

DETEKSI DAN KLASIFIKASI PENYAKIT DAUN TANAMAN PORANG MENGUNAKAN MODEL YOLOV8

Muhammad Al Hafiz¹; Buddy Satria^{2*}; Arifan Rahman³

Departemen Informatika, Fakultas Teknologi Informasi^{1,2,3}
Universitas Andalas, Padang, Indonesia^{1,2,3}
<https://unand.ac.id/>^{1,2,3}

malhafiz713@gmail.com¹, buddy.satria@it.unand.ac.id^{2*}, arifanrahman@it.unand.ac.id³

(*) Corresponding Author



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

Abstract— Porang (*Amorphophallus muelleri*) is a high-value agricultural commodity whose productivity can be significantly reduced by leaf diseases. Conventional visual inspection is time-consuming and subjective, highlighting the need for an automated detection system that is both accurate and efficient. Previous studies on porang leaf diseases have primarily focused on image classification or object detection methods with limited capability to generalize under varying visual conditions. Therefore, this study aims to evaluate the performance of the YOLOv8n model integrated with data augmentation for detecting and classifying five conditions of porang leaves: early blight, late blight, konjac mosaic, insect attacks, and healthy leaves. The proposed approach combines YOLOv8n with on-the-fly data augmentation during training and Stratified 5-Fold Cross-Validation to improve the model's generalization capability. A total of 1,065 leaf images were used for model training and evaluation. Data augmentation techniques, including Mosaic, HSV color adjustment, and geometric transformations, were applied during training. Experimental results show that the proposed model achieved a mean Average Precision (mAP50) of 80.53%, a Precision of 83.11%, and a Recall of 70.66%, outperforming the baseline model without augmentation, which obtained an mAP50 of only 63.15%. Although the early blight and healthy classes achieved excellent detection performance (mAP50 > 90%), the relatively lower Recall was mainly caused by background bias in the insect class, resulting in several objects being missed during detection. Overall, the integration of YOLOv8n with data augmentation demonstrates its potential to improve the generalization capability of porang leaf disease detection systems under diverse visual conditions.

Keywords: Data Augmentation, Deep Learning, Object Detection, Porang Leaf Disease, YOLOv8

Abstrak— Tanaman porang (*Amorphophallus muelleri*) merupakan komoditas pertanian bernilai ekonomi tinggi yang produktivitasnya dapat menurun secara signifikan akibat penyakit daun. Proses identifikasi penyakit secara visual masih bersifat subjektif dan memerlukan waktu yang relatif lama, sehingga diperlukan sistem deteksi otomatis yang cepat dan akurat. Penelitian sebelumnya mengenai penyakit daun porang umumnya masih berfokus pada klasifikasi citra atau menggunakan metode deteksi objek yang memiliki keterbatasan dalam menghadapi variasi kondisi visual. Oleh karena itu, penelitian ini bertujuan mengevaluasi kinerja model YOLOv8n yang dipadukan dengan teknik augmentasi data untuk mendeteksi dan mengklasifikasikan lima kondisi daun porang, yaitu bercak cokelat (early blight), busuk daun (late blight), mosaik konjac (konjac mosaic), serangan serangga (insects), dan daun sehat (healthy). Pendekatan yang diusulkan mengintegrasikan YOLOv8n dengan augmentasi data secara on-the-fly selama proses pelatihan serta Stratified 5-Fold Cross-Validation untuk meningkatkan kemampuan generalisasi model. Sebanyak 1.065 citra daun digunakan pada proses pelatihan dan evaluasi model. Teknik augmentasi yang diterapkan meliputi Mosaic, penyesuaian ruang warna HSV, dan transformasi geometris. Hasil pengujian menunjukkan bahwa model memperoleh nilai mean Average Precision (mAP50) sebesar 80,53%, Precision sebesar 83,11%, dan Recall sebesar 70,66%, lebih tinggi dibandingkan model tanpa augmentasi yang hanya mencapai mAP50 sebesar 63,15%. Meskipun kelas early blight dan daun sehat berhasil dideteksi dengan sangat baik (mAP50 > 90%), nilai Recall yang relatif lebih rendah terutama disebabkan

oleh *background bias* pada kelas insects, sehingga sebagian objek tidak berhasil terdeteksi. Secara keseluruhan, integrasi YOLOv8n dengan teknik augmentasi data menunjukkan potensi dalam meningkatkan kemampuan generalisasi sistem deteksi penyakit daun porang pada berbagai kondisi visual.

Kata kunci: *Augmentasi Data, Deep Learning, Deteksi Objek, Penyakit Daun Porang, YOLOv8*

PENDAHULUAN

Porang (*Amorphophallus muelleri*) merupakan tanaman umbi-umbian asli Indonesia yang telah menjadi komoditas pertanian strategis dengan nilai ekonomi tinggi dan potensi ekspor yang menjanjikan (Zuhan & Kristian, 2023). Selain memiliki manfaat luas di sektor pangan, kesehatan, dan industri kosmetik karena kandungan glukomanannya yang tinggi, upaya maksimalisasi produktivitas porang dihadapkan pada ancaman serius berupa penyakit daun dan serangan hama (Badan Karantina Indonesia, 2023). Penyakit seperti bercak cokelat (*early blight*), busuk daun (*late blight*), mosaik konjac, serta kerusakan akibat serangga dapat menurunkan kemampuan fotosintesis dan mengakibatkan kerugian produksi umbi hingga 88% (Soedarjo & Djufry, 2021). Secara konvensional, identifikasi penyakit masih bergantung pada inspeksi visual oleh petani yang memakan banyak waktu, subjektif, dan rentan terhadap kesalahan diagnosis, terutama pada area perkebunan yang luas (Ashwinkumar et al., 2022). Keterbatasan ini mendorong kebutuhan mendesak akan sistem deteksi otomatis berbasis pengolahan citra (*image processing*) yang mampu memberikan diagnosis secara cepat, konsisten, dan objektif.

Perkembangan sistem deteksi penyakit tanaman berbasis komputer telah melalui berbagai pendekatan. Salah satu bidang teknologi yang digunakan, yaitu *computer vision* dan *machine learning* telah banyak dimanfaatkan untuk menyelesaikan berbagai permasalahan klasifikasi objek berdasarkan karakteristik visual citra. Berbagai penelitian menunjukkan bahwa pemanfaatan fitur warna dan algoritma klasifikasi mampu menghasilkan performa yang baik dalam mengenali pola visual objek, sehingga menunjukkan potensi *computer vision* sebagai solusi identifikasi otomatis pada berbagai domain (Satria et al., 2025).

Penelitian terkait penyakit daun porang telah menggunakan berbagai pendekatan, mulai dari *machine learning* berbasis ekstraksi fitur hingga *deep learning* dan *object detection*. Pendekatan awal menggunakan *machine learning* klasik dengan ekstraksi fitur tekstur berbasis *Gray-Level Co-Occurrence Matrix* (GLCM) dan *Artificial Neural Network* (ANN) telah diusulkan (Tsaqib Marwan & Rimantho, 2022). Selanjutnya, penerapan *deep learning* melalui penelitian oleh Zuhan dan Kristian (2023) menggunakan arsitektur EfficientNetV2M

menunjukkan kemampuan klasifikasi dengan akurasi yang tinggi (Zuhan & Kristian, 2023). Di sisi lain, pendekatan *object detection* menggunakan SSD-MobileNet juga telah diterapkan untuk memperoleh informasi lokasi objek melalui *bounding box* (Nurhasanah et al., 2023). Pendekatan YOLOv8n juga telah diterapkan untuk mendeteksi penyakit pada tanaman dengan memanfaatkan kemampuan *object detection* dalam mengidentifikasi objek penyakit secara langsung (Ahmad Zaeni Dahlan & Ghufroon Zaida Muflih, 2025). Perbandingan penelitian tersebut dapat dilihat pada Tabel 1.

Tabel 1. Perbandingan Penelitian Terdahulu

Peneliti n	Metode	Dataset	Hasil & Keterbatasan
Marwan & Rimantho	GLCM + ANN	40 citra daun porang sakit	Koefisien regresi 0,905; RMSE 0,5. Dataset terbatas dan menggunakan fitur <i>hand-crafted</i> .
Zuhan & Kristian	DCNN Transfer Learning (EfficientNetV2M)	1.000 citra menjadi 10.000 citra setelah augmentasi	Akurasi 98,44%. Berfokus pada <i>image classification</i> , sehingga tidak memberikan lokasi penyakit.
Nurhasanah et al.	SSD-MobileNet	1.650 citra daun porang; 3 kelas penyakit	Akurasi 95,45%. Jarak deteksi maksimal 15 cm dan masih terjadi misklasifikasi pada gejala yang mirip.

Sumber: (Tsaqib Marwan & Rimantho, 2022, Zuhan & Kristian, 2023, Nurhasanah et al., 2023)

Berdasarkan Tabel 1, penelitian mengenai penyakit daun porang telah berkembang dari pendekatan berbasis ekstraksi fitur *hand-crafted* menuju penerapan *deep learning* dan *object detection*. Pendekatan GLCM dan ANN yang digunakan oleh Marwan dan Rimantho (2022) masih bergantung pada ekstraksi fitur secara manual, yang memiliki keterbatasan dalam merepresentasikan variasi karakteristik visual secara otomatis (Hassan et al., 2022).

Sementara itu, penelitian Zuhan dan Kristian (2023) menggunakan EfficientNetV2M dan menghasilkan akurasi yang tinggi, tetapi pendekatan *image classification* hanya menghasilkan label kelas tanpa memberikan informasi lokasi objek secara spasial. Keterbatasan tersebut sejalan dengan karakteristik metode

klasifikasi citra yang tidak menyediakan informasi lokasi objek sebagaimana pada *object detection* (H. Wang et al., 2022). Di sisi lain, penelitian Nurhasanah et al. (2023) telah menerapkan SSD-MobileNet untuk memberikan informasi lokasi melalui *bounding box*, tetapi masih memiliki keterbatasan pada jarak deteksi dan misklasifikasi gejala yang memiliki kemiripan visual. Kondisi tersebut menunjukkan bahwa masih diperlukan pendekatan *object detection* yang mampu melakukan klasifikasi sekaligus lokalisasi penyakit daun porang. Beberapa studi komparatif terkini menunjukkan bahwa keluarga algoritma YOLO (You Only Look Once) merupakan salah satu pendekatan *object detection* yang mampu memberikan keseimbangan antara kecepatan inferensi dan akurasi deteksi. Penelitian yang membandingkan YOLOv8 dengan YOLO11 untuk identifikasi penyakit pada daun tomat juga menunjukkan bahwa YOLOv8 memiliki kemampuan deteksi yang baik pada objek penyakit tanaman (Majid & Ariatmanto, 2025).

Hasil serupa ditunjukkan oleh penelitian yang membandingkan YOLOv5 dan YOLOv8 untuk deteksi penyakit daun tanaman tomat, di mana YOLOv8 menunjukkan kinerja yang lebih baik pada beberapa metrik evaluasi dibandingkan YOLOv5 (Choiriyah & Supriyanto, 2025). Selanjutnya, adapun penelitian yang membandingkan YOLOv8 dengan arsitektur lain seperti RetinaNet dan Faster R-CNN pada tugas deteksi objek di bidang pertanian menunjukkan bahwa YOLOv8 memperoleh nilai *Mean Average Precision* (mAP50) sebesar 0,885 dengan waktu inferensi 11,7 ms pada varian Nano, sedangkan RetinaNet dan Faster R-CNN masing-masing memperoleh mAP50 sebesar 0,695 dan 0,670 dengan waktu inferensi 133,9 ms dan 266,2 ms (Daraghmi et al., 2025).

Berdasarkan karakteristik tersebut, penelitian ini menggunakan YOLOv8n karena memiliki arsitektur yang ringan, kebutuhan komputasi yang relatif rendah, serta sesuai untuk pelatihan pada dataset berukuran terbatas. Arsitektur dilengkapi dengan *decoupled head* yang mampu meningkatkan proses klasifikasi dan regresi *bounding box*, serta kombinasi *Feature Pyramid Network (FPN)* dan *Path Aggregation Network (PAN)* memungkinkan model mendeteksi objek berukuran kecil secara lebih efektif pada berbagai kondisi visual (Terven et al., 2023). Karakteristik tersebut menjadikan YOLOv8n sebagai model yang potensial untuk dikembangkan dalam sistem deteksi penyakit daun tanaman yang membutuhkan kemampuan klasifikasi sekaligus lokalisasi objek secara akurat.

Berdasarkan karakteristik tersebut, penelitian ini menerapkan YOLOv8n untuk mendeteksi dan mengklasifikasikan lima kondisi daun tanaman porang, yaitu *early blight*, *late blight*, *konjac mosaic*, *insects*, dan *healthy*, menggunakan dataset sebanyak 1.065 citra. Untuk meningkatkan keragaman data dan kemampuan model dalam menghadapi variasi kondisi visual, augmentasi data diterapkan secara *on-the-fly* selama proses pelatihan. Teknik yang digunakan meliputi Mosaic, penyesuaian HSV, *flipping*, *scaling*, dan *translation*. Pemilihan teknik tersebut didukung oleh penelitian sebelumnya pada deteksi penyakit daun berbasis YOLO yang menunjukkan bahwa augmentasi melalui penyesuaian HSV, *translation*, *scaling*, dan *flipping* dapat membantu menghadapi variasi kondisi lingkungan dan mengurangi dampak distorsi fotometrik, sedangkan Mosaic dapat memperkaya informasi latar belakang serta variasi skala objek (Y. Wang et al., 2022). Selanjutnya, *Stratified 5-Fold Cross-Validation* digunakan untuk mempertahankan proporsi kelas yang relatif seimbang pada setiap fold sehingga evaluasi performa model dapat dilakukan secara lebih representatif, terutama ketika distribusi kelas tidak sepenuhnya seimbang (Szeghalmy & Fazekas, 2023). Pendekatan tersebut diharapkan dapat meningkatkan kemampuan generalisasi YOLOv8n dalam mendeteksi dan mengklasifikasikan kondisi daun porang pada berbagai variasi visual.

BAHAN DAN METODE

Penelitian ini menggunakan pendekatan eksperimental yang dilakukan secara sistematis melalui lima tahapan utama, dimulai dari studi literatur dan pengumpulan data, dilanjutkan dengan proses perancangan, implementasi, hingga evaluasi akhir model. Fokus utama penelitian terletak pada perancangan alur pengembangan model yang dimulai dari tahap persiapan data hingga proses pelatihan model yang optimal. Pada penelitian ini, model yang digunakan adalah YOLOv8 varian nano (YOLOv8n) yang dipilih karena memiliki arsitektur ringan, kebutuhan komputasi yang rendah, dan lebih sesuai untuk dataset dengan jumlah relatif kecil.

Penggunaan varian nano juga bertujuan untuk mengurangi risiko *overfitting* sekaligus mempertahankan efisiensi proses pelatihan dan inferensi tanpa mengorbankan kemampuan deteksi objek. Tahap persiapan data mencakup proses anotasi dan pembagian dataset, sedangkan tahap pelatihan dan evaluasi dilakukan menggunakan metode *Stratified 5-Fold Cross-Validation* guna

memperoleh bobot model yang optimal dan menghasilkan performa deteksi yang stabil.

Pengumpulan Data

Dataset yang digunakan merupakan dataset sekunder bernama *AmorphophallusGarden* yang diperoleh dari repositori publik Kaggle. Dataset terdiri atas 1.065 citra daun tanaman porang yang merepresentasikan lima kondisi, yaitu *early blight*, *late blight*, *konjac mosaic*, *insects*, dan *healthy*. Citra diperoleh dari berbagai kondisi lingkungan dan sudut pengambilan gambar, sehingga memiliki variasi visual yang representatif untuk proses pelatihan dan evaluasi model deteksi objek.

Persiapan Data

Persiapan data dilakukan melalui tiga tahapan utama. Pertama, seluruh citra dianotasi secara manual menggunakan platform Roboflow untuk menghasilkan *bounding box* sebagai *ground truth* pada setiap objek penyakit daun porang. Kedua, dilakukan tahap *pre-processing* berupa standarisasi resolusi citra menjadi 640×640 piksel dan penerapan fitur *auto-orient* untuk menyesuaikan orientasi citra berdasarkan metadata EXIF sehingga seluruh gambar memiliki orientasi yang konsisten sebelum proses pelatihan. Ketiga, dataset diekspor ke dalam format YOLO yang terdiri atas citra, berkas anotasi, dan berkas konfigurasi dataset sebagai masukan pada proses pelatihan model.

Pelatihan Model

Sebelum proses pelatihan, dataset dipisahkan menjadi 80% training set dan 20% testing set. Training set kemudian dievaluasi menggunakan metode Stratified 5-Fold Cross-Validation sehingga proporsi setiap kelas tetap terjaga pada setiap fold. Pada setiap iterasi, sekitar 80% data digunakan sebagai data pelatihan dan 20% sebagai data validasi secara bergantian. Model yang digunakan adalah YOLOv8 varian nano (YOLOv8n). Pada skenario dengan augmentasi, teknik augmentasi yang diterapkan secara *on-the-fly* meliputi *Mosaic*, penyesuaian ruang warna HSV (*Hue*, *Saturation*, *Value*), *flipping*, *scaling*, dan *translation* untuk meningkatkan kemampuan generalisasi terhadap variasi kondisi visual. Konfigurasi hyperparameter yang digunakan selama proses pelatihan ditunjukkan pada Tabel 2.

Tabel 2. Konfigurasi Hyperparameter Pelatihan YOLOv8n

No	Hyperparameter	Nilai
1	Epoch	200
2	Batch Size	8
3	Initial Learning Rate	0.01

No	Hyperparameter	Nilai
4	Optimizer	Auto
5	Early Stopping (<i>Patience</i>)	30
6	IoU Threshold	0.7
7	Momentum	0.937
8	Weight Decay	0.0005

Sumber: (Hasil Penelitian, 2026)

Evaluasi Model

Evaluasi model dilakukan dalam dua fase untuk mengukur kemampuan generalisasi terhadap data baru. Pada fase pertama, hasil pelatihan pada setiap fold dievaluasi menggunakan data validasi untuk menilai konsistensi performa dan memilih model terbaik berdasarkan nilai *mean Average Precision* (mAP). Selanjutnya, model terbaik diuji menggunakan 20% data uji independen yang tidak pernah dilibatkan selama proses pelatihan maupun validasi untuk memperoleh evaluasi yang objektif terhadap kemampuan generalisasi model. Kinerja YOLOv8n kemudian diukur secara kuantitatif menggunakan metrik *Precision*, *Recall*, *F1-Score*, *Intersection over Union* (IoU), *Average Precision* (AP), dan *mean Average Precision* (mAP). Hasil evaluasi ini menghasilkan bobot model terbaik (.pt) yang digunakan untuk mendeteksi penyakit pada citra daun porang baru.

HASIL DAN PEMBAHASAN


Penelitian ini mengevaluasi kinerja arsitektur YOLOv8n melalui dua skenario pelatihan, yaitu model tanpa augmentasi data (Model 1) dan model dengan augmentasi data (Model 2). Kedua skenario menggunakan dataset, ukuran citra, arsitektur YOLOv8n, serta konfigurasi hyperparameter pelatihan yang sama sebagaimana ditunjukkan pada Tabel 2. Perbedaan kedua skenario hanya terletak pada penerapan augmentasi data secara *on-the-fly* selama proses pelatihan, yaitu Model 1 dilatih tanpa augmentasi, sedangkan Model 2 dilatih menggunakan augmentasi. Dengan konfigurasi yang sama tersebut, perbandingan kedua model dilakukan untuk mengevaluasi pengaruh penerapan augmentasi terhadap kemampuan deteksi penyakit daun porang pada berbagai kondisi visual. Hasil evaluasi dianalisis berdasarkan proses pelatihan, performa pada data uji, serta karakteristik deteksi pada masing-masing kelas penyakit.

Hasil Pelatihan Model Tanpa Augmentasi

Pelatihan dilakukan menggunakan konfigurasi hyperparameter sebagaimana ditunjukkan pada Tabel 2 dengan mekanisme *early stopping* (*patience* = 30) untuk menghentikan pelatihan apabila tidak terjadi peningkatan

performa selama sejumlah epoch tertentu. Berdasarkan hasil eksperimen, Model memperoleh rata-rata nilai mAP50 sebesar 0,6195 dengan waktu pelatihan 51 menit 54 detik. Meskipun pelatihan dirancang hingga maksimum 200 epoch, mekanisme *early stopping* menghentikan proses

lebih awal karena peningkatan performa pada data validasi tidak lagi signifikan. Hal ini menunjukkan bahwa model telah mencapai kondisi konvergen, namun belum mampu menghasilkan kemampuan generalisasi yang optimal. Kurva hasil pelatihan Model 1 ditunjukkan pada Gambar 1.



Sumber: (Hasil Penelitian, 2026)

Gambar 1. Kurva Pelatihan Model 1

Berdasarkan Gambar 1, nilai *training loss* mengalami penurunan secara konsisten hingga akhir pelatihan, menunjukkan bahwa model semakin mampu menyesuaikan diri terhadap data latih. Sebaliknya, *validation loss* mulai meningkat setelah beberapa epoch meskipun *training loss* terus menurun. Pola ini merupakan indikasi terjadinya *overfitting*, yaitu kondisi ketika model mempelajari karakteristik spesifik pada data pelatihan sehingga kemampuannya generalisasinya terhadap data yang belum pernah dilihat menjadi menurun. Fenomena tersebut juga didukung oleh nilai mAP50 yang hanya mencapai 0,6195, yang menunjukkan bahwa peningkatan performa pada data latih tidak sepenuhnya diikuti oleh peningkatan akurasi pada data validasi.

Selain itu, kurva Precision menunjukkan tren peningkatan yang relatif stabil selama proses pelatihan, sedangkan kurva Recall masih mengalami fluktuasi dan cenderung berada pada nilai yang lebih rendah dibandingkan Precision. Hal ini mengindikasikan bahwa model masih belum mampu mendeteksi seluruh objek penyakit secara konsisten sehingga masih terdapat objek yang tidak berhasil terdeteksi (*false negative*). Analisis lebih lanjut mengenai fenomena ini dibahas pada hasil evaluasi menggunakan data uji. Visualisasi train batch hasil pelatihan Model 1 ditunjukkan pada Gambar 2.



Sumber: (Hasil Penelitian, 2026)

Gambar 2. Train Batch Model 1

Berdasarkan Gambar 2, seluruh citra pelatihan masih mempertahankan karakteristik visual asli tanpa penerapan augmentasi data. Variasi orientasi daun, posisi objek, skala, maupun kondisi pencahayaan relatif terbatas sehingga distribusi data pelatihan menjadi kurang beragam. Kondisi tersebut menyebabkan model cenderung mempelajari pola visual yang spesifik terhadap data pelatihan dan kurang adaptif ketika dihadapkan pada variasi citra baru selama proses pengujian. Temuan ini sejalan dengan pola *overfitting* yang ditunjukkan pada kurva loss pada Gambar 1.


Secara keseluruhan, hasil pelatihan Model 1 menunjukkan bahwa penggunaan data asli tanpa augmentasi mampu menghasilkan proses pelatihan yang konvergen, namun kemampuan generalisasi

model masih terbatas akibat rendahnya variasi data pelatihan. Oleh karena itu, pada skenario berikutnya diterapkan teknik augmentasi data untuk meningkatkan keragaman data dan memperbaiki performa deteksi model.

Hasil Pelatihan Model dengan Augmentasi Data

Pada Model 2 diterapkan teknik augmentasi data yang meliputi *Mosaic*, penyesuaian ruang warna HSV (*Hue*, *Saturation*, *Value*), serta


transformasi geometris berupa *flipping*, *scaling*, dan *translation*. Berdasarkan hasil pelatihan, penerapan augmentasi meningkatkan rata-rata nilai mean Average Precision (mAP50) menjadi 0,7770, lebih tinggi dibandingkan Model 1 yang hanya mencapai 0,6195. Peningkatan performa tersebut diikuti dengan bertambahnya waktu pelatihan menjadi 3 jam 3 menit 53 detik akibat proses pembangkitan variasi citra pada setiap iterasi pelatihan. Kurva hasil pelatihan Model 2 ditunjukkan pada Gambar 3.



Sumber: (Hasil Penelitian, 2026)

Gambar 3. Kurva Pelatihan Model 2

Berdasarkan Gambar 3, nilai training loss dan validation loss mengalami penurunan secara konsisten hingga akhir proses pelatihan tanpa menunjukkan peningkatan validation loss yang signifikan. Pola tersebut menunjukkan bahwa model mampu mempelajari karakteristik data pelatihan sekaligus mempertahankan kemampuan generalisasi terhadap data validasi. Selain itu, kurva Precision, Recall, dan mAP memperlihatkan tren peningkatan yang lebih stabil dibandingkan Model 1. Hasil ini menunjukkan bahwa augmentasi data berhasil memperkaya variasi sampel pelatihan sehingga model tidak hanya mempelajari karakteristik spesifik dari data asli, tetapi juga mampu mengenali pola penyakit pada berbagai variasi kondisi visual. Visualisasi train batch hasil pelatihan Model 2 ditunjukkan pada Gambar 4.



Sumber: (Hasil Penelitian, 2026)

Gambar 4. Train Batch Model 2

Berdasarkan Gambar 4, proses augmentasi menghasilkan variasi citra yang jauh lebih beragam dibandingkan Model 1. Teknik *Mosaic* menggabungkan empat citra menjadi satu bidang pelatihan sehingga memperkaya variasi posisi dan ukuran objek dalam satu gambar. Selain itu, transformasi HSV menghasilkan variasi intensitas warna dan pencahayaan, sedangkan transformasi geometris berupa *flipping*, *scaling*, dan *translation* menghasilkan perubahan orientasi, ukuran, dan posisi objek. Variasi tersebut mendorong model mempelajari karakteristik penyakit daun secara lebih umum sehingga tidak bergantung pada pola visual tertentu yang terdapat pada data pelatihan.

Secara keseluruhan, penerapan augmentasi data memberikan peningkatan kemampuan generalisasi model yang ditunjukkan oleh kurva pelatihan yang lebih stabil serta peningkatan nilai mAP50 sebesar 15,75 poin persentase, dari 61,95% pada Model 1 menjadi 77,70% pada Model 2. Meskipun waktu pelatihan menjadi lebih lama, peningkatan performa yang diperoleh menunjukkan bahwa augmentasi data efektif dalam meningkatkan ketahanan model terhadap variasi kondisi visual pada citra daun porang.

Evaluasi Kinerja Model pada Data Uji

Evaluasi akhir dilakukan menggunakan data uji independen yang tidak pernah dilibatkan selama proses pelatihan maupun validasi. Tahap ini

bertujuan untuk mengukur kemampuan generalisasi model terhadap data baru. Perbandingan kinerja antara Model 1 (tanpa augmentasi) dan Model 2 (dengan augmentasi) dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan Kinerja Model

No	Metrik Evaluasi	Model 1	Model 2
1	Precision	0.7298	0.8311
2	Recall	0.5839	0.7066
3	F1-Score	0.6342	0.7593
4	mAP50	0.6315	0.8053
5	mAP50-95	0.4209	0.5871

Sumber: (Hasil Penelitian, 2026)

Berdasarkan Tabel 3, penerapan augmentasi data memberikan peningkatan pada seluruh metrik evaluasi. Nilai Precision meningkat dari 72,98% menjadi 83,11%, sedangkan Recall meningkat dari 58,39% menjadi 70,66%. Peningkatan tersebut diikuti oleh kenaikan F1-Score dari 63,42% menjadi 75,93%, yang menunjukkan keseimbangan yang lebih baik antara kemampuan model dalam mendeteksi objek (Recall) dan ketepatan klasifikasi (Precision).

Selain itu, nilai mAP50 meningkat secara signifikan dari 63,15% menjadi 80,53%, sedangkan mAP50-95 meningkat dari 42,09% menjadi 58,71%, yang menunjukkan peningkatan kemampuan model dalam melakukan lokalisasi objek pada berbagai tingkat Intersection over Union (IoU). Peningkatan performa tersebut menunjukkan bahwa augmentasi data berhasil memperkaya variasi citra selama proses pelatihan sehingga model mampu mempelajari representasi fitur yang lebih beragam.

Variasi posisi objek, orientasi daun, ukuran objek, serta kondisi pencahayaan yang dihasilkan melalui teknik Mosaic, penyesuaian HSV, dan transformasi geometris membantu model menjadi lebih robust terhadap kondisi visual yang berbeda dibandingkan dengan model yang hanya dilatih menggunakan citra asli. Meskipun demikian, nilai Recall masih lebih rendah dibandingkan dengan Precision.

Kondisi ini menunjukkan bahwa model masih gagal mendeteksi sebagian objek penyakit (false negative), terutama pada objek dengan karakteristik visual yang kompleks atau kurang menonjol. Fenomena tersebut menunjukkan bahwa kemampuan menemukan seluruh objek penyakit masih menjadi tantangan, meskipun kemampuan klasifikasi terhadap objek yang berhasil terdeteksi sudah tergolong baik. Temuan ini selanjutnya dianalisis berdasarkan performa masing-masing kelas penyakit.

Analisis Karakteristik Deteksi Tiap Kelas


Untuk mengetahui kemampuan model dalam mendeteksi setiap jenis penyakit daun porang, dilakukan analisis berdasarkan nilai mAP50 pada masing-masing kelas. Hasil perbandingan performa Model 1 dan Model 2 dapat dilihat pada Tabel 4.

Tabel 4. Perbandingan mAP50 Tiap Kelas

No	Kelas	Model 1	Model 2
1	Early Blight	0.8204	0.9073
2	Healthy	0.7829	0.9034
3	Insect	0.2809	0.5280
4	Konjac Mosaic	0.5833	0.8114
5	Late Blight	0.6901	0.8764

Sumber: (Hasil Penelitian, 2026)

Berdasarkan Tabel 4, penerapan augmentasi data meningkatkan performa deteksi pada seluruh kelas penyakit. Kelas early blight, healthy, konjac mosaic, dan late blight memperoleh nilai mAP50 di atas 0,81, yang menunjukkan bahwa karakteristik visual pada keempat kelas tersebut relatif lebih konsisten sehingga lebih mudah dipelajari oleh model. Selain itu, peningkatan performa pada seluruh kelas menunjukkan bahwa augmentasi data berhasil meningkatkan kemampuan generalisasi model terhadap variasi kondisi visual selama proses pelatihan. Sebaliknya, kelas insect masih menghasilkan performa terendah meskipun mengalami peningkatan dari 0,2809 menjadi 0,5280. Untuk memahami penyebab rendahnya performa tersebut, dilakukan analisis menggunakan confusion matrix yang ditunjukkan pada Gambar 5.



Sumber: (Hasil Penelitian, 2026)

Gambar 5. Confusion Matrix Model 2

Berdasarkan Gambar 5, model berhasil mendeteksi 73 objek insect secara benar, sedangkan 57 objek masih diklasifikasikan sebagai background (false negative). Tingginya jumlah false negative tersebut menyebabkan nilai Recall kelas

insect menjadi lebih rendah dibandingkan kelas lainnya. Kondisi ini menunjukkan bahwa model masih gagal menemukan sebagian objek penyakit meskipun objek tersebut tersedia pada citra uji. Fenomena tersebut dipengaruhi oleh karakteristik visual kerusakan akibat serangga yang umumnya berupa lubang atau bagian daun yang hilang sehingga area anotasi masih mengandung tekstur latar belakang seperti tanah atau bayangan. Akibatnya, model tidak hanya mempelajari karakteristik kerusakan daun, tetapi juga mempelajari pola visual latar belakang (*background bias*). Kondisi ini menyebabkan sebagian objek gagal dikenali sebagai penyakit meskipun lokasi daun telah terdeteksi. Temuan tersebut menunjukkan bahwa kompleksitas visual objek masih menjadi salah satu tantangan utama pada deteksi penyakit daun berbasis object detection. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penggunaan metode instance segmentation agar objek daun dapat dipisahkan dari latar belakang secara lebih presisi sehingga *background bias* dapat diminimalkan.

KESIMPULAN

Penelitian ini telah berhasil mengimplementasikan arsitektur YOLOv8n dengan metode Stratified 5-Fold Cross-Validation untuk mendeteksi lima kondisi daun porang, yaitu early blight, late blight, konjac mosaic, insects, dan healthy. Hasil penelitian menunjukkan bahwa penerapan augmentasi data meningkatkan kinerja model dibandingkan dengan model tanpa augmentasi, dengan capaian mAP50 sebesar 80,53%, Precision sebesar 83,11%, dan Recall sebesar 70,66%. Selain itu, model memberikan performa yang sangat baik pada kelas *early blight*, *healthy*, *late blight*, dan *konjac mosaic*, sedangkan kelas *insects* masih memiliki performa terendah akibat *false negative* yang dipengaruhi oleh *background bias*. Hasil penelitian menunjukkan bahwa kombinasi YOLOv8n dan augmentasi data dapat meningkatkan kinerja deteksi penyakit daun porang dibandingkan dengan model tanpa augmentasi. Penelitian selanjutnya disarankan untuk mengurangi *background bias* pada kelas *insects* melalui penambahan variasi dataset atau penerapan *instance segmentation*.

REFERENSI

Ahmad Zaeni Dahlan, & Ghufroon Zaida Muflih. (2025). Implementasi Computer Vision untuk Deteksi Penyakit pada Tanaman Tomat Menggunakan Algoritma YOLOv8 (You Only Look Once). *Jurnal Ilmiah Sistem Informasi*

- Dan Ilmu Komputer*, 5(2), 104–117. <https://doi.org/10.55606/juisik.v5i2.1154>
- Ashwinkumar, S., Rajagopal, S., Manimaran, V., & Jegajothi, B. (2022). Automated plant leaf disease detection and classification using optimal MobileNet based convolutional neural networks. *Materials Today: Proceedings*, 51, 480–487. <https://doi.org/10.1016/j.matpr.2021.05.584>
- Badan Karantina Indonesia. (2023). *Perdana, Ekspor 25 Ton Serpih Porang Asal Bangka Belitung Tembus Pasar Tiongkok*. Badan Karantina Indonesia. <https://karantinaindonesia.go.id/detailberita/Perdana%2C-Ekspor-25-Ton-Serpih-Porang-Asal-Bangka-Belitung-Tembus-Pasar-Tiongkok?#>
- Choiriyah, S., & Supriyanto, A. (2025). Perbandingan Deep Learning YOLOv5 dan YOLOv8 Untuk Deteksi Penyakit Daun Tanaman Tomat. *JITSI : Jurnal Ilmiah Teknologi Sistem Informasi*, 6(1), 56–65. <https://doi.org/10.62527/jitsi.6.1.348>
- Daraghmi, Y.-A., Naser, W., Daraghmi, E. Y., & Fouchal, H. (2025). Drone-Assisted Plant Stress Detection Using Deep Learning: A Comparative Study of YOLOv8, RetinaNet, and Faster R-CNN. *AgriEngineering*, 7(8). <https://doi.org/10.3390/agriengineering7080257>
- Hassan, S. M., Amitab, K., Jasinski, M., Leonowicz, Z., Jasinska, E., Novak, T., & Maji, A. K. (2022). A Survey on Different Plant Diseases Detection Using Machine Learning Techniques. *Electronics*, 11(17). <https://doi.org/10.3390/electronics11172641>
- Majid, M. A. K., & Ariatmanto, D. (2025). Analisis Perbandingan Kinerja Model YOLO11 dan YOLOv8 dalam Identifikasi Penyakit pada Daun Tomat. *Jurnal Bangkit Indonesia*, 14(2), 63–72. <https://doi.org/10.52771/bangkitindonesia.v14i2.459>
- Nurhasanah, R., Fadhlillah, F., Zandrato, N., & Bangun, M. B. (2023). Application of Deep Learning for Mobile-Phased Detection of Leaf Diseases in *Amorphophallus Muelleri* Blume Using SSD-MobileNet. *2023 Eighth International Conference on Informatics and Computing (ICIC)*, 1–6. <https://doi.org/10.1109/ICIC60109.2023.10382110>
- Satria, B., Afrianto, N., Ningsih, L., Sakinah, P., Sidaauruk, A., & Mayola, L. (2025). Comparative Analysis of Weighted-KNN, Random Forest,

- and Support Vector Machine Models for Beef and Pork Image Classification Using Machine Learning. *JOIV: International Journal on Informatics Visualization*, 9(4), 1677. <https://doi.org/10.62527/joiv.9.4.3736>
- Soedarjo, M., & Djufry, F. (2021). Identified diseases would threaten on the expansion of *Amorphophallus muelleri* Blume cultivation in Indonesia. *IOP Conference Series: Earth and Environmental Science*, 648(1), 012043. <https://doi.org/10.1088/1755-1315/648/1/012043>
- Szeghalmy, S., & Fazekas, A. (2023). A Comparative Study of the Use of Stratified Cross-Validation and Distribution-Balanced Stratified Cross-Validation in Imbalanced Learning. *Sensors*, 23(4), 2333. <https://doi.org/10.3390/s23042333>
- Terven, J., Córdova-Esparza, D.-M., & Romero-González, J.-A. (2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*, 5(4), 1680–1716. <https://doi.org/10.3390/make5040083>
- Tsaqib Marwan, F. A., & Rimantho, D. (2022). Applying Image Classification for Detect Leaf Disease: Case Study for Porang Plant. *2022 International Conference on ICT for Smart Society (ICISS)*, 1–5. <https://doi.org/10.1109/ICISS55894.2022.9915203>
- Wang, H., Shang, S., Wang, D., He, X., Feng, K., & Zhu, H. (2022). Plant Disease Detection and Classification Method Based on the Optimized Lightweight YOLOv5 Model. *Agriculture*, 12(7). <https://doi.org/10.3390/agriculture12070931>
- Wang, Y., Wang, Y., & Zhao, J. (2022). MGA-YOLO: A lightweight one-stage network for apple leaf disease detection. *Frontiers in Plant Science*, Volume 13-2022. <https://doi.org/10.3389/fpls.2022.927424>
- Zuhan, M., & Kristian, Y. (2023). Detection of Porang Plant Diseases and Pests (*Amorphophallus muelleri*) Based on Leaf Imagery Utilizing DCNN Transfer Learning. *JTECS: Jurnal Sistem Telekomunikasi Elektronika Sistem Kontrol Power Sistem Dan Komputer*, 3(2), 129. <https://doi.org/10.32503/jtecs.v3i2.3709>