
Pendeteksi Penyakit dan Hama pada Kelapa Sawit Menggunakan Metode Yolo untuk Memantau Pertumbuhan Tanaman

Irvan Widyadinata^{*1}, Agustinus Rudatyo Himamunanto², Yo'el Piter Sumihar³

^{1,2}Program Studi Informatika, Fakultas Sains dan Komputer, Universitas Kristen Immanuel

³Program Studi Fisika, Fakultas Sains dan Komputer, Universitas Kristen Immanuel

Email: *irvan.widyadinata@mail.ukrim.ac.id, rudatyo@ukrimuniversity.ac.id,

pieter.haro@ukrimuniversity.ac.id

(Naskah masuk: 23 Juni 2025, diterima untuk diterbitkan: 20 Januari 2026)

Abstrak: Penyakit dan hama pada tanaman kelapa sawit merupakan tantangan utama dalam menjaga produktivitas dan keberlanjutan industri perkebunan. Deteksi dini yang tidak efisien dapat menyebabkan penurunan hasil panen secara signifikan. Penelitian ini mengembangkan sistem deteksi otomatis penyakit dan hama pada kelapa sawit menggunakan algoritma deep learning YOLOv11s. Sistem dirancang untuk meningkatkan efisiensi pemantauan dan mengurangi kerugian akibat gangguan organisme pengganggu tanaman. Dataset terdiri dari 2.544 citra yang dianotasi ke dalam tujuh kelas utama, mencakup berbagai kondisi tanaman. Pelatihan dilakukan pada platform komputasi awan dengan dukungan GPU, dan model dievaluasi menggunakan metrik precision, recall, F1-score, dan mean Average Precision (mAP@0.5). Hasil pelatihan menunjukkan performa yang baik dengan precision sebesar 71,2%, recall 77,2%, F1-score 74,1%, dan mAP@0.5 sebesar 76,8%. Sistem ini menunjukkan potensi untuk diterapkan dalam pemantauan real-time kondisi kelapa sawit secara efisien dan akurat.

Kata Kunci – Yolo; Pendeteksian; Kelapa sawit; Deep learning; Citra digital

Disease and Pest Detector in Oil Palm Using Yolo Method to Monitor Plant Growth

Abstract: Diseases and pests in oil palm plantations remain key challenges in maintaining agricultural productivity and sustainability. Ineffective early detection can lead to significant yield losses. This study proposes an automated detection system for oil palm diseases and pests using the YOLOv11s deep learning algorithm. The system aims to improve plantation monitoring efficiency and minimize damage caused by harmful organisms. A total of 2,544 annotated images across seven major plant condition classes were used for training. The model was trained on a cloud-based GPU platform and evaluated using precision, recall, F1-score, and mean Average Precision (mAP@0.5). Results demonstrate robust model performance with a precision of 71.2%, recall of 77.2%, F1-score of 74.1%, and mAP@0.5 of 76.8%. The proposed system shows promise for real-time, efficient, and accurate monitoring of oil palm plantations.

Keywords – YOLO; Detection; Oil Palm; Deep Learning; Digital Image

1. PENDAHULUAN

Industri perkebunan kelapa sawit merupakan pilar penting perekonomian Indonesia, berkontribusi signifikan terhadap pendapatan negara dan kesejahteraan masyarakat, terutama di wilayah Kalimantan Barat, khususnya Kabupaten Bengkayang. Namun, ancaman serius berupa serangan hama dan penyakit terus mengintai, berpotensi menurunkan produktivitas dan mengancam keberlanjutan industri ini. Deteksi dini hama dan penyakit menjadi kunci utama dalam menjaga kualitas dan kuantitas hasil panen, serta meminimalisir kerugian ekonomi yang signifikan. Metode konvensional yang umumnya mengandalkan pengamatan manual oleh tenaga ahli, seringkali kurang efisien, memakan waktu, dan rentan terhadap kesalahan manusia. Keterlambatan deteksi dapat menyebabkan meluasnya serangan hama dan penyakit, sehingga upaya pengendalian menjadi lebih sulit dan biaya yang dikeluarkan semakin besar.[1]

Oleh karena itu, terdapat kebutuhan mendesak akan suatu sistem deteksi dini yang lebih akurat, cepat, dan efisien. Teknologi pengolahan citra digital dan metode pembelajaran mesin (machine learning) menawarkan solusi yang menjanjikan untuk mengatasi keterbatasan metode konvensional. Sistem deteksi otomatis berbasis citra digital mampu menganalisis gambar atau video tanaman kelapa sawit untuk mendeteksi gejala penyakit atau serangan hama secara real-time, memberikan informasi yang akurat dan cepat kepada petani atau pengelola perkebunan. Informasi ini kemudian dapat digunakan untuk mengambil keputusan yang tepat dan cepat dalam melakukan tindakan pengendalian hama dan penyakit, meminimalisir dampak negatif terhadap produktivitas dan keberlanjutan industri [2]

Penelitian ini berfokus pada pengembangan dan evaluasi sebuah sistem deteksi otomatis penyakit dan hama pada tanaman kelapa sawit menggunakan algoritma You Only Look Once versi 11 (YOLOv11), sebuah metode pembelajaran mendalam yang telah terbukti efektif dan efisien dalam mendeteksi objek pada citra. Sistem ini dirancang untuk mengidentifikasi tujuh kelas utama penyakit dan hama yang umum ditemukan pada tanaman kelapa sawit, yang meliputi: batang sawit sehat, bercak daun sawit, buah sawit sehat, busuk pucuk kelapa sawit, daun sawit sehat, serangan tikus, dan serangan jamur Ganoderma. Penelitian ini menggunakan dataset yang telah diberi label dengan presisi tinggi menggunakan platform Roboflow, memastikan akurasi anotasi yang tinggi. Proses pelatihan model akan dilakukan di Google Colaboratory dengan dukungan unit pemrosesan grafis (GPU) untuk mempercepat komputasi.[3]

Hasil penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam meningkatkan efisiensi dan efektivitas deteksi dini penyakit dan hama pada tanaman kelapa sawit, mendukung keberlanjutan dan peningkatan produktivitas industri perkebunan kelapa sawit di Indonesia. Penelitian ini juga akan menganalisis efektivitas penggunaan teknologi citra digital dalam memantau pertumbuhan dan mendeteksi masalah pada tanaman kelapa sawit, memberikan wawasan yang berharga bagi pengembangan pertanian presisi di Indonesia. Penelitian ini akan membahas secara rinci metodologi yang digunakan, hasil pengujian, dan implikasi dari temuan penelitian terhadap praktik pengelolaan perkebunan kelapa sawit.[4].

2. METODE PENELITIAN

Deteksi penyakit dan hama pada tanaman kelapa sawit dapat dilakukan secara efektif dengan metode YOLO, sebuah algoritma deteksi objek real-time berbasis deep learning. YOLO unggul dalam memberikan deteksi yang cepat dan akurat, yang penting dalam aplikasi pertanian [5]. Algoritma ini membagi citra input menjadi grid, di mana setiap grid memprediksi kemungkinan objek, posisi, dan kelasnya. Dalam penelitian ini, YOLO digunakan untuk mendeteksi penyakit dan hama pada daun, batang, dan buah kelapa sawit. Metode ini mengikuti desain eksperimental kuantitatif dengan tahapan akuisisi data, pemrosesan, pelatihan model, evaluasi performa, dan implementasi sistem untuk memastikan akurasi dan efisiensi. [6]

2.1. Subjek dan Sumber Data

2.1.1. Data Citra

Dataset yang digunakan dalam penelitian ini terdiri dari gambar tanaman kelapa sawit yang dikumpulkan dari sumber publik dan koleksi sekunder. Citra yang dikumpulkan mencakup variasi kondisi pencahayaan, resolusi, sudut pengambilan gambar, dan lingkungan sekitar untuk meningkatkan daya generalisasi model.[7] Jenis Citra yang dikumpulkan mencakup objek dengan 7 kelas utama, yaitu:

Tabel 1. Jumlah Data Citra

Kelas	Jumlah Data Citra
Batang Sawit Sehat	346

Bercak Daun Sawit	311
Buah Sawit Sehat	466
Busuk Pucuk Kelapa sawit	436
Daun Sawit Sehat	310
Hama Tikus	326
Jamur Ganoderma	349
Total	2.544

2.1.2. Pelabelan Data


Roboflow digunakan sebagai alat utama untuk pelabelan dan anotasi dataset. Proses ini secara manual atau otomatis menandai area pada setiap gambar di mana penyakit atau hama tertentu terlihat. Penandaan ini dilakukan dengan membuat kotak-kotak (bounding box) di sekitar objek yang ingin dideteksi. [8] Tujuan utama dari labelling ini adalah untuk mengajari model mengenali berbagai kondisi tanaman kelapa sawit yang sudah ditentukan, seperti batang sawit sehat, bercak daun sawit, buah sawit sehat, busuk pucuk kelapa sawit, hama tikus atau jamur ganoderma. sehingga mudah untuk dikenali setiap penyakit, hama dan perkembangan yang ditampilkan.



Gambar 1. Pelabelan

2.2. Pelatihan Model

Model YOLOv11s dilatih menggunakan 2.544 citra kelapa sawit beranotasi tujuh kelas, dengan implementasi berbasis PyTorch di Google Colab menggunakan GPU. Dataset dibagi menjadi 70% data latih, 20% validasi, dan 10% pengujian. Sebelum pelatihan, gambar diproses melalui resize (640×640 piksel), [9] augmentasi (rotasi, flipping, pencahayaan), dan normalisasi piksel [0,1]. Pelatihan dilakukan selama 30 epoch dengan learning rate 0,01, batch size 16, dan optimizer SGD. Anotasi berformat YOLO dibuat menggunakan Roboflow. Evaluasi kinerja model mencakup precision, recall, F1-score, dan mAP@0.5 serta mAP@0.5:0.95. [10] Hasil pelatihan menunjukkan model mampu mendeteksi objek secara real-time dengan performa yang cukup baik, tahap evaluasi performa model menghasilkan skor model lebih akurat dengan skor yang tinggi.



Gambar 2. Graph Pelatihan Model

2.3. Analisis Data

Proses analisis data dilakukan secara terintegrasi menggunakan platform Roboflow untuk manajemen dataset, anotasi gambar, konversi format, augmentasi data, dan pelatihan model awal. Roboflow menyediakan antarmuka visual untuk anotasi manual objek yang menunjukkan gejala penyakit dan hama pada daun, batang, dan buah kelapa sawit. Langkah analisis data dimulai dengan mengunggah citra tanaman kelapa sawit ke Roboflow dalam format JPEG. [11] Setiap gambar dianotasi secara manual dengan bounding box untuk menandai gejala penyakit atau serangan hama. Roboflow kemudian melakukan augmentasi otomatis untuk meningkatkan keberagaman data. Setelah anotasi dan augmentasi, dataset diekspor dalam format YOLOv11 dan dibagi menjadi training set (70%), validation set (20%), dan test set (10%). Dataset yang telah siap digunakan kemudian dilatih menggunakan model YOLOv11 di Google Colab dengan Python, di mana hasil evaluasi seperti mAP, precision, dan recall diperoleh dari modul evaluasi internal YOLO.

2.4. Pengukuran

Pengukuran kinerja model deteksi dilakukan menggunakan empat metrik utama, yaitu precision, recall, F1-score, dan mAP@0.5. Precision mengukur seberapa banyak hasil deteksi yang benar dari seluruh deteksi yang dilakukan, sedangkan recall menunjukkan seberapa banyak objek yang berhasil terdeteksi dari semua yang seharusnya terdeteksi. [13] F1-score merupakan rata-rata harmonis dari precision dan recall untuk menilai keseimbangan keduanya. Sementara itu, mAP@0.5 digunakan untuk mengukur rata-rata akurasi model dengan ambang kesamaan posisi sebesar 50% antara prediksi dan data asli. Selain itu, confusion matrix juga digunakan untuk melihat jumlah prediksi yang benar dan salah pada tiap kelas, sehingga membantu memahami performa model secara keseluruhan. [14]

2.4.1. Rumus

1. Precision (Presisi):

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

Kemampuan model mendeteksi objek dengan benar dari semua yang diprediksi.

2. Recall:

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

Kemampuan model menangkap semua objek yang benar-benar ada.

3. F1-score:

$$F1 = \frac{2 \cdot (Precision \cdot Recall)}{Precision + Recall}$$

Rata-rata harmonis antara precision dan recall, berguna saat diperlukan keseimbangan keduanya.

4. mAP@0.5 (Mean Average Precision):

$$mAP@0.5 = \frac{1}{N} \sum_{k=0}^n AP_i \text{ dengan } IoU \geq 0,5$$

Mengukur rata-rata presisi dari semua kelas pada ambang kesesuaian prediksi terhadap ground truth.

3. HASIL DAN PEMBAHASAN

3.1. Deskripsi Dataset

Dataset yang digunakan terdiri dari 2544 citra kelapa sawit, yang mencakup berbagai bagian tanaman seperti daun, batang, dan buah[15]. Gambar-gambar tersebut telah dianotasi secara manual untuk menandai objek gejala penyakit, hama dan pertumbuhan. Total terdapat 7 kelas utama yang terdeteksi, yaitu:

Tabel 2. Data Citra

Kelas	Jumlah Label Citra
Batang Sawit Sehat	358
Bercak Daun Sawit	16.006
Buah Sawit Sehat	2.903
Busuk Pucuk Kelapa sawit	779
Daun Sawit Sehat	789
Hama Tikus	3.380
Jamur Ganoderma	2.110

Pembagian dataset dilakukak dengan Train set 70% 1780 citra, Valid set 20% 510 citra, Test set 10% 254 citra

3.2. Hasil Labeling Klasifikasi Data

Berdasar kan hasil pendeteksi gambar ini adalah representasi visual dari sistem deteksi objek yang digunakan untuk memantau kesehatan tanaman kelapa sawit, mengidentifikasi keberadaan penyakit kondisi yang kurang sehat serta mengonfirmasi bagian tanaman yang sehat. Kotak-kotak berwarna dengan label dan angka menunjukkan probabilitas deteksi oleh model.



Gambar 3. Hasil Labelling Klasifikasi Dataset

3.3. Hasil Pelatihan Model Yolov11s

Dalam pelatihan selama 30 epoch, model yolov11s menghasilkan performa sebagai berikut:


Tabel 3. Hasil Evaluasi Yolov11s

Kelas	Precision (P)	Recall (R)	Map@0,5	Map@0.5:0.95
Batang Sawit Sehat	0.973	0.919	0.976	0.702
Bercak Daun Sawit	0.515	0.475	0.442	0.300
Buah Sawit Sehat	0.605	0.782	0.743	0.434
Busuk Pusuk Kelapa Sawit	0.656	0.571	0.644	0.255
Daun Sawit Sehat	0.673	0.920	0.829	0.667
Hama Tikus	0.722	0.820	0.829	0.643
Jamur Ganoderma	0.841	0.919	0.910	0.693

3.4. Interpretasi Visual


Interpretasi visual dilakukan untuk mengevaluasi kinerja model YOLOv11s dalam mendeteksi objek pada citra kelapa sawit secara lebih intuitif. Visualisasi hasil evaluasi, seperti confusion matrix dan grafik metrik performa, memberikan gambaran yang jelas mengenai akurasi deteksi, kesalahan klasifikasi, serta stabilitas model pada berbagai ambang kepercayaan.

Confusion matrix berfungsi sebagai alat evaluasi visual yang menunjukkan kinerja model YOLOv11s dalam mendeteksi penyakit dan hama pada kelapa sawit. Matriks ini membandingkan hasil prediksi model dengan kondisi sebenarnya (ground truth) untuk tujuh kelas objek, termasuk background. Nilai diagonal utama menunjukkan jumlah deteksi yang benar (True Positives), sedangkan nilai di luar diagonal menandakan kesalahan klasifikasi (False Positives dan False Negatives). Matriks ini memberikan gambaran kekuatan dan kelemahan model dalam mengenali tiap kelas, serta menjadi dasar penting untuk mengevaluasi dan meningkatkan performa deteksi.



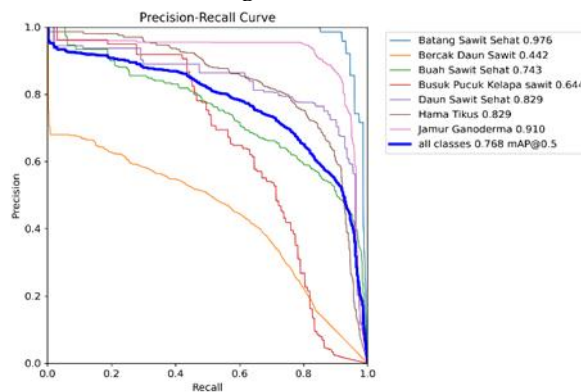
Gambar 4 Confusion Matrix

Normalized Confusion Matrix, yang merupakan versi persentase atau proporsional dari confusion matrix sebelumnya. Berbeda dengan Gambar 3 yang menampilkan jumlah absolut deteksi, matriks ini menunjukkan proporsi prediksi yang benar dan salah relatif terhadap jumlah total sampel di setiap kelas sebenarnya. Angka-angka pada diagonal utama merepresentasikan tingkat recall atau sensitivitas model untuk setiap kelas, menunjukkan persentase objek dari kelas tertentu yang berhasil dideteksi dengan benar. Sementara itu, nilai-nilai di luar diagonal menggambarkan persentase kesalahan klasifikasi, baik itu objek yang salah diprediksi ke kelas lain atau yang terlewatkan. Normalized confusion matrix ini sangat berguna untuk membandingkan kinerja model antar kelas secara adil, terutama ketika terdapat ketidakseimbangan jumlah data antar kelas, karena ia memberikan gambaran yang lebih intuitif tentang seberapa baik model mengidentifikasi setiap kategori secara proporsional.

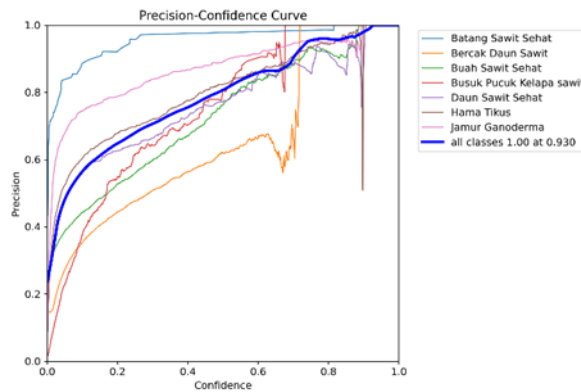


Gambar 5. Normalized Confusion Matrix

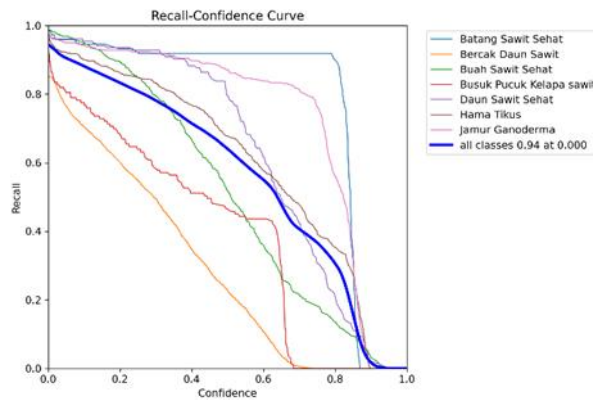
Kinerja model pada Gambar 6 hingga 9 menyajikan grafik evaluasi kinerja model YOLOv11s pada berbagai ambang kepercayaan. Gambar 6 (Precision-Recall Curve) menunjukkan hubungan antara precision dan recall, di mana luas kurva (AP) menjadi indikator performa tiap kelas. Gambar 7 (Precision-Confidence Curve) memperlihatkan peningkatan precision seiring naiknya ambang kepercayaan. Sebaliknya, Gambar 8 (Recall-Confidence Curve) menunjukkan penurunan recall saat ambang meningkat. Gambar 9 (F1-Confidence Curve) menampilkan keseimbangan precision dan recall pada berbagai ambang, membantu menentukan titik optimal performa model. Keempat grafik ini memberikan gambaran mendalam tentang stabilitas dan kualitas deteksi model.




Gambar 6. maP@0.5



Gambar 7. Presion



Gambar 8. Recall



Gambar 9. F1 Skor

3.5. Analisis Hasil Pengukuran

Tabel 4 Hasil pengukuran

Kelas	Precision (P)	Recall (R)	F1-score	Map@0,5
Batang Sawit Sehat	0.973	0.919	0.945	0.976
Bercak Daun Sawit	0.515	0.475	0.494	0.442
Buah Sawit Sehat	0.605	0.782	0.682	0.743
Busuk Pusuk Kelapa Sawit	0.656	0.571	0.611	0.644
Daun Sawit Sehat	0.673	0.920	0.777	0.829
Hama Tikus	0.722	0.820	0.768	0.829
Jamur Ganoderma	0.841	0.919	0.878	0.910
Rata-rata	0.712	0.772	0.741	0.768

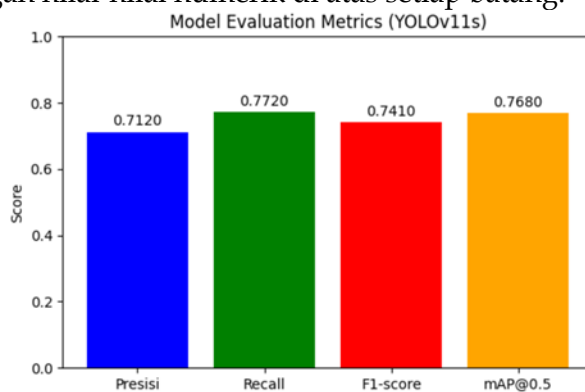
Model YOLOv11s yang diterapkan dalam penelitian ini menunjukkan performa yang baik dalam mendeteksi tujuh kelas objek yang berkaitan dengan kondisi tanaman kelapa sawit. Evaluasi dilakukan dengan menggunakan metrik precision, recall, F1-score, dan mAP@0.5, yang memberikan gambaran komprehensif terhadap akurasi klasifikasi dan kemampuan deteksi spasial dari model. Kelas Batang Sawit Sehat menunjukkan performa terbaik, dengan precision 97,3%, recall 91,9%, F1-score 94,5%, dan mAP@0.5 97,6%, mengindikasikan konsistensi tinggi dalam mengenali fitur batang sawit yang tegas. Kinerja sangat baik juga ditunjukkan oleh kelas Jamur Ganoderma, yang mencatat F1-score 87,8% dan mAP@0.5 76,8%, berkat morfologi jamur yang khas. Di sisi lain, kelas Bercak Daun Sawit memiliki performa terendah, dengan F1-score 49,4% dan mAP@0.5 44,2%, mengindikasikan kesulitan model dalam mengenali variasi gejala bercak daun yang tidak seragam dan kurang kontras.[16] Kelas lainnya menunjukkan performa menengah hingga tinggi. Kelas Buah Sawit Sehat dan Busuk Pucuk Kelapa Sawit masing-masing mencatat F1-score 68,2% dan 61,1%, serta mAP@0.5 sebesar 74,3% dan 64,4%, menandakan bahwa model cukup andal dalam mendeteksi dua objek ini meskipun terdapat variasi bentuk dan warna. Kelas Daun Sawit Sehat dan Hama Tikus

menunjukkan F1-score masing-masing 77,7% dan 76,8%, serta mAP@0.5 sebesar 82,9% pada keduanya. Hasil ini menunjukkan bahwa model mampu membedakan daun sehat dan mendeteksi keberadaan hama dengan cukup baik, berkat pola visual yang khas. Secara umum, model YOLOv11 menunjukkan kemampuan deteksi objek yang menjanjikan, terutama untuk kelas-kelas dengan fitur visual yang jelas, dan dapat dioptimalkan lebih lanjut untuk meningkatkan deteksi pada kelas dengan gejala yang bervariasi.[17]

3.6. Hasil Analisis Keseluruhan

Secara keseluruhan, performa rata-rata model YOLOv11s untuk semua kelas mencapai precision sebesar 71,2%, recall 77,2%, F1-score 74,1%, dan mAP@0.5 sebesar 76,8%. Capaian ini menunjukkan bahwa YOLOv11s memiliki potensi kuat untuk diterapkan dalam sistem pemantauan kondisi tanaman kelapa sawit secara real-time, terutama untuk kelas-kelas dengan karakteristik visual yang jelas. Meski demikian, performa model masih dapat ditingkatkan pada kelas-kelas dengan tingkat kesulitan deteksi yang tinggi, seperti Bercak Daun Sawit dan Busuk Pucuk Kelapa Sawit, yang mengalami penurunan presisi dan konsistensi deteksi akibat variasi visual yang kompleks. Untuk mengatasi keterbatasan tersebut, beberapa pendekatan dapat dipertimbangkan, antara lain penerapan teknik peningkatan data (data augmentation), penyeimbangan distribusi data antar kelas (class balancing), serta eksplorasi arsitektur model yang lebih dalam dan kompleks seperti YOLOv5m atau YOLOv5x. Langkah-langkah ini diharapkan dapat memperbaiki generalisasi model terhadap fitur yang lebih beragam dan kompleks. Secara umum, hasil penelitian ini memberikan kontribusi signifikan dalam pengembangan sistem deteksi otomatis berbasis visi komputer yang efisien dan aplikatif, serta dapat diintegrasikan dalam praktik pertanian presisi untuk meningkatkan produktivitas dan keberlanjutan industri kelapa sawit.[18]

Dengan pengukuran pengujian dengan hasil tersebut menggunakan grafik batang yang menampilkan "Model Evaluation Metrics" (Metrik Evaluasi Model). Grafik ini menunjukkan empat metrik kinerja model dengan nilai-nilai numerik di atas setiap batang.



Gambar 10. Model Evaluation Matrix

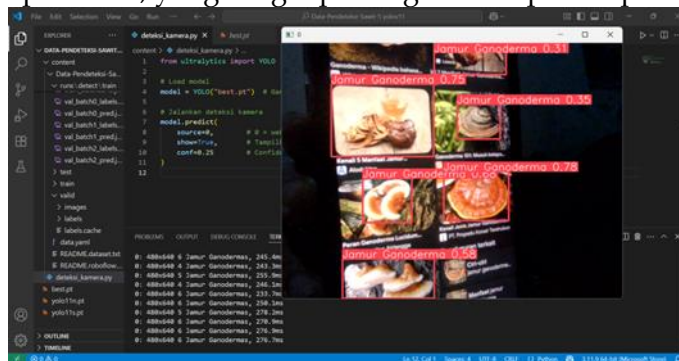
3.7. Hasil Akurasi Model

Perhitungan Akurasi menggunakan mAP@0.5 sebagai representasi akurasi deteksi objek. Karena YOLO tidak menghitung True Negative (TN) secara eksplisit, maka mAP@0.5 digunakan sebagai akurasi dalam deteksi objek. Hasil Akurasi (YOLO) = mAP@0.5 = 0,768 = 76,80%. Nilai mAP@0.5 sebesar 76,80% menunjukkan bahwa model YOLOv11s memiliki kemampuan yang baik dalam mendeteksi dan mengklasifikasikan objek secara tepat pada ambang kemiripan lokasi minimal 50%.

3.8. Hasil Pengukuran Video Live

Pengujian ini menunjukkan kemampuan model YOLOv11s yang telah dilatih untuk mendeteksi objek Jamur Ganoderma, secara real-time dari stream kamera. Model berhasil

mengidentifikasi beberapa instance Jamur Ganoderma dalam citra dan memberikan tingkat kepercayaan untuk setiap deteksi, yang sangat penting untuk aplikasi pemantauan di lapangan.



Gambar 11. Hasil Pengujian Video Live.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa metode YOLOv11s memiliki performa andal dan konsisten dalam mendeteksi penyakit serta hama pada kelapa sawit berbasis citra digital. Model ini mampu melakukan deteksi secara real-time dengan akurasi tinggi, serta efektif mengenali gejala pada daun, batang, dan buah. Tantangan utama terletak pada kelas bercak daun yang menunjukkan performa rendah. Peningkatan performa dapat dicapai melalui augmentasi data, penyeimbangan kelas, dan penggunaan arsitektur YOLOv11s yang lebih kompleks. Hasil ini mendukung penerapan sistem pemantauan otomatis berbasis citra dalam pengembangan pertanian presisi di sektor kelapa sawit.

DAFTAR PUSTAKA

- [1] S. Yang, J. Yao, and G. Teng, "Corn Leaf Spot Disease Recognition Based on Improved YOLOv8," *Agriculture (Switzerland)*, vol. 14, no. 5, May 2024, doi: <https://doi.org/10.3390/agriculture14050666>
- [2] J. Wang, C. Qin, B. Hou, Y. Yuan, Y. Zhang, and W. Feng, "LCGSC-YOLO: a lightweight apple leaf diseases detection method based on LCNet and GSConv module under YOLO framework," *Front Plant Sci*, vol. 15, 2024, doi: <https://doi.org/10.3389/fpls.2024.1398277>.
- [3] Y. Wang, C. Yi, T. Huang, and J. Liu, "Research on Intelligent Recognition for Plant Pests and Diseases Based on Improved YOLOv8 Model," *Applied Sciences (Switzerland)*, vol. 14, no. 12, Jun. 2024, doi: <https://doi.org/10.3390/app14125353>.
- [4] R. Ahmed and E. H. Abd-Elkawy, "Improved Tomato Disease Detection with YOLOv5 and YOLOv8," *Engineering, Technology and Applied Science Research*, vol. 14, no. 3, pp. 13922–13928, Jun. 2024, doi: <https://doi.org/10.48084/etasr.7262>.
- [5] E. Iren, "Comparison of YOLOv5 and YOLOv6 Models for Plant Leaf Disease Detection," *Engineering, Technology and Applied Science Research*, vol. 14, no. 2, pp. 13714–13719, Apr. 2024, doi: <https://doi.org/10.48084/etasr.7033>.
- [6] B. Erwanto, A. I. Pradana, and D. Hartanti, "Pengembangan Sistem Deteksi Penyakit Tanaman Tomat Melalui Citra Daun dengan Metode You Only Look Once (YOLO) Berbasis Android," *G-Tech: Jurnal Teknologi Terapan*, vol. 8, no. 3, pp. 1453–1463, Jul. 2024, doi: <https://doi.org/10.33379/gtech.v8i3.4327>.
- [7] A. Putra Pranjaya, F. Rizki, R. Kurniawan, and N. K. Daulay, "KLIK: Kajian Ilmiah Informatika dan Komputer Klasifikasi Penyakit Pada Daun Tanaman Padi Berbasis YoloV5 (You Only Look Once)," *Media Online*, vol. 4, no. 6, pp. 3127–3136, 2024, doi: <https://doi.org/10.30865/klik.v4i6.1916>.

- [8] D. G. Manurung et al., "Deteksi Dan Klasifikasi Hama Potato Beetle Pada Tanaman Kentang Menggunakan YOLOV8," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 4, pp. 723-734, Aug. 2024, doi: <https://doi.org/10.25126/jtiik.1148092>.
- [9] H. F. Hanum and D. M. Fathurahman, "Perancangan Sistem Pendeteksi Kualitas Tanaman Tomat Berdasarkan Daun Menggunakan Computer Vision dengan YOLO dan OpenCV," 2024, doi: <https://prosiding.pnj.ac.id/sniv/article/view/2217>
- [10] L. Firgia and S. Thomas, "Deteksi Jenis Penyakit Dan Hama Pada Tanaman Jagung Menggunakan Arsitektur Spatial Pyramid Pooling Pada YOLOv5s," *Jurnal Riset Sistem Informasi Dan Teknik Informatika (JURASIK)*, vol. 8, no. 2, pp. 452-459, 2023, doi: <https://tunasbangsa.ac.id/ejurnal/index.php/jurasik>
- [11] M. D. Anggraini, K. Kusri, and H. Al Fatta, "SOCIAL DISTANCING DETECTION FINDING OPTIMAL ANGLE WITH YOLO V3 DEEP LEARNING METHOD," *Jurnal Teknik Informatika (Jutif)*, vol. 3, no. 5, pp. 1449-1455, Oct. 2022, doi: <https://doi.org/10.20884/1.jutif.2022.3.5.390>.
- [12] M. Hatami, T. Tukino, F. Nurapriani, W. Widiyawati, and W. Andriani, "DETEKSI HELMET DAN VEST KESELAMATAN SECARA REALTIME MENGGUNAKAN METODE YOLO BERBASIS WEB FLASK," *EDUSAINTEK: Jurnal Pendidikan, Sains dan Teknologi*, vol. 10, no. 1, pp. 221-233, Jan. 2023, doi: <https://doi.org/10.47668/edusaintek.v10i1.651>.
- [13] Mohammad Chasrun Hasani, Fadhila Milenasari, and N. Setyawan, "Pemantauan Physical Distance Pada Area Umum Menggunakan YOLO Tiny V3," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 146-152, Feb. 2022, doi: <https://doi.org/10.29207/resti.v6i1.3808>.
- [14] L. Setiana Riva, "Deteksi Penyakit Tanaman Cabai Menggunakan Algoritma YOLOv5 Dengan Variasi Pembagian Data," vol. 8, no. 3, 2023, doi: <https://ejournal.poltekharber.ac.id/index.php/informatika/article/view/5679>
- [15] K. A. Baihaqi and C. Zonyfar, "Deteksi Lahan Pertanian Yang Terdampak Hama Tikus Menggunakan Yolo v5," 2022, doi: <https://journal.unsika.ac.id/index.php/syntax/article/view/722>
- [16] M. Deden Miftah Fauzi, T. Al Mudzakir, C. Emilia Sukmawati, and J. Indra, "KLIK: Kajian Ilmiah Informatika dan Komputer Deteksi Jenis Penyakit Pada Tanaman Padi Menggunakan Yolo V5," *Media Online*, vol. 5, no. 1, pp. 39-48, 2024, doi: <https://doi.org/10.30865/klik.v5i1.2009>.
- [17] P. A. Widjaja and J. R. Leonesta, "Differentiate a Health and Sick of Mango Leaves Using YOLOv4," *Formosa Journal of Science and Technology*, vol. 2, no. 7, pp. 1749-1758, Jul. 2023, doi: <https://doi.org/10.55927/fjst.v2i7.4792>.
- [18] M. Anwar, Y. Kristian, and E. Setyati, "CLASSIFICATION OF CHILI PLANT DISEASES EQUIPPED WITH LEAF AND FRUIT IMAGE SEGMENTATION USING YOLO V7," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 6, no. 1, 2023, doi: <https://doi.org/10.30741/jid.v2i2.1335>