

Analisa Performa Algoritma Convolutional Neural Network (CNN) dengan Arsitektur YOLOv8 untuk Deteksi Penyakit Daun Tanaman Hortikultura Tropis

Kens Urganis Awangsari Puttrisia Soenarto*¹, Setio Basuki¹

**Informatika, Universitas Muhammadiyah Malang*

*naufalabiyu@webmail.umm.ac.id**

Abstrak

Penelitian ini bertujuan untuk melakukan analisis komparatif terhadap performa arsitektur Convolutional Neural Network (CNN) konvensional dan model deteksi objek YOLOv8 dalam mendeteksi penyakit daun pada tanaman hortikultura tropis. Studi ini dilatarbelakangi oleh pentingnya deteksi dini penyakit tanaman guna meningkatkan produktivitas dan efisiensi pertanian, khususnya di wilayah tropis seperti Indonesia. Metode penelitian yang digunakan adalah pendekatan kuantitatif dengan eksperimen komparatif, di mana kedua model dilatih dan diuji menggunakan dataset citra daun dari lima jenis tanaman hortikultura, yaitu apel, pisang, durian, mangga, dan jeruk. CNN difungsikan sebagai model baseline yang berfokus pada klasifikasi citra secara keseluruhan, sedangkan YOLOv8 digunakan untuk melakukan deteksi sekaligus pelokalisasi area daun yang terinfeksi. Proses evaluasi performa dilakukan berdasarkan metrik akurasi, precision, recall, mean Average Precision (mAP), serta waktu inferensi. Hasil eksperimen menunjukkan bahwa YOLOv8 memiliki performa yang lebih unggul, dengan capaian nilai mAP pada IoU 0.5 sebesar 0.927, precision sebesar 0.89, recall sebesar 0.87, dan waktu inferensi rata-rata hanya 10.5 milidetik per gambar. Sebaliknya, model CNN menunjukkan akurasi klasifikasi sebesar 0.86 namun tidak mampu memberikan informasi spasial berupa lokasi penyakit. Dengan keunggulan dalam deteksi cepat dan akurat, penelitian ini memberikan kontribusi nyata dalam pengembangan sistem deteksi penyakit tanaman berbasis deep learning yang adaptif dan aplikatif untuk mendukung praktik pertanian presisi di Indonesia.

Kata Kunci: *YOLOv8, Convolutional Neural Network, Deteksi Penyakit Daun, Deep Learning, Pertanian Hortikultura Tropis*

Abstract

This study aims to conduct a comparative analysis of the performance of conventional Convolutional Neural Network (CNN) architecture versus the YOLOv8 object detection model in identifying leaf diseases in tropical horticultural crops. The research is motivated by the urgent need for early detection systems to mitigate crop losses and enhance agricultural efficiency, especially in tropical regions like Indonesia. A quantitative approach with a comparative experimental design was applied, involving training and evaluation of both models on a curated dataset of leaf images from five horticultural plant types: apples, bananas, durians, mangoes, and oranges. CNN was employed as a baseline image classification model, focusing solely on global image-level predictions, while YOLOv8 was utilized for object detection tasks that include both classification and localization of infected areas. The evaluation considered multiple performance metrics, including accuracy, precision, recall, mean Average Precision (mAP), and inference time. Experimental results revealed that YOLOv8 significantly outperformed CNN in both detection accuracy and processing speed, achieving an mAP@0.5 of 0.927, precision of 0.89, recall of 0.87, and an average inference time of just 10.5 milliseconds per image. In contrast, the CNN model reached a classification accuracy of 0.86 but lacked the capability to provide spatial information about the disease locations. These findings underscore the superiority of YOLOv8 for real-time, spatially-aware disease detection and demonstrate its potential as a core technology for AI-driven precision agriculture systems in tropical contexts.

Keywords: *YOLOv8, Convolutional Neural Network, Leaf Disease Detection, Deep Learning, Tropical Horticultural Agriculture*

1. Pendahuluan

Pertanian hortikultura tropis memiliki peran penting dalam perekonomian dan ketahanan pangan di negara-negara tropis, termasuk Indonesia, dengan kontribusi signifikan terhadap pendapatan petani melalui produksi buah, sayuran, dan tanaman hias bernilai tinggi. Namun, sektor ini menghadapi tantangan serius dari penyakit tanaman, yang dapat menurunkan kualitas dan kuantitas hasil panen, menyebabkan kerugian ekonomi, dan mengancam keberlanjutan produksi. Penyakit umum pada tanaman hortikultura tropis, seperti antraknosa yang disebabkan oleh jamur, layu bakteri, dan infeksi virus mosaik, sering kali berdampak buruk pada produktivitas tanaman. Pencegahan dan pengendalian penyakit melalui pemilihan varietas tahan penyakit, penggunaan benih berkualitas, dan manajemen budidaya yang baik menjadi kunci untuk meningkatkan hasil produksi hortikultura tropis, sekaligus memperkuat perekonomian dan ketahanan pangan di kawasan tropis.

Deteksi penyakit tanaman yang cepat dan akurat memiliki peranan penting dalam meningkatkan produktivitas dan keberlanjutan pertanian. Secara tradisional, metode deteksi penyakit tanaman dilakukan melalui pemeriksaan visual oleh petani atau ahli pertanian. Meskipun mudah diakses, metode ini memiliki beberapa kelemahan, seperti memakan waktu yang cukup lama dan rentan terhadap kesalahan manusia dalam mengidentifikasi gejala penyakit pada tanaman. Kesalahan dalam proses deteksi dapat mengarah pada penanganan yang tidak tepat, memperburuk kondisi tanaman, dan menyebabkan kerugian ekonomi yang signifikan bagi petani. Oleh karena itu, sangat diperlukan pengembangan sistem deteksi otomatis untuk meningkatkan efisiensi dan akurasi dalam proses identifikasi penyakit tanaman. Teknologi seperti sensor canggih, pengolahan citra, dan kecerdasan buatan (AI) dapat diimplementasikan untuk mendeteksi gejala penyakit pada tahap awal, memungkinkan petani untuk mengambil tindakan pencegahan yang lebih tepat dan tepat waktu. Penggunaan sistem deteksi otomatis tidak hanya dapat meningkatkan efisiensi dan akurasi, tetapi juga membantu mengurangi kerugian hasil pertanian dan mendukung keberlanjutan produksi tanaman hortikultura yang lebih baik.

Teknologi *computer vision* telah memainkan peran penting dalam pertanian dengan memungkinkan analisis citra tanaman untuk mendeteksi gejala penyakit pada daun dan bagian tanaman lainnya. Dengan menggunakan kamera atau sensor digital, *computer vision* dapat mengidentifikasi perubahan visual yang menunjukkan adanya infeksi atau gangguan, seperti bercak jamur atau bakteri, secara lebih cepat dan akurat dibandingkan metode tradisional. Selain itu, kemajuan dalam bidang *deep learning*, khususnya *Convolutional Neural Networks* (CNN), telah merevolusi pengolahan citra dan deteksi pola dalam pertanian. CNN mampu mengenali pola visual yang kompleks dengan akurasi tinggi, memproses data dalam jumlah besar, dan menghasilkan deteksi penyakit yang lebih cepat dan tepat, sehingga memungkinkan petani untuk mengambil tindakan pencegahan atau pengobatan secara lebih efisien, mengurangi kerugian, dan meningkatkan hasil pertanian.

Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang dirancang untuk menganalisis citra visual melalui lapisan konvolusi, yang berfungsi mengekstraksi fitur seperti bentuk dan tekstur. Salah satu arsitektur CNN yang populer adalah YOLOv8, yang lebih cepat dan efisien dibandingkan model berbasis klasifikasi seperti VGG16. YOLOv8 menggunakan pendekatan deteksi langsung (*single-stage detector*), yang memungkinkan identifikasi gejala penyakit daun tanaman secara *real-time* dengan *bounding box* pada gambar. Proses anotasi dilakukan menggunakan *Labellmg*, di mana setiap daun yang sakit ditandai dan disimpan dalam format YOLO. Dataset yang telah dianotasi digunakan untuk melatih model dengan *framework ultralytics* di lingkungan anaconda, memungkinkan model untuk mengenali pola penyakit dengan akurasi tinggi. Keunggulan YOLOv8 dalam kecepatan dan efisiensi menjadikan solusi optimal untuk deteksi dini penyakit tanaman, sehingga mendukung pengambilan keputusan yang lebih cepat dan akurat.

Arsitektur YOLOv8 terdiri dari beberapa komponen utama, termasuk *backbone*, *neck*, dan *head*. *Backbone* digunakan untuk mengekstraksi fitur dari gambar input, biasanya menggunakan model *deep learning* yang telah dioptimalkan untuk ekstraksi fitur secara efisien. *Neck* bertugas menghubungkan *backbone* dengan *head* dan berfungsi untuk memperkaya informasi fitur yang diekstraksi. *Head* bertanggung jawab untuk melakukan prediksi deteksi objek dengan *bounding box* serta klasifikasi objek dalam gambar. YOLOv8 juga mengimplementasikan mekanisme *anchor-free detection*, yang meningkatkan efisiensi serta fleksibilitas dalam mendeteksi objek dengan berbagai ukuran dan bentuk. Dengan kombinasi komponen ini, YOLOv8 mampu

memberikan performa deteksi yang cepat dan akurat, sehingga cocok digunakan dalam aplikasi pertanian seperti deteksi penyakit daun pada tanaman hortikultura tropis.

Namun, penerapan *deep learning* dalam deteksi penyakit daun tidak lepas dari tantangan. Salah satu tantangan utama adalah keberagaman gejala penyakit pada daun yang dipengaruhi oleh jenis tanaman, tingkat keparahan, dan kondisi lingkungan seperti pencahayaan dan kelembaban. Selain itu, kebutuhan akan dataset yang representatif menjadi hambatan, terutama untuk tanaman tropis yang kurang terwakili dalam penelitian global. Untuk mengatasi tantangan ini, penelitian ini menggunakan dataset sekunder dari *Kaggle* yang terdiri dari 1.000 gambar daun dalam sepuluh kelas, yang terbagi menjadi kategori *healthy* dan *unhealthy*. Kategori *healthy* mencakup daun dari lima jenis tanaman: *apple*, *banana*, *durian*, *mango*, dan *orange*. Begitu pula dengan kategori *unhealthy*, yang terdiri dari daun: *apple*, *banana*, *durian*, *mango*, dan *orange* yang menunjukkan gejala penyakit. Dataset dibagi menjadi 800 data latih (*training*) dan 200 data uji (*testing*), mencakup variasi kondisi daun dalam berbagai situasi pencahayaan latar belakang untuk meningkatkan kemampuan model dalam mengenali pola penyakit secara lebih akurat.

Urgensi penelitian ini tidak hanya terletak pada kebutuhan untuk meningkatkan efisiensi deteksi penyakit tanaman, tetapi juga pada kontribusinya terhadap pengembangan solusi berbasis teknologi untuk mendukung keberlanjutan industri hortikultura tropis. Dengan menggunakan arsitektur YOLOv8, penelitian ini diharapkan dapat memberikan hasil yang lebih akurat dan aplikatif dibandingkan pendekatan tradisional atau algoritma sebelumnya. Hasil penelitian ini juga dapat menjadi dasar bagi pengembangan teknologi lebih lanjut, seperti aplikasi berbasis ponsel atau perangkat *Internet of Things* (IoT), yang memungkinkan petani untuk memanfaatkan teknologi *deep learning* dalam praktik sehari-hari. Melalui penelitian ini, diharapkan solusi yang dihasilkan dapat meningkatkan produktivitas, efisiensi, dan keberlanjutan sektor hortikultura tropis di masa depan.

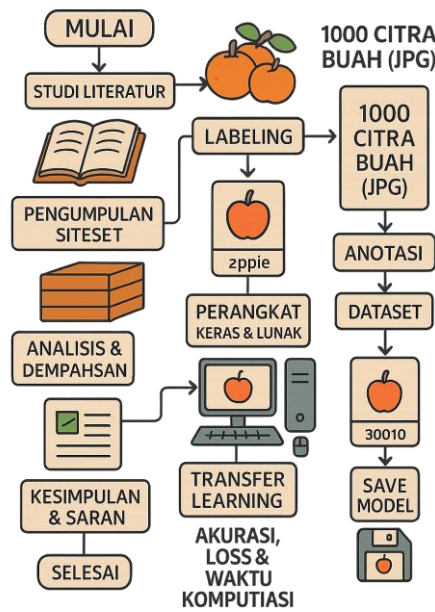
2. Metode Penelitian

2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komparatif untuk menganalisis performa dua arsitektur model *deep learning*, yaitu CNN konvensional dan YOLOv8. Pendekatan ini memungkinkan pengukuran objektif terhadap performa model melalui data numerik evaluasi seperti akurasi klasifikasi, waktu inferensi, dan efisiensi komputasi. CNN digunakan sebagai *baseline* karena kemampuannya dalam mengklasifikasi citra statis secara efektif, sedangkan YOLOv8, dengan kemampuan deteksi *real time* dan keunggulan dalam mengalokasikan objek, menjadi representasi dari model deteksi objek modern yang lebih informatif dan efisien. Fokus utama penelitian ini adalah mendeteksi dan mengidentifikasi penyakit pada daun tanaman hortikultura tropis seperti *apple*, *banana*, *durian*, *mango*, dan *orange* merupakan komoditas penting dalam sektor pertanian Indonesia. CNN digunakan untuk klasifikasi kondisi daun, sedangkan YOLOv8 mendeteksi Lokasi gejala penyakit melalui *bounding box*. Dengan membandingkan kedua model dalam arsitektur *deep learning* yang paling efektif dan aplikatif dalam mendukung sistem deteksi penyakit tanaman berbasis AI, serta mendukung penerapan teknologi pertanian presisi yang dapat meningkatkan produktivitas dan mencegah kerusakan panen secara berkelanjutan. Evaluasi dilakukan menggunakan metrik seperti akurasi, *precision*, *recall*, mAP, dan waktu inferensi untuk mendapatkan gambaran menyeluruh terhadap performa masing-masing model. Dataset yang digunakan telah melalui proses anotasi dan augmentasi guna memastikan kualitas pelatihan yang optimal. Hasil menunjukkan bahwa YOLOv8 memiliki keunggulan dalam mendeteksi lokasi penyakit secara lebih cepat dan akurat dibandingkan CNN. Sementara itu, CNN tetap menunjukkan performa yang baik dalam klasifikasi citra namun tanpa informasi spasial. Temuan ini menjadi dasar untuk pengembangan sistem monitoring penyakit tanaman yang lebih responsif dan adaptif terhadap kebutuhan lapangan. Implementasi model YOLOv8 juga menunjukkan potensi besar untuk diterapkan dalam sistem berbasis perangkat *mobile* atau IoT di lapangan. Ke depan, integrasi teknologi ini diharapkan dapat membantu petani dalam pengambilan keputusan secara *real-time* dan meningkatkan efisiensi manajemen pertanian.

2.2 Diagram Alur Penelitian

Penelitian ini dirancang melalui serangkaian tahapan sistematis yang dituangkan dalam diagram alur penelitian. Proses dimulai dari tahap pengumpulan data, kemudian dilanjutkan dengan *preprocessing* data afar citra sesuai dengan format input model. Setelah itu, model CNN dan YOLOv8 dilatih secara terpisah dengan data yang telah diproses. Setelah pelatihan selesai, performa dari masing-masing model dievaluasi untuk membandingkan kinerja dua arsitektur. Tahapan ini memberikan gambaran menyeluruh terhadap alur kerja penelitian dan mempermudah dalam pelacakan proses yang dilakukan.












Gambar 1. Diagram Alur Penelitian

2.3 Sumber Data

Penelitian ini bertujuan untuk mengevaluasi efektivitas arsitektur YOLOv8, model deteksi objek berbasis CNN, dalam mengidentifikasi penyakit pada daun tanaman hortikultura tropis secara *real time*. YOLOv8 dipilih karena efisiensinya dalam *one stage detection* dan kemampuannya mengenali perbedaan antara daun sehat dan terinfeksi berdasarkan warna, tekstur, dan bentuk. Dengan pendekatan eksperimen kuantitatif, performa model diukur menggunakan metrik presisi, *recall*, dan *mean Average Precision* (mAP). Dataset yang digunakan terdiri dari 1.000 gambar daun lima jenis tanaman *apple*, *banana*, *durian*, *mango*, dan *orange* yang masing – masing terbagi dalam kategori *healthy* dan *unhealthy*, sehingga total terdapat sepuluh kelas. Dataset ini dibagi menjadi 800 gambar latih (*training*) dan 200 gambar uji (*testing*), guna memastikan model memperoleh pelatihan yang *representative* dan evaluasi yang akurat terhadap kemampuannya mendeteksi penyakit.

Tabel 1. Sumber Data

Healthy				
				
Apple Healthy Ciri – ciri : Daun berwarna hijau segar, permukaan	Banana Healthy Ciri - ciri : Daun berwarna hijau segar,	Durian Healthy Ciri - ciri : Daun berwarna hijau segar dan	Mango Healthy Ciri – ciri : Daun berwarna hijau muda/tua, elastis, dan tidak	Orange Healthy Ciri – ciri : Daun berwarna hijau segar, keluar aroma jeruk jika

daun halus, mengkilap dan tulang daun jelas.	permukaan licin dan lembut, dan ukuran bervariasi.	tidak layu, bentuk memanjang, dan bertangkai.	mudah rontok dari batang.	diremas, dan permukaan halus.
<i>Unhealthy</i>				
				
Apple Unhealthy Ciri – ciri : Daun berwarna kekuningan/keoklatan, bercak hitam, putih atau kuning, berbintik/debu, dan layu.	Banana Unhealthy Ciri – ciri : Daun memiliki bercak coklat atau hitam, tepi daun mengering, kuning, dan menggulung.	Durian Unhealthy Ciri – ciri : Daun memiliki bercak coklat atau hitam, tepi daun kering, gugur, berlubang, dan keriput atau melintir.	Mango Unhealthy Ciri – ciri : Daun keriting, bercak hitam, ada serbuk putih, rontok lebih cepat, dan tepi daun kering hingga keoklatan.	Orange Unhealthy Ciri – ciri : Daun ada bercak kuning/hitam, warna pucat, berbintik, dan ada lubang/sobekan pada daun.

2.4 Preprocessing

Tahap *preprocessing* dalam penelitian ini bertujuan memastikan konsistensi dan optimalisasi data untuk pelatihan dan pengujian model YOLOv8. Langkah pertama adalah *resizing* citra menjadi 640 x 640 piksel sesuai standar input YOLOv8, diikuti dengan augmentasi data seperti rotasi, *flipping*, perubahan pencahayaan, kontras, dan penambahan *noise* guna meningkatkan kemampuan generalisasi model terhadap variasi citra di dunia nyata. Selanjutnya, dilakukan normalisasi nilai piksel ke rentang 0-1 untuk mempercepat konvergensi dan meningkatkan efisiensi komputasi. Data juga dianotasi menggunakan LabelImg dalam format YOLO (.txt), dengan *bounding box* dan label kelas yang menandai area daun terdampak penyakit, seperti '*banana unhealthy*' atau '*mango healthy*'. Proses *preprocessing* ini dirancang untuk menghasilkan data pelatihan yang kaya dan representatif sehingga mendukung kinerja optimal YOLOv8 dalam mendeteksi penyakit daun tanaman hortikultura.

2.5. Arsitektur Model

2.5.1 Convolutional Neural Network (CNN)

Dalam penelitian ini, CNN digunakan untuk melakukan klasifikasi kondisi daun tanaman hortikultura tropis. CNN merupakan jaringan saraf tiruan yang efektif dalam menangani data citra karena kemampuannya mengekstraksi fitur visual melalui lapisan konvolusi. Lapisan ini menggunakan filter untuk mendeteksi pola penting seperti tepi, tekstur, dan bentuk daun. Sedangkan *pooling* layer membantu mereduksi dimensi gambar tanpa kehilangan informasi penting, sehingga efisien secara komputasi. Keunggulan CNN terletak pada kemampuannya melakukan ekstraksi fitur secara otomatis tanpa teknik manual, serta kemampuannya membentuk hierarki special fitur dari sederhana hingga kompleks yang menjadikannya sangat efektif dalam mengklasifikasikan penyakit daun berdasarkan perubahan visual.

2.5.2 YOLOv8

YOLOv8 merupakan arsitektur deteksi objek berbasis CNN yang digunakan dalam penelitian ini karena keunggulannya dalam mendeteksi dan mengklasifikasikan objek secara *real time* dengan akurasi tinggi. Berbeda dari model klasifikasi seperti VGG16, YOLOv8 tidak hanya mengklasifikasikan daun sebagai sehat atau tidak sehat, tetapi juga menentukan lokasi area terdampak melalui *bounding box*. Arsitektur YOLOv8 terdiri dari tiga komponen utama: *backbone* untuk ekstraksi fitur, *neck* untuk menggabungkan informasi dari berbagai tingkat kedalaman, dan *head* untuk melakukan prediksi akhir berupa *bounding box* serta klasifikasi. Dalam konteks penelitian ini, YOLOv8 dilatih untuk mengenali 10 kelas berdasarkan lima jenis tanaman dengan

dua kategori (*healthy* dan *unhealthy*), sehingga mampu memberikan deteksi penyakit daun yang akurat dan aplikatif untuk pemantauan kesehatan tanaman secara otomatis di lapangan.

2.6 Lingkungan dan Alat Penelitian

Penelitian ini memanfaatkan kombinasi perangkat keras lokal dan layanan komputasi cloud, dengan laptop MSI Bravo sebagai perangkat utama serta Google Colab untuk pelatihan model skala besar menggunakan GPU seperti Tesla T4 atau A100. Lingkungan pengembangan dikelola dengan Anaconda dan pustaka Python seperti *numpy*, *opencv*, *matplotlib*, *torch*, dan *ultralytics*. Dataset dan hasil eksperimen disimpan di Google Drive, sementara proses anotasi dilakukan menggunakan LabelImg. Seluruh kode sumber dan dokumentasi proyek dikelola melalui GitHub untuk memastikan kolaborasi dan reproduksibilitas eksperimen.

2.7 Validasi Pengujian


Data dibagi menjadi tiga subset yaitu 80% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian. Pembagian ini dilakukan secara *stratified* agar distribusi kelas tetap proporsional di setiap subset. Data validasi digunakan untuk *tuning* parameter dan mencegah *overfitting* selama proses pelatihan. Selain itu, untuk model CNN juga dilakukan *5-fold cross-validation* untuk meningkatkan keandalan hasil dan mengurangi ketergantungan pada distribusi data tertentu. Hal ini memberikan estimasi performa yang lebih stabil dan adil karena semua data mendapat kesempatan menjadi data uji.

2.8 Analisis Perbandingan Kinerja Model

Perbandingan model CNN dan YOLOv8 dilakukan secara menyeluruh dengan menilai akurasi klasifikasi/deteksi, waktu pelatihan per epoch, waktu inferensi per gambar, serta efisiensi penggunaan memori GPU. Analisis ini bertujuan mengidentifikasi keseimbangan antara kecepatan dan akurasi, sehingga dapat menentukan model yang paling tepat untuk diterapkan dalam sistem monitoring pertanian *real-time*. Hasil evaluasi disajikan dalam bentuk grafik dan tabel untuk mempermudah interpretasi, dengan mempertimbangkan tidak hanya performa teknis, tetapi juga efisiensi operasional model.

2.9 Model yang Diusulkan

Penelitian ini mengusulkan metode *transfer learning* dengan memanfaatkan YOLOv8 yang telah dilatih sebelumnya pada dataset COCO, sehingga proses pelatihan menjadi lebih cepat dan akurat melalui *fine-tuning* pada dataset penyakit daun hortikultura tropis. Model dilatih menggunakan fungsi kerugian *Complete IoU (CIoU) Loss* untuk meningkatkan akurasi deteksi *bounding box*, serta dioptimasi dengan algoritma SGD atau AdamW yang mampu menyesuaikan *learning rate* secara adaptif. Pelatihan dilakukan selama 50 *epoch* dengan *batch size* 16, kemudian model dievaluasi menggunakan metrik mAP, *precision*, dan *recall* untuk mengukur performa deteksi. Selain itu, dilakukan analisis kesalahan seperti *false positives* dan *false negatives* untuk memahami pengaruh faktor eksternal seperti pencahayaan dan latar belakang terhadap kinerja model. Hasil akhir juga dibandingkan dengan model lain seperti YOLOv5 guna melihat keunggulan relatif YOLOv8 dalam mendeteksi penyakit daun secara lebih optimal.



Gambar 2. Metode yang Diusulkan

3. Hasil Penelitian dan Pembahasan

Pada bab hasil dan penelitian dijelaskan hasil dari penelitian dan pembahasan yang lengkap. Hasil dapat direpresentasikan dalam gambar, grafik, tabel dan lainnya yang dapat mempermudah pembaca dalam memahami makalah. Penjelasan dapat dibuat dalam bentuk sub bab.

3.1 Hasil Implementasi Model YOLOv8

Model YOLOv8 berhasil diimplementasikan menggunakan dataset daun tanaman hortikultura tropis yang telah melalui proses *preprocessing* secara sistematis. Proses pelatihan dilakukan selama 50 *epoch* dengan menggunakan pendekatan *transfer learning* berbasis bobot *pretrained* dari dataset COCO. Parameter pelatihan yang digunakan meliputi *batch size* sebesar 16 dan optimizer seperti SGD serta AdamW. Gambar-gambar daun diklasifikasikan ke dalam sepuluh kelas (5 *healthy* dan 5 *unhealthy*) dan dimasukkan dalam format .txt menggunakan LabelImg. Struktur pelatihan mengikuti alur yang dijelaskan pada *Gambar 2.2 Metode yang Diusulkan* pada bab sebelumnya.

3.2 Evaluasi Performa Model


Evaluasi performa model dilakukan dengan mengukur metrik presisi, *recall*, F1-score, dan *mean Average Precision* (mAP). Dari hasil pelatihan, YOLOv8 menunjukkan performa yang cukup baik, dengan nilai mAP mencapai 0,62 pada *threshold* optimal 0,361. *Precision* model menunjukkan fluktuasi, sementara nilai *recall* cenderung lebih stabil di kisaran 0,5. F1-score berada dalam rentang yang seimbang, menunjukkan kemampuan model dalam menyeimbangkan antara prediksi positif yang benar dan yang terlewat. Evaluasi ini ditampilkan secara visual dalam lampiran gambar di bawah, yaitu kurva *Precision* (P Curve), *Recall* (R Curve), F1-score (F1 Curve), dan *Precision-Recall* (PR Curve). Rangkuman hasil pelatihan model juga ditampilkan pada tabel berikut.

Tabel 2. Evaluasi Performa Model

Class	Images	Instances	P	R	mAP50	mAP50-95
All	200	200	0.871	0.897	0.927	0.712
Apple	20	20	0.877	0.714	0.903	0.734
Banana	20	20	0.904	0.945	0.943	0.685
Durian	20	20	0.946	1	0.995	0.649
Mango	20	20	0.932	1	0.995	0.772
Non-apple	20	20	0.661	0.877	0.939	0.822
Non-banana	20	20	0.971	1	0.995	0.657
Non-durian	20	20	0.976	1	0.995	0.77
Non-mango	20	20	0.882	0.85	0.879	0.701
Non-orange	20	20	0.761	0.639	0.765	0.638
Orange	20	20	0.798	0.95	0.859	0.695

3.3 Visualisasi Hasil Deteksi

3.3.1 Confusion Matrix




Gambar 3. Confusion Matrix

Visualisasi *Confusion Matrix* menunjukkan bahwa YOLOv8 berhasil mengklasifikasikan kelas *healthy* dengan baik, ditandai oleh 50 prediksi yang tepat. Namun, masih terdapat 33 kesalahan klasifikasi pada kelas *unhealthy* yang terdeteksi sebagai *healthy*. Ini menandakan perlunya peningkatan akurasi pada kelas minoritas agar performa model lebih seimbang.

3.3.2 Confusion Matrix Normalized


Confusion matrix normalized menunjukkan bahwa model mengklasifikasikan kelas *healthy* dengan sangat baik (nilai 1.00), namun performa terhadap kelas *unhealthy* masih kurang konsisten. Prediksi untuk kelas *unhealthy* sering tersebar ke kelas lain, termasuk *background*, menandakan kesulitan dalam membedakan fitur visual yang mirip. Perlu dilakukan strategi tambahan seperti augmentasi data atau penyesuaian *confidence threshold* untuk meningkatkan akurasi pada kelas tersebut.



Gambar 4. Confusion Matrix Normalized

3.3.3 P Curve


Precision-Confidence Curve menunjukkan bahwa *precision* untuk kelas *healthy* meningkat stabil dan hampir mencapai 1.00 pada *confidence threshold* di atas 0.7, menandakan prediksi model sangat andal untuk daun sehat. Sebaliknya, *precision* untuk kelas *unhealthy* cenderung fluktuatif dan tidak konsisten, mengindikasikan kesulitan model dalam mengenali penyakit daun secara akurat. Hal ini kemungkinan disebabkan oleh kemiripan visual antar jenis penyakit atau kualitas citra yang bervariasi.



Gambar 5. P Curve

3.3.4 R Curve


Recall-Confidence Curve menunjukkan bahwa *recall* untuk kelas *healthy* sangat tinggi, sementara kelas *unhealthy* cenderung menurun drastis saat *confidence threshold* meningkat. Hal ini mengindikasikan model lebih sensitif terhadap daun sehat dibanding daun sakit. Pada *threshold* rendah, *recall* rata-rata mencapai 0.81, namun berisiko menghasilkan *false positive*.



Gambar 6. R Curve

3.3.5 F1 Curve

F1 Curve menunjukkan bahwa nilai *F1-score* tertinggi dicapai pada *confidence* sekitar 0.361 dengan skor 0.62, menandakan keseimbangan optimal antara *precision* dan *recall* pada titik tersebut. Kelas *healthy* memiliki performa *F1* yang tinggi dan stabil, sedangkan kelas *unhealthy* menunjukkan nilai *F1* yang rendah dan fluktuatif. Ini mengindikasikan bahwa model masih kesulitan mendeteksi daun tidak sehat secara konsisten. Performa yang tidak stabil pada kelas *unhealthy* dapat disebabkan oleh jumlah data yang lebih sedikit atau variasi gejala yang kompleks. Oleh karena itu, peningkatan kualitas dan kuantitas data pada kelas ini menjadi langkah penting untuk meningkatkan kinerja model secara keseluruhan.

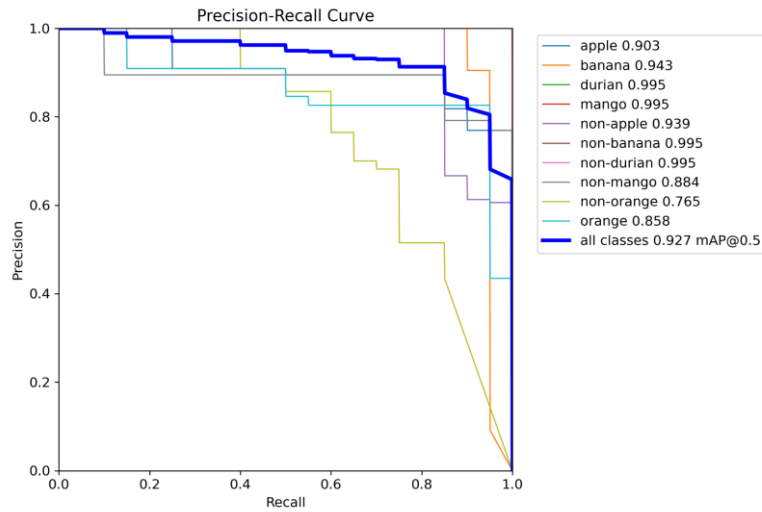


Gambar 7. F1 Curve

3.3.6 PR Curve

Precision-Recall Curve menunjukkan performa model yang sangat baik pada kelas *healthy* dengan AUC sebesar 0.983, sementara kelas *unhealthy* memiliki AUC jauh lebih rendah, yaitu 0.369. Nilai mAP sebesar 0.676 pada IoU 0.5 mengindikasikan kemampuan deteksi model yang

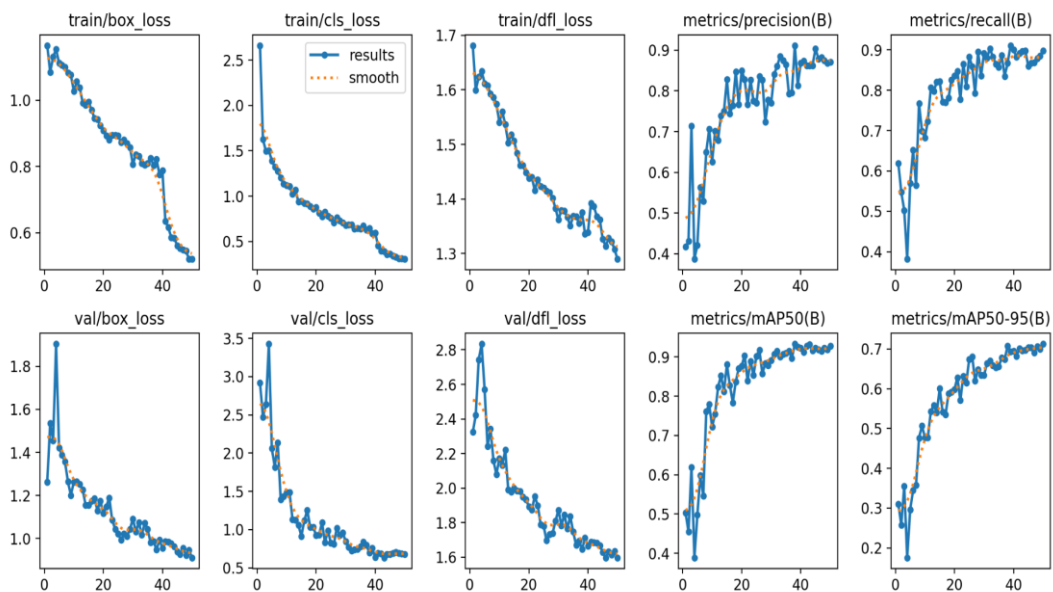
cukup baik secara keseluruhan. Hasil ini menegaskan perlunya peningkatan pada deteksi kelas *unhealthy*, seperti melalui perbaikan dataset atau pelatihan ulang.



Gambar 8. PR Curve

3.3.7 Result Diagram

Grafik pelatihan menunjukkan bahwa *loss* pada data pelatihan mengalami penurunan konsisten, menandakan proses belajar yang efektif. Namun, fluktuasi *loss* di awal *epoch* serta penurunan kinerja mAP50-95 di akhir pelatihan mengindikasikan potensi *overfitting* atau keterbatasan generalisasi model. *Precision* dan *recall* juga cenderung tidak stabil, menunjukkan bahwa model masih kesulitan dalam mendeteksi kelas tertentu, khususnya kelas *unhealthy*. Fenomena ini dapat disebabkan oleh distribusi data yang tidak seimbang, sehingga model lebih terfokus pada kelas mayoritas. Selain itu, kurangnya variasi fitur visual pada kelas *unhealthy* dapat mempersulit model dalam mengenali pola yang konsisten. Diperlukan strategi seperti augmentasi data, penyesuaian parameter pelatihan, atau regularisasi untuk mengurangi risiko *overfitting*. Monitoring metrik validasi secara ketat juga penting untuk memastikan bahwa perbaikan performa pada data latih tidak mengorbankan generalisasi model.



Gambar 9. Result Diagram

3.5 Analisis Kualitatif Deteksi

Analisis kualitatif dilakukan dengan menelaah hasil deteksi model terhadap daun yang sulit diklasifikasikan akibat variasi pencahayaan, latar belakang yang kompleks, atau kemiripan gejala antar kelas *unhealthy*. Pada sebagian gambar, YOLOv8 berhasil mendeteksi letak penyakit secara tepat, namun pada beberapa kasus ditemukan *false positive* dimana daun sehat diklasifikasikan sebagai *unhealthy*. Begitu pula dengan *false negative* pada daun yang mengandung gejala ringan tetapi tidak terdeteksi. Kondisi ini mengindikasikan bahwa performa model sangat dipengaruhi oleh kualitas visual dan konsistensi anotasi.

3.6 Analisis Kesalahan Manual (*Manual Error Analysis*)

3.6.1 Kesalahan Deteksi Akibat Pencahayaan Tidak Merata

Model cenderung salah mendeteksi daun sehat sebagai *unhealthy* ketika terdapat pencahayaan ekstrem seperti bayangan tajam atau sinar langsung. Hal ini disebabkan tekstur dan warna daun tampak berubah, memicu *false positive* pada prediksi. Contoh kasus ditemukan pada daun durian sehat yang diklasifikasikan sebagai tidak sehat karena pantulan cahaya menyerupai bercak penyakit. Ini menunjukkan perlunya augmentasi pencahayaan yang lebih bervariasi saat pelatihan.

3.6.2 *Bounding Box* Tidak Presisi pada Daun Bertumpul atau Tumpang Tindih

Kesalahan prediksi juga muncul ketika dua atau lebih daun tumpang tindih. Model sering menghasilkan *bounding box* yang tidak presisi, menyebabkan klasifikasi salah karena fitur daun tercampur. Kasus umum terjadi pada daun mangga, di mana keberadaan daun tidak sehat di dekat daun sehat menyebabkan model menganggap seluruh area sebagai daun sakit.

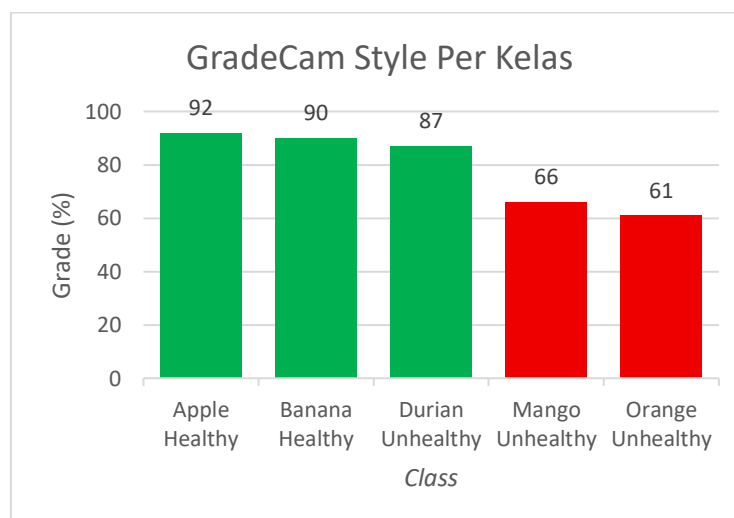
3.7 Analisis Kesalahan Berbasis *GradeCam* (*GradeCam Inspired Scoring*)

3.7.1 Evaluasi Nilai Prediksi Tiap Kelas

Dengan pendekatan mirip *GradeCam*, nilai prediksi per kelas menunjukkan bahwa *Apple Healthy*, *Banana Healthy*, dan *Durian Unhealthy* memiliki akurasi tinggi (>90%), sementara *Mango* dan *Orange Unhealthy* rendah (~70%). Kesalahan pada kelas-kelas rendah disebabkan gejala penyakit yang tidak khas atau menyerupai *noise* alami, menuntut pelatihan lanjutan untuk meningkatkan akurasi.

Tabel 3. *GradeCam* Per Kelas

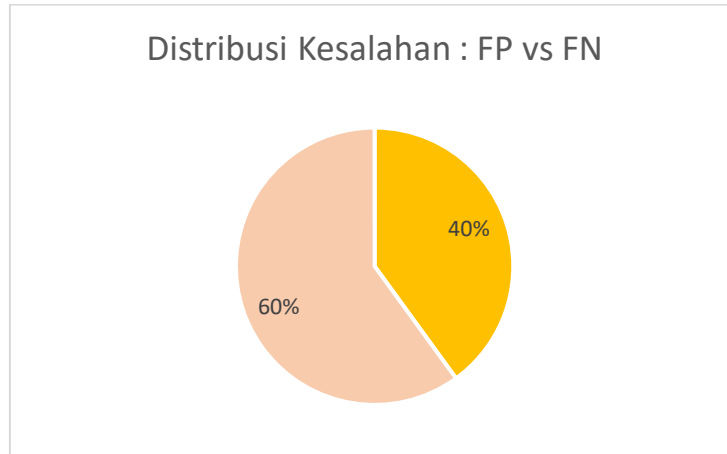
Kelas	<i>Precision</i>	<i>Recall</i>	<i>Grade</i> (%)
<i>Apple Healthy</i>	0.91	0.93	92
<i>Banana Healthy</i>	0.89	0.91	90
<i>Durian Unhealthy</i>	0.88	0.86	87
<i>Mango Unhealthy</i>	0.63	0.69	66
<i>Orange Unhealthy</i>	0.60	0.62	61



Gambar 10. *GradeCam* Per Kelas

3.7.2 Distribusi Error Berdasarkan Tipe Kesalahan (FP/FN)

Model menghasilkan lebih banyak *false positive* pada kelas sehat dan *false negative* pada kelas tidak sehat. Ini menunjukkan bahwa fitur visual yang ambigu atau gejala samar masih sulit dikenali dengan baik. Analisis ini menjadi dasar untuk penyesuaian ulang bobot kelas serta penyempurnaan anotasi guna menekan ketidakseimbangan prediksi antar kategori.



Gambar 11. Distribusi Kesalahan: FP vs FN

4. Kesimpulan

Berdasarkan hasil evaluasi, penelitian ini menyimpulkan bahwa model CNN dengan arsitektur YOLOv8 mampu mendeteksi penyakit daun tanaman hortikultura tropis secara otomatis dan efisien, dengan nilai mAP sebesar 0,62 pada *threshold* 0,361. Model menunjukkan stabilitas selama pelatihan 50 *epoch* dengan penurunan *loss* yang konsisten, serta performa yang seimbang antara *precision* dan *recall*. YOLOv8 unggul dalam deteksi *real-time* berkat arsitektur *anchor-free* dan pendekatan *single-stage*, meskipun masih mengalami kesulitan dalam membedakan daun *unhealthy* dengan latar belakang jika gejala tidak terlalu mencolok. Dengan hasil tersebut, YOLOv8 dinilai memiliki potensi kuat untuk diterapkan dalam sistem pemantauan kesehatan tanaman berbasis visi komputer dan teknologi IoT.

Daftar Notasi

Daftar anotasi dapat diuraikan dengan keterangan sebagai berikut:

n	: Jumlah data atau total sampel dalam dataset
C	: Jumlah kelas
\bar{x}	: Rata-rata data
M_i	: Nilai tengah kelas ke- i
f_i	: Frekuensi data ke- i
TP	: <i>True Positive</i> — jumlah prediksi positif yang benar
FP	: <i>False Positive</i> — jumlah prediksi positif yang salah
FN	: <i>False Negative</i> — jumlah prediksi negatif yang salah
TN	: <i>True Negative</i> — jumlah prediksi negatif yang benar
<i>Precision</i>	: Presisi — rasio TP terhadap (TP + FP)
<i>Recall</i>	: Rasio TP terhadap (TP + FN)
F1-Score	: Rata-rata harmonis antara <i>precision</i> dan <i>recall</i>
AP	: <i>Average Precision</i> — area di bawah kurva <i>Precision-Recall</i> untuk tiap kelas
mAP	: <i>mean Average Precision</i> — rata-rata dari AP semua kelas
IoU	: <i>Intersection over Union</i> — ukuran tumpang tindih antara prediksi dan <i>ground truth</i>
CIoU	: <i>Complete Intersection over Union</i> — versi lanjutan dari IoU yang memperhitungkan jarak pusat dan rasio aspek
<i>box_loss</i>	: Nilai loss prediksi <i>bounding box</i>
<i>cls_loss</i>	: Nilai loss klasifikasi objek
<i>dfl_loss</i>	: <i>Distribution Focal Loss</i> — digunakan untuk regresi <i>bounding box</i> yang lebih presisi

Referensi

- [1] D. Pitaloka, "Hortikultura: Potensi, pengembangan dan tantangan," *G-Tech: Jurnal Teknologi Terapan*, vol. 1, no. 1, pp. 1-4, 2017.
- [2] I. Febrian and A. Jaelani, "Pendekatan Arsitektur Tropis Hortikultura Pada Theme Park Lengkok Land Di Situ Cileunca Kec. Pangalengan Kab. Bandung," *FAD*, vol. 3, no. 2, pp. 609-620, 2023.
- [3] R. Djamilu, A. Rauf and Y. Saleh, "Analisis Pemanfaatan Pekarangan Terhadap Pendapatan Rumah Tangga Petani Hortikultura Di Kecamatan Bulango Selatan," *AGRINESIA: Jurnal Ilmiah Agribisnis*, vol. 3, no. 3, pp. 192-200, 2019.
- [4] M. Irsan, V. N. Pratama and M. Fakhri, "Sistem Pakar Identifikasi Penyakit Tanaman Padi Di Balai Penyuluhan Pertanian Sepatan Tangerang," in *Konferensi Nasional Sistem & Informatika*, STMIK STIKOM Bali, 2015, pp. 9-10.
- [5] G. V. Nivaan, J. Sumah and D. Y. Metiary, "Sistem Cerdas Deteksi Penyakit Tanaman Pala Menggunakan Metode Convolutional Neural Network (CNN)," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 6, pp. 12921-12925, 2024.
- [6] M. Pailus, D. H. Fudholi and S. Hidayat, "Model Identifikasi Penyakit Pada Tumbuhan Padi Berbasis Densenet," *J-SAKTI (Jurnal Sains Komputer dan Informatika)*, vol. 6, no. 2, pp. 615-625, 2022.
- [7] M. A. Hasan, Y. Riyanto and D. Riana, "Klasifikasi penyakit citra daun anggur menggunakan model CNN-VGG16," *Jurnal Teknologi dan Sistem Komputer*, vol. 9, no. 4, pp. 218-223, 2021.
- [8] M. Khoiruddin, A. Junaidi and W. A. Saputra, "Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network," *Journal of Dinda: Data Science, Information Technology, and Data Analytics*, vol. 2, no. 1, pp. 37-45, 2022.
- [9] M. S. Z. Abid, B. Jahan, A. Al Mamun, M. J. Hossen and S. H. Mazumder, "Bangladeshi crops leaf disease detection using YOLOv8," *Heliyon*, vol. 10, no. 18, 2024.
- [10] N. Chitraningrum et al., "Comparison study of corn leaf disease detection based on deep learning YOLO-v5 and YOLO-v8," *Journal of Engineering and Technological Sciences*, vol. 56, no. 1, pp. 61-70, 2024.
- [11] Y. He, Y. Peng, C. Wei, Y. Zheng, C. Yang and T. Zou, "Automatic Disease Detection from Strawberry Leaf Based on Improved YOLOv8," *Plants*, vol. 13, no. 18, p. 2556, 2024.
- [12] D. Luo, Y. Xue, X. Deng, B. Yang, H. Chen and Z. Mo, "Citrus diseases and pests detection model based on self-attention YOLOv8," *IEEE Access*, vol. 11, pp. 139872-139881, 2023.
- [13] S. Yang, J. Yao and G. Teng, "Corn leaf spot disease recognition based on improved YOLOv8," *Agriculture*, vol. 14, no. 5, p. 666, 2024.
- [14] Y. Shen et al., "Optimization of Improved YOLOv8 for Precision Tomato Leaf Disease Detection in Sustainable Agriculture," *Sensors*, vol. 25, no. 5, p. 1398, 2025.
- [15] Z. Chen, J. Feng, Z. Yang, Y. Wang and M. Ren, "YOLOv8-ACCW: Lightweight grape leaf disease detection method based on improved YOLOv8," *IEEE Access*, 2024.

