tingkat kepercayaan yang dibutuhkan untuk prediksi positif. Digunakan untuk menganalisis hubungan antara tingkat kepercayaan dan nilai F1 Score untuk setiap kelas dalam tugas klasifikasi. Di dalam grafik ini, sumbu X mewakili tingkat kepercayaan, sedangkan

sumbu Y mewakili nilai F1 Score, yang merupakan rata-rata harmonis dari presisi dan recall. Garis-garis yang berwarna masing-masing mewakili performa model pada kelas "Daun Bercak", "Daun Karat", dan "Daun Sehat" masing-masing, dan garis biru tebal menunjukkan rata-rata kinerja model pada semua

kelas, dengan nilai maksimum F1 Score 0,93 yang dicapai pada tingkat kepercayaan 0,497. nilai metrik ini menggambarkan kemampuan model mampu mengenali objek (daun sehat, daun karat dan daun bercak).



Gambar 7 Performa evaluasi model YOLOv8: a) grafik presisi-*confidence*, b) grafik recall-*confidence*, c) grafik presisi-recall, dan d) grafik F1-*confidence*.

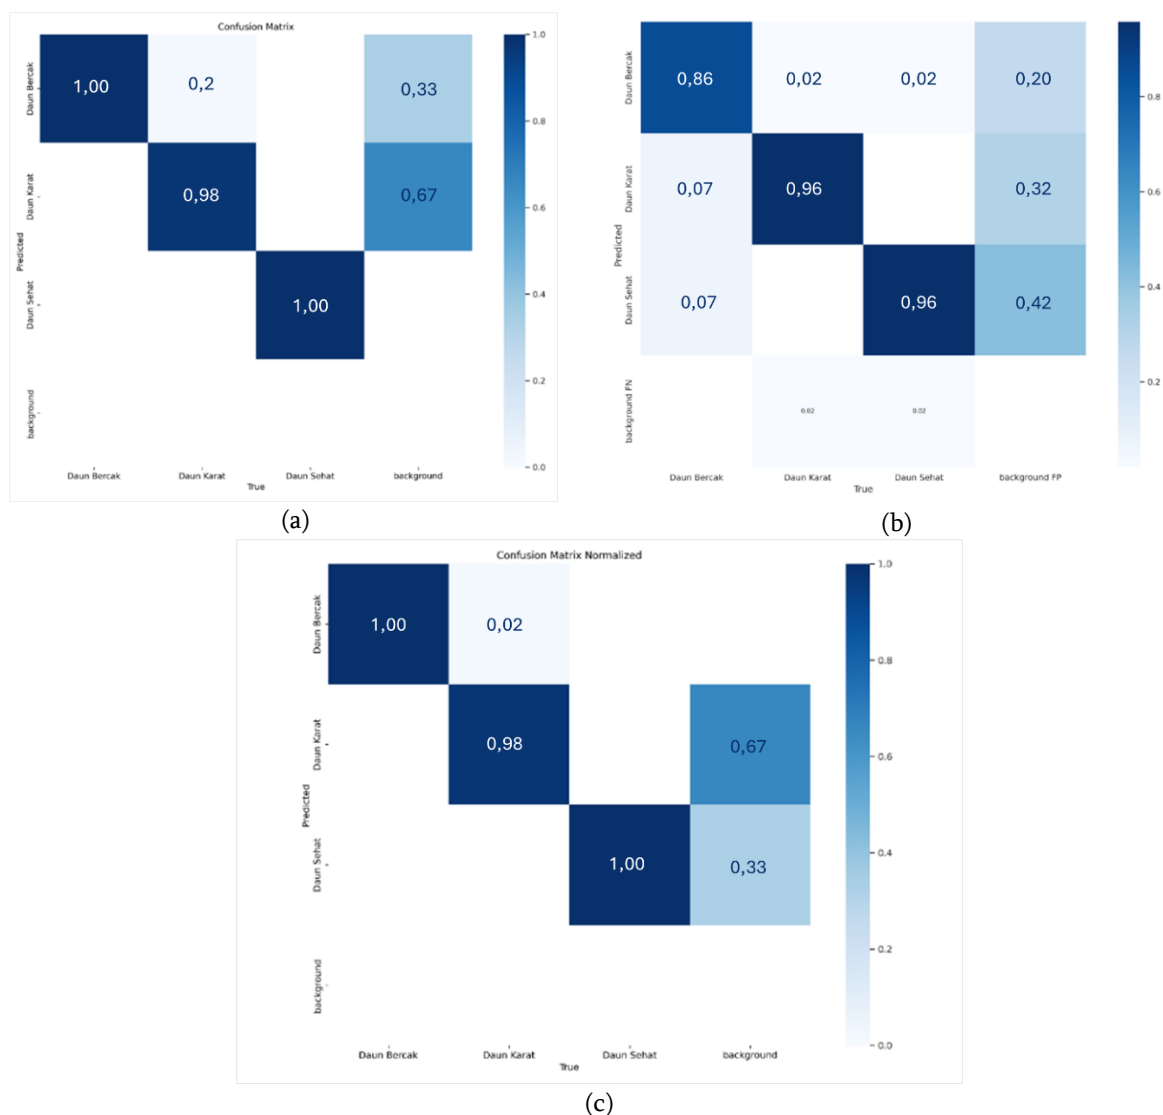
Grafik presisi *confidence* pada Gambar 7a menunjukkan kinerja model YOLOv8 melalui perbandingan antara tingkat kepercayaan prediksi dan tingkat presisi. Garis-garis yang berwarna masing-masing mewakili performa model pada kelas "Daun Bercak", "Daun Karat", dan "Daun Sehat" masing-masing, dan garis biru tebal menunjukkan performa model pada seluruh kelas dengan presisi 1,00 yang dicapai pada tingkat kepercayaan 0,943. Gambar 7b merupakan grafik recall *confidence* model YOLOv8 dengan nilai *confidence* 0,00 untuk mencapai nilai recall 1,00. Gambar 7c menunjukkan performa model dalam mendeteksi objek dari setiap kelas dengan berbagai threshold *confidence*. Untuk semua kelas, nilai mAP@0,5 (mean Average Presisi at IoU=0,5) yaitu 0,995, menunjukkan model secara keseluruhan memiliki akurasi deteksi yang tinggi pada level IoU 0,5. Nilai F1 Score 0,99 yang dicapai pada tingkat kepercayaan 0,574, Hal ini

menunjukkan bahwa model ini memiliki kinerja yang sangat baik pada berbagai tingkat kepercayaan, dengan nilai F1 Score yang sangat dekat dengan 1,00, yang menunjukkan akurasi prediksi yang sangat tinggi dan seimbang antara presisi dan recall. Berdasarkan metrik evaluasi hasil penelitian ini lebih baik dibandingkan penelitian sebelumnya (Meilita & Yustanti, 2024), perlakuan augmentasi, hyperparameter, Preprocessing dan optimizer yang telah dilakukan mampu meningkatkan kinerja dari model YOLOv8.

Confusion matrik memberikan informasi mengenai distribusi gambar yang seimbang untuk ketiga kelas pada training. Setiap kelas memiliki 1000 dataset gambar, jumlah dataset yang ideal untuk melatih model deep learning karena model tidak akan bias terhadap kelas tertentu. Confusion matrik menyediakan ringkasan prediksi yang dibuat oleh model dibandingkan dengan label data yang

sebenarnya (Ghafar *et al.*, 2024). Confusion matriks digunakan untuk menilai kinerja model klasifikasi dalam mengenali tiga kelas daun, yaitu "Daun Bercak", "Daun Karat", dan "Daun Sehat". Matriks ini menunjukkan seberapa banyak contoh dari setiap kelas yang diprediksi dengan benar (diagonal) dan seberapa banyak yang diprediksi salah (luar diagonal). Diagonal matriks menunjukkan tingkat akurasi prediksi yang tepat, sedangkan nilai-nilai yang tidak berada di diagonal menunjukkan tingkat kesalahan prediksi. Berdasarkan Gambar 8a, YOLOv5 untuk kelas daun bercak dan daun sehat

mendapatkan nilai 1 sedangkan kelas daun karat mendapat nilai 0,98 pada proses validasi atau dibandingkan hasil prediksi dengan data aktual. Nilai confusion matrik YOLOv7 dapat dilihat pada Gambar 8b yaitu kelas daun karat dan daun sehat sebesar 0,96, sedangkan kelas daun bercak sebesar 0,86. Model YOLOv8 mendapatkan nilai 1 untuk kelas daun bercak dan daun sehat sedangkan untuk kelas daun karat mendapatkan nilai 0,98. secara keseluruhan model YOLO mendapatkan nilai confusion matrik yang baik yang merepresentasikan hasil kinerja model yang baik saat dilakukan validasi.



Gambar 8. Confusion matrik model YOLO: a) YOLOv5, b) YOLOv7, dan c) YOLOv8.

Testing

Pengujian dilakukan menggunakan model terbaik berdasarkan performa F1 score, nilai F1 score merepresentasikan keseimbangan antara precision dan recall. Pada penelitian ini didapatkan model

terbaik adalah YOLOv8. Testing dilakukan menggunakan nilai *confidence* score 0,574 yang didapatkan dari grafik F1-*confidence* score pada gambar, hal ini untuk mendapatkan hasil yang seimbang antara presisi dan recall.

Tabel 3. Perbandingan hasil testing model YOLOv8 dengan aktual

		Prediksi		
		Daun sehat	Daun karat	Daun bercak
Aktual	Daun sehat	50	-	-
	Daun karat	-	50	-
	Daun bercak	-	3	47

Testing menggunakan 50 dataset gambar daun untuk setiap kelas sehingga total dataset yang digunakan sebanyak 150 gambar daun kopi. Hasil prediksi dari model YOLOv8 dapat dilihat pada Tabel 3. Hal ini menunjukkan bahwa performa model sangat baik untuk memprediksi kelas daun sehat dan daun karat dengan nilai prediksi tepat untuk 50 data setiap kelas, namun untuk kelas daun bercak model YOLOv8 mengalami kesalahan prediksi pada 3 dataset. Untuk keseluruhan model YOLOv8 memiliki performa yang baik untuk melakukan prediksi penyakit pada tanaman kopi varietas robusta.

Tabel 4. Nilai Evaluasi matrik testing model YOLOv8

Kelas	Akurasi	Presisi	Recall	F1-Score
Daun sehat	100%	100%	100%	100%
Daun karat	100%	100%	100%	100%
Daun bercak	94%	100%	94%	97%

Nilai evaluasi matrik dapat dilihat pada Tabel 4. Berdasarkan hasil pengujian model YOLOv8 pada deteksi penyakit daun tanaman kopi, diperoleh performa yang sangat baik untuk ketiga kelas. Model mampu mencapai akurasi 100% pada kelas daun sehat dan daun karat , dengan nilai presisi, recall, dan F1-Score yang juga sempurna (100%). Hasil ini menunjukkan bahwa model tidak melakukan kesalahan dalam mendeteksi objek pada kedua kelas tersebut. Sementara itu, pada kelas daun bercak , model memperoleh akurasi sebesar 94%, dengan presisi 100%, recall 94%, dan F1-Score 97%, mengindikasikan bahwa semua prediksi positif untuk

kelas ini adalah benar (tanpa false positive). Namun, terdapat sedikit false negative yang menyebabkan recall tidak mencapai nilai maksimal, sehingga model sedikit kurang sensitif dalam mendeteksi semua instance daun bercak yang ada. Secara keseluruhan, hasil ini menunjukkan bahwa model YOLOv8 memiliki kemampuan deteksi yang sangat tinggi, terutama dalam membedakan kondisi daun kopi yang sehat dan terserang penyakit karat, serta cukup andal untuk mendeteksi daun dengan bercak penyakit. Untuk hasil testing yang dibandingkan dengan data validasi dapat dilihat pada Gambar 9.



Gambar 9. Hasil deteksi pada testing dataset menggunakan YOLOv8, a) Klasifikasi aktual dari dataset, dan b) Klasifikasi prediksi YOLOv8.

Secara umum YOLOv8 memiliki kinerja yang baik berdasarkan nilai evaluasi metrik dan hasil uji testing yang menunjukkan nilai F1 score mencapai 100% untuk prediksi daun sehat, 100% untuk daun karat, dan 97% untuk daun bercak. Nilai ini menggambarkan bahwa YOLOv8 dapat digunakan sebagai model pra latih untuk mengidentifikasi serangan hama dan penyakit berdasarkan citra daun kopi robusta.

SIMPULAN

Berdasarkan hasil analisis perbandingan kinerja model deteksi objek berbasis YOLO untuk identifikasi penyakit daun tanaman kopi, YOLOv8 menunjukkan performa terbaik dengan nilai mAP@50 sebesar 99,5% dan mAP@50-95 sebesar 94,6%, untuk kelas daun sehat dan karat nilai akurasi mencapai 100%. Model ini memberikan keseimbangan optimal antara presisi dan recall untuk seluruh kelas, sehingga YOLOv8 paling efektif untuk mendeteksi kondisi daun secara akurat. Meskipun YOLOv5 memiliki mAP@50 yang setara dan waktu pelatihan yang lebih singkat (1,748 jam dibandingkan 2,200 jam pada YOLOv8), nilai mAP@50-95 YOLOv5 lebih rendah, sedikit inferioritas dalam aspek presisi dan recall dibandingkan YOLOv8. Di sisi lain, YOLOv7 menunjukkan performa yang relatif lebih rendah baik dari segi metrik evaluasi maupun efisiensi waktu pelatihan, sehingga kurang direkomendasikan untuk tugas deteksi spesifik ini. Dengan demikian, YOLOv8 menjadi model pilihan utama untuk aplikasi deteksi dini penyakit daun kopi, terutama ketika keakuratan prediksi menjadi prioritas utama.

UCAPAN TERIMA KASIH

Ucapan terima kasih kepada Lembaga Penelitian dan Pengabdian Kepada Masyarakat (LPPM) Institut Teknologi Sumatera yang telah mendanai penelitian ini dengan kontrak penelitian Nomor B/763ac/IT9.C1/PT.01.03/2022.

DAFTAR PUSTAKA

Abid, MSZ, B Jahan, A Al Mamun, M Jakir Hossen, and S Hossain Mazumder. 2024. Bangladeshi crops leaf disease detection using YOLOv8. *Heliyon*. 10: e36694. <https://doi.org/10.1016/j.heliyon.2024.e36694>
Albuquerque, LD, and EB Guedes. 2024. Coffee plant

leaf disease detection for digital agriculture. *Journal on Interactive Systems*. 15(1): 220–233. DOI: 10.5753/jis.2024.3804
Araaf, RT, A Minn, and T Ahamed. 2024. Coffee leaf rust disease detection and implementation of an edge device for pruning infected leaves via deep learning algorithms. *Sensors*. 24(24): 8018. <https://doi.org/10.3390/s24248018>
Aziz, F, and F Ernawan. 2023. Object detection for diagnosis rice leaf diseases using YOLO method. *Communication in Science and Technology*. 0(0): 0000.
Chen, JW, WJ Lin, HJ Cheng, CL Hung, CY Lin, and SP Chen. 2021. A smartphone-based application for scale pest detection using multiple-object detection methods. *Electronics*. 10(4): 372. DOI: 10.3390/electronics10040372
Cheng, D, Z Zhao, and J Feng. 2024. Rice diseases identification method based on improved YOLOv7-Tiny. *Agriculture*. 14(5): 709. <https://doi.org/10.3390/agriculture14050709>
Fragoso, J, C Silva, T Paixão, AB Alvarez, OC Júnior, R Florez, F Palomino-Quispe, LG Savian, and PA Trazzi. 2025. Coffee-leaf diseases and pests detection based on YOLO models. *Applied Sciences*. 15(9): 5040. <https://doi.org/10.3390/app15095040>
Ghafar, A, C Chen, S Atif Ali Shah, Z Ur Rehman, and G Rahman. 2024. Visualizing plant disease distribution and evaluating model performance for deep learning classification with YOLOv8. *Pathogens*. 13(12): 1032. <https://doi.org/10.3390/pathogens13121032>
Gope, HL, H Fukai, FM Ruhad, and S Barman. 2024. Comparative analysis of YOLO models for green coffee bean detection and defect classification. *Scientific Reports*. 14: 28946. <https://doi.org/10.1038/s41598-024-78598-7>
Gunawan, MD, A Franz, dan RR Manullang. 2020. Sistem pakar penyakit tanaman kopi (*Coffea* sp.) metode forward chaining berbasis web. *Buletin Poltanesa*. 21: 26–31. DOI: <https://doi.org/10.51967/tanesa.v21i1.321>
Harmiansyah, D Diptaningsari, N Wardani, Meidaliyantisyah, R Mawardi, and J Hendra. 2023a. Intensity of leaf rust disease on four robusta coffee clones in Natar, South Lampung. *IOP Conference Series: Earth and Environmental Science*. 1230(1): 012097. DOI: 10.1088/1755-1315/1230/1/012097
Harmiansyah, H, R Fil'aini, Z Mufidah, NWA Utari,

- J Hendra, D Diptaningsari, M Meidaliantisya, N Wardani, R Mawardi, dan MA Mustafid. 2023b. Sistem smart detection penyakit pada tanaman kopi robusta menggunakan SSD MobileNet V2 sebagai model pra-terlatih. Jurnal Agrikultura. 34(1): 154-162. DOI: <https://doi.org/10.24198/agrikultura.v34i1.43052>
- Harmiansyah, EP Sembiring, ET Oviana, and Supriyanto. 2024a. Detection of new oil palm fruit bunches based on deep learning. IOP Conference Series: Earth and Environmental Science. 1379: 012003. DOI 10.1088/1755-1315/1379/1/012003
- Harmiansyah, H, ET Oviana, R Alpaizon, DP Khalifah, dan P Dwirota. 2024b. Sistem deteksi hama dan penyakit tanaman mangga (*Mangifera indica* L.) berbasis deep learning menggunakan model pra latih YOLOv5. Jurnal Agrikultura. 35(1): 151-163. DOI: <https://doi.org/10.24198/agrikultura.v35i1.53834>
- Hidayat, DSP, S Khomsah, NA Prasetya, dan SD Wulandari. 2023. Sistem pakar diagnosis penyakit tanaman kopi robusta dengan metode similarity. Conference on Electrical Engineering, Informatics, Industrial Technology, and Creative Media 2023. 3: 1-1010
- Meilita, B, dan W Yustanti. 2024. Sistem deteksi penyakit kulit kucing menggunakan algoritma You Only Look Once (YOLO) v8. 05: 178-188. DOI: <https://doi.org/10.26740/jeisbi.v5i2.60656>
- Mots'oe hli, M. 2024. Assistive image annotation systems with deep learning and natural language capabilities: A review. arXiv. 2407:0052. DOI: 10.48550/arXiv.2407.00252
- Naik, BJ, SC Kim, R Seenayah, PA Basha, and EY Song. 2021. Coffee cultivation techniques, impact of climate change on coffee production, role of nanoparticles and molecular markers in coffee crop improvement, and challenges. Journal of Plant Biotechnology. 48(4): 207-222. <https://doi.org/10.5010/JPB.2021.48.4.207>
- Paulos, EB, and MM Woldeyohannis. 2022. Detection and classification of coffee leaf disease using deep learning. 2022 International Conference on Information and Communication Technology for Development for Africa. ICT4DA 2022: 1-6
- Salsabila, S, M Hidayat, dan M Polin. 2025. Deteksi dini hama dan penyakit tanaman padi dengan metode YOLO. Difussion Journal of System and Information Technology. 5: 173-182. DOI: <https://doi.org/10.37031/diffusion.v5i2.31644>
- Siska, RKW, L Lubis, & L Lisnawati, 2018. Serangan karat daun kopi (*Hemileia vastatrix* B et Br) pada tanaman kopi arabika di Perkebunan Rakyat Kabupaten Mandailing Natal Sumatera Utara. Talenta Conference Series: Agricultural and Natural Resources (ANR). 1: 82-86.
- Sugiarti, L. 2019. Identifikasi hama dan penyakit pada tanaman kopi di kebun percobaan Fakultas Pertanian Universitas Winaya Mukti. Jurnal Agro Wiralodra. 2: 16-22. DOI: <https://doi.org/10.31943/agrowiralodra.v2i1.27>
- Upadhyay, A, NS Chandel, KP Singh, SK Chakraborty, BM Nandede, M Kumar, A Subeesh, K Upendar, A Salem, and A Elbeltagi. 2025. Deep learning and computer vision in plant disease detection: A comprehensive review of techniques, models, and trends in precision agriculture. Artificial Intelligence Review. 58: 92. <https://doi.org/10.1007/s10462-024-11100-x>
- Yao, Z, and M Huang. 2024. Deep learning in tropical leaf disease detection: advantages and applications. Tropical Plants. 3: e020. doi: 10.48130/tp-0024-0018
- Ye, B, R Xue, and H Xu. 2025. ASD-YOLO: a lightweight network for coffee fruit ripening detection in complex scenarios. Frontiers in Plant Science. 16: 1484784. doi: 10.3389/fpls.2025.1484784