

PENERAPAN BAYESIAN-OPTIMIZED DEEP LEARNING FRAMEWORK BERBASIS YOLOV8 DAN OPTUNA UNTUK DETEKSI MULTIKELAS PENYAKIT KAKAO

I Putu Oka Wisnawa[✉], Putu Manik Prihatini, Ni Gusti Ayu Putu Harry Saptarini,
I Made Dwi Jendra Sulastra, Ni Luh Putu Listya Dewi

Politeknik Negeri Bali, Badung, Indonesia

Email: okawisnawa@pnb.ac.id

DOI: <https://doi.org/10.46880/jmika.Vol10No1.pp326-343>

ABSTRACT

Anthracnose and Black Pod Rot are the primary fungal threats to Theobroma cacao L., causing yield losses of up to 44% globally, yet in-field detection is challenged by canopy illumination variability and the spectral similarity of lesions measuring 2–8 mm. A lightweight object detection framework combining YOLOv8 Nano (yolov8n.pt) with Optuna's Tree-structured Parzen Estimator (TPE) was developed to classify Anthracnose, Black Pod Rot, and Healthy Cocoa Pod simultaneously. Two scenarios were evaluated on 780 augmented images: Scenario 1 using NopPruner (Standard Bayesian) and Scenario 2 using HyperbandPruner, over 100 trials at 50 epochs per trial. The Bayesian scenario recorded mAP50 of 0.9840, mAP50-95 of 0.8932, and Macro Recall of 1.0000 on independent test data, at 7.60 ms/image. The Hyperband scenario achieved mAP50 of 0.9913 and mAP50-95 of 0.8945, reducing GPU workload by 44.40% by executing only 2,780 of 5,000 theoretical epochs—compressing optimization duration from 6 hours 51 minutes to 3 hours 45 minutes. With a negligible mAP50-95 gap of 0.0013 between scenarios, the proposed framework demonstrates deployability on mobile and edge devices for real-time cocoa disease monitoring in precision agriculture.

Keyword: Cocoa Diseases, Hyperparameter Optimization, Object Detection, Precision Agriculture, YOLOv8.

ABSTRAK

Penyakit Anthracnose dan Black Pod Rot pada buah Theobroma cacao L. menyebabkan kehilangan hasil panen hingga 44% secara global, dengan deteksi lapangan terhambat oleh fluktuasi pencahayaan kanopi dan kemiripan morfologi lesi berukuran 2–8 mm. Kerangka kerja deep learning berbasis YOLOv8 Nano (yolov8n.pt) dikembangkan dan dioptimasi secara otomatis menggunakan Optuna melalui algoritma Tree-structured Parzen Estimator (TPE). Dua skenario komparatif diimplementasikan pada dataset 780 citra untuk tiga kelas deteksi: Anthracnose, Black Pod Rot, dan Healthy Cocoa Pod—Skenario 1 menerapkan NopPruner (Standard Bayesian) dan Skenario 2 menerapkan HyperbandPruner, masing-masing dengan 100 trial dan 50 epoch per trial. Skenario Bayesian mencatatkan mAP50 sebesar 0,9840, mAP50-95 sebesar 0,8932, dan Recall Makro 1,0000 pada data uji independen, dengan latensi inferensi 7,60 ms/citra. Skenario Hyperband mencapai mAP50 sebesar 0,9913 dan mAP50-95 sebesar 0,8945, sekaligus memangkas 44,40% beban komputasi GPU dengan hanya mengeksekusi 2.780 dari 5.000 epoch teoritis, mereduksi durasi optimasi dari 6 jam 51 menit menjadi 3 jam 45 menit. Selisih mAP50-95 antar skenario hanya 0,0013, mengonfirmasi kelayakan implementasi YOLOv8 Nano pada perangkat bergerak untuk mendukung sistem deteksi penyakit kakao berbasis pertanian presisi secara real-time.

Kata Kunci: Deteksi Objek, Optimasi Hiperparameter, Penyakit Kakao, Pertanian Presisi, YOLOv8.

PENDAHULUAN

Theobroma cacao L. merupakan komoditas perkebunan yang memiliki nilai strategis bagi perekonomian nasional. Indonesia menduduki posisi ketiga sebagai produsen kakao terbesar di dunia, dengan Kabupaten Jembrana, Bali, sebagai salah satu sentra produksi utamanya. Namun, produktivitas kakao nasional mengalami penurunan signifikan sejak 2015 hingga terdegradasi ke posisi ketujuh global.

Penurunan ini diakibatkan oleh praktik budidaya yang suboptimal dan prevalensi serangan patogen yang tidak terkendali. Di antara berbagai ancaman biotik, *Anthracnose* yang disebabkan oleh *Colletotrichum gloeosporioides* dan *Black Pod Rot* (Busuk Buah) yang disebabkan oleh *Phytophthora palmivora* merupakan patogen paling destruktif, dengan intensitas serangan mencapai 30 – 50% di berbagai wilayah Indonesia. Tanpa mekanisme deteksi dini yang akurat, kehilangan

hasil panen dapat mencapai 44% secara global. Kondisi ini mengancam keberlanjutan ekonomi petani dan ketahanan pangan nasional secara langsung. Oleh karena itu, adopsi teknologi precision agriculture melalui sistem deteksi dini penyakit menjadi keharusan untuk memfasilitasi intervensi manajemen yang tepat waktu dan memitigasi kerugian yang lebih luas (Sykes et al., 2023).

Deteksi penyakit kakao secara visual di lapangan menghadapi tantangan agroekologis yang kompleks. Variasi pencahayaan di bawah kanopi pohon pelindung, oklusi daun kering, dan heterogenitas latar belakang tanah perkebunan secara konsisten menurunkan akurasi pengamatan manual. Tantangan ini diperparah oleh kemiripan karakteristik visual antara gejala *Anthracnose* dan *Black Pod Rot* (Busuk Buah). Kedua penyakit ini sama-sama menghasilkan lesi awal berukuran 2 – 8 mm pada permukaan buah dengan gradasi warna cokelat kehitaman yang sulit dibedakan secara kasat mata, terutama pada tahap infeksi dini. Kondisi agroekosistem yang dinamis ini menuntut sistem deteksi berbasis komputasi yang mampu beradaptasi terhadap variabilitas visual yang tinggi di lahan produksi sesungguhnya (Gao et al., 2024).

Paradigma deteksi penyakit tanaman berbasis deep learning telah bergeser dari model *Convolutional Neural Networks* (CNN) konvensional menuju

arsitektur deteksi objek *real-time* berbasis *You Only Look Once* (YOLO). Studi terdahulu melaporkan bahwa implementasi YOLOv5 dan YOLOv6 mampu meningkatkan akurasi deteksi *Anthracnose* sebesar 5,4% dibandingkan model baseline, dengan tingkat presisi mencapai 86,5 – 86,8% pada kondisi lapangan. YOLOv8 selanjutnya mendemonstrasikan performa yang lebih unggul dalam deteksi penyakit multikelas dengan perolehan mean *Average Precision* (mAP) hingga 98% dan F1-score 97% pada berbagai spesies tanaman (Chen et al., 2022). Kendati demikian, implementasi arsitektur ini pada domain pertanian masih menghadapi kendala fundamental: optimasi hyperparameter yang tidak dilakukan secara sistematis. Tanpa pendekatan optimasi terukur, model cenderung kurang mampu menggeneralisasi variabilitas visual yang kompleks di lahan produksi, sehingga efektivitas mitigasi penyakit pada skala agrikultur industri menjadi terbatas secara kritis (Singh et al., 2025).

Kesenjangan metodologis ini tergambar jelas dalam peta penelitian terdahulu yang dirangkum pada Tabel 1. Sebagian besar studi mengandalkan arsitektur YOLO generasi sebelumnya tanpa prosedur *Hyperparameter Optimization* (HPO) yang sistematis, atau mengimplementasikan metode optimasi konvensional yang terbukti tidak efisien secara komputasi.

Tabel 1. Perbandingan Penelitian Terdahulu (*State-of-the-Art*)

Peneliti & Tahun	Metode yang Digunakan	Objek / Komoditas	Keterbatasan / Gap Penelitian
Chen et al. (2022)	YOLOv5 (modifikasi arsitektur)	Penyakit daun multispesies	Tanpa HPO sistematis; performa bergantung pada konfigurasi manual yang rentan sub-optimal
Gomez et al. (2024)	YOLOv8 (baseline)	<i>Phaseolus vulgaris</i> (Common Bean) - <i>Anthracnose</i>	Akurasi 90%; generalisasi pada kondisi real-field yang heterogen belum divalidasi secara ketat
Noon et al. (2024)	Model CNN yang ditingkatkan	Penyakit daun tanaman dan buah (real-field)	Tidak mengintegrasikan kerangka HPO otomatis; optimasi dilakukan secara manual
Utomo et al. (2025)	EfficientNetV2 + HPO (Optuna)	Penyakit daun <i>Oryza sativa</i> (Padi)	Terbatas pada klasifikasi daun; tidak dapat diaplikasikan untuk deteksi objek buah secara spasial
Singh et al. (2025)	CNN + Whale Optimization Algorithm	Penyakit daun <i>Solanum lycopersicum</i> (Tomat)	Algoritma optimasi non-standar; skalabilitas dan replikabilitas pada komoditas lain belum diuji
Agila & Harin Fernandez (2025)	YOLOv8 (anchor-free)	Tanaman kacang (Bean Crops), penghitungan daun	Tidak menerapkan HPO; fokus pada penghitungan daun, bukan deteksi penyakit multikelas
Penelitian Ini	YOLOv8n + Optuna (Bayesian vs. Hyperband HPO)	<i>Theobroma cacao</i> L. (<i>Anthracnose</i>), <i>Black Pod Rot</i> (Busuk Buah), <i>Healthy Cocoa Pod</i>	Mengisi celah: HPO sistematis berbasis Optuna pada YOLOv8 untuk deteksi penyakit buah kakao multikelas; membandingkan efisiensi Bayesian standard dan Hyperband pruning

Dari Tabel 1., tampak bahwa tidak ada satu pun studi terdahulu yang secara eksplisit menggabungkan arsitektur YOLOv8 dengan kerangka HPO otomatis berbasis Optuna untuk deteksi multikelas penyakit pada buah kakao. Celah riset ini merupakan justifikasi utama bagi usulan metodologi dalam penelitian ini.

Penelitian ini mengusulkan pengembangan *Bayesian-Optimized Deep Learning Framework* yang mengintegrasikan arsitektur YOLOv8n dengan metode optimasi Bayesian melalui Optuna untuk deteksi multikelas penyakit pada buah *Theobroma cacao L.*, mencakup kelas *Anthracnose*, *Black Pod Rot* (Busuk Buah), dan *Healthy Cocoa Pod*. Kontribusi utama penelitian ini bersifat tiga lapis. Secara arsitektural, mekanisme deteksi *anchor-free* pada YOLOv8 memberikan keunggulan dalam menangani variasi morfologi buah kakao (3 – 20 cm) dan mendeteksi lesi berukuran 2 – 8 mm secara lebih akurat dibandingkan model berbasis anchor seperti YOLOv5 dan YOLOv6 (Gao et al., 2024). Secara metodologis, penerapan HPO sistematis melalui Optuna, dengan perbandingan antara strategi standard *Bayesian* dan *Hyperband pruning*, secara efektif memitigasi inefisiensi dan sub-optimalitas yang diakibatkan oleh optimasi manual (Bischl et al., 2023a). Secara praktis, kerangka kerja yang dihasilkan berpotensi diadopsi sebagai sistem peringatan dini untuk intervensi manajemen responsif guna meminimalkan penurunan hasil panen dan mendukung keberlanjutan ekonomi perkebunan kakao (Sykes et al., 2023).

KAJIAN LITERATUR

Deteksi Penyakit Tanaman Berbasis Deep Learning

Paradigma deteksi penyakit tanaman berbasis deep learning telah bergeser dari metode klasifikasi berbasis *Convolutional Neural Networks* (CNN) konvensional seperti VGG, ResNet, dan EfficientNet menuju arsitektur *real-time object detection* yang lebih lanjut seperti *You Only Look Once* (YOLO). Studi terdahulu yang mengandalkan model klasifikasi *single-class* secara inheren membatasi kapasitas sistem dalam mengidentifikasi berbagai gejala patogen secara simultan dalam satu cakupan citra. Keterbatasan metodologis ini menjadikan pendekatan tersebut kurang efektif untuk implementasi *in-field*, di mana kompleksitas agroekosistem sering kali menyebabkan munculnya infeksi ganda atau gejala heterogen pada organ tanaman yang sama. Oleh karena itu, transisi menuju sistem deteksi yang mampu mengenali entitas patogen secara presisi dan spasial menjadi krusial guna memfasilitasi diagnosis dini yang akurat dalam mendukung mitigasi penyakit yang komprehensif (Soekarta et al., 2023).

Arsitektur *You Only Look Once* (YOLO) memfasilitasi deteksi objek real-time melalui inferensi tunggal, meningkatkan efisiensi komputasi secara signifikan pada analisis visual. Iterasi YOLOv5 dan YOLOv6 telah mendemonstrasikan peningkatan akurasi sebesar 5,4% dibandingkan model baseline pada deteksi *Anthracnose* dan *powdery mildew*, dengan presisi berkisar antara 86,5% hingga 86,8% pada kondisi lapangan. Lebih lanjut, pengembangan arsitektur YOLOv8 mencatatkan mean *Average Precision* (mAP) sebesar 98% dan F1-score 97%, menegaskan keunggulan performa model dalam deteksi penyakit daun multikelas. Efikasi ini ditunjang oleh integrasi backbone yang lebih efisien, mekanisme *anchor-free detection*, serta *enhanced feature aggregation* yang secara sistematis memitigasi false positive pada citra dengan latar belakang kompleks, sebuah prasyarat fundamental untuk mengoptimalkan ketajaman diagnostik sistem peringatan dini penyakit tanaman di lingkungan lahan yang dinamis (Abid et al., 2024).

Meskipun arsitektur YOLOv8 menunjukkan performa deteksi yang unggul, efektivitasnya dalam lingkungan pertanian yang tidak terkendali (*unconstrained*) dibandingkan dengan kondisi laboratorium tetap menjadi subjek diskusi ilmiah yang krusial. Literatur menunjukkan bahwa penerapan YOLOv7, YOLOv8, dan YOLO-NAS pada dataset *real-field Phaseolus vulgaris* (*common bean*) dari Afrika dan Kolombia mampu mencapai akurasi sebesar 90% dalam mendeteksi *Anthracnose*; namun, hasil ini masih rentan terhadap degradasi performa akibat variabilitas iluminasi, oklusi daun, dan heterogenitas latar belakang tanah. Senada dengan hal tersebut, studi mengenai deteksi penyakit daun menggunakan YOLOv6s pada kondisi lapangan menegaskan bahwa optimasi model untuk melakukan *feature disentanglement* dari latar belakang pertanian yang kompleks tetap merupakan *critical research gap* yang belum terpecahkan secara memadai. Keterbatasan persistensi ini menggarisbawahi urgensi pengembangan framework yang lebih *robust* untuk mempertahankan fidelitas inferensi yang tinggi di tengah kondisi lingkungan agraris yang dinamis (Noon et al., 2024).

Implementasi arsitektur YOLOv8 tanpa prosedur optimasi hyperparameter sistematis cenderung menunjukkan performa yang sub-optimal ketika dihadapkan pada variabilitas citra *in-field*. Sebagian besar metrik akurasi yang dilaporkan dalam literatur saat ini berbasis pada dataset dengan kondisi lingkungan terkontrol, sehingga kemampuan generalisasi model terhadap variasi kondisi lapangan

yang heterogen masih memerlukan validasi empiris lebih lanjut. Keterbatasan ini menjadi penghambat utama dalam transisi menuju sistem deteksi penyakit yang tangguh, sehingga menuntut pengembangan kerangka kerja optimasi yang lebih adaptif untuk mitigasi penyakit Antraknosa dan Busuk Buah pada *Theobroma cacao* secara *real-time* (Gomez et al., 2024; Noon et al., 2024).

Peran Hyperparameter Optimization (Optuna) dalam Deep Learning

Optimasi hyperparameter (HPO) merupakan determinan utama dalam memastikan efikasi model deep learning pada domain pertanian yang memiliki tingkat variabilitas data tinggi. Bukti empiris menegaskan bahwa performa arsitektur Convolutional Neural Networks (CNN) sangat dipengaruhi oleh konfigurasi hyperparameter krusial, seperti learning rate, densitas unit hidden layer, dropout rates, dan dimensi filter. Namun, teknik optimasi konvensional termasuk penyesuaian manual, grid search, dan random search sering kali terkendala oleh inefisiensi komputasi dan keterbatasan skalabilitas. Ketergantungan pada prosedur iteratif berbasis trial-and-error yang bersifat heuristik cenderung menghasilkan konfigurasi sub-optimal, sehingga membatasi kemampuan generalisasi model terhadap kompleksitas fitur pada citra lapangan. Oleh karena itu, adopsi mekanisme optimasi yang sistematis menjadi imperatif untuk mencapai keseimbangan antara akurasi deteksi dan efisiensi inferensi dalam kerangka kerja pertanian presisi yang mampu beroperasi secara real-time (Bischl et al., 2023b; Singh et al., 2025)

Optimasi Bayesian, yang diimplementasikan melalui kerangka kerja Optuna, menyajikan mekanisme pencarian ruang parameter yang lebih efisien secara matematis dibandingkan dengan metode pencarian konvensional. Dengan memanfaatkan *Tree-structured Parzen Estimator* (TPE), algoritma ini memodelkan distribusi hyperparameter secara probabilistik dan secara adaptif merekomendasikan konfigurasi optimal berikutnya berdasarkan riwayat evaluasi (*evaluation history*), sehingga meminimalkan jumlah iterasi eksperimental yang diperlukan untuk mencapai konvergensi model (Bischl et al., 2023; Utomo et al., 2025). Secara matematis, algoritma TPE dalam optimasi Bayesian bekerja dengan membalikkan probabilitas bersyarat $P(y|x)$ menggunakan Teorema Bayes menjadi $P(x|y)$, di mana x melambangkan konfigurasi hyperparameter dan y melambangkan nilai metrik evaluasi (mAP50-95). Fungsi densitas probabilitas dari konfigurasi hyperparameter tersebut

dimodelkan berdasarkan ambang batas kuantil γ seperti ditunjukkan pada Persamaan (1):

$$P(x \vee y) = \begin{cases} \ell(x) & \text{jika } y < \gamma \\ g(x) & \text{jika } y \geq \gamma \end{cases}$$

di mana $\ell(x)$ melambangkan distribusi probabilitas dari himpunan hiperparameter yang menghasilkan nilai fungsi tujuan yang superior (di atas ambang batas kuantil γ), sedangkan $g(x)$ merupakan distribusi probabilitas dari kelompok hiperparameter yang menghasilkan performa suboptimal. Berdasarkan kedua pembagian distribusi tersebut, ruang pencarian dieksplorasi secara dinamis dengan memaksimalkan metrik Expected Improvement (EI) yang dirumuskan pada Persamaan (2):

$$EI(x) = \int_{-\infty}^{\gamma} (\gamma - y) P(y \vee x) dy = \frac{\gamma \ell(x) - \ell(x) \int_{-\infty}^{\gamma} P(y) dy}{\gamma \ell(x) + (1 - \gamma) g(x)}$$

Melalui manipulasi aljabar, maksimisasi nilai Expected Improvement pada Persamaan (2) terbukti berbanding lurus dengan maksimisasi rasio spasial antar kedua fungsi densitas probabilitas tersebut, yang diformulasikan melalui Persamaan (3):

$$\max EI(x) \equiv \frac{\ell(x)}{g(x)}$$

Melalui simplifikasi matematis pada Persamaan (3), Optuna secara efisien menentukan kandidat hiperparameter baru pada setiap iterasi dengan cara memprioritaskan area ruang pencarian yang memaksimalkan nilai $\ell(x)$ sekaligus meminimalkan probabilitas kemunculan nilai $g(x)$.

Efektivitas pendekatan ini terkonfirmasi dalam klasifikasi penyakit pada rice leaf (penyakit daun padi) menggunakan arsitektur EfficientNetV2, di mana optimasi hyperparameter sistematis memberikan peningkatan kinerja yang signifikan, dengan mencapai akurasi sebesar 99% serta nilai precision, recall, dan F-score pada rentang 0,97 – 1,00; jauh melampaui performa model baseline tanpa optimasi. Mengingat variabilitas data pada sektor pertanian yang kompleks, integrasi kerangka kerja optimasi ini menjadi krusial untuk menjamin robustabilitas model dalam mengidentifikasi patogen tanaman secara akurat dan efisien pada skala operasional (Bischl et al., 2023a; Utomo et al., 2025).

Dalam konteks efisiensi operasional tersebut, kerangka kerja Optuna menyediakan opsi arsitektur yang mengintegrasikan algoritma *Hyperband*, sebagai bentuk implementasi dari *Bayesian Optimization HyperBand* (BOHB), untuk mengeksekusi mekanisme pemangkasan dini (*early pruning*). Mekanisme ini secara adaptif menghentikan proses pelatihan (*training*) pada konfigurasi hiperparameter yang menunjukkan performa buruk, sehingga mampu menghemat sumber daya komputasi secara signifikan saat menangani karakteristik dataset pertanian yang kompleks. Alokasi komputasi yang efisien tersebut dicapai melalui penggunaan *Successive Halving Algorithm* (SHA) yang secara iteratif menyaring jumlah konfigurasi yang dievaluasi dalam beberapa tahapan (*rounds*). Pada tahapan awal, seluruh kandidat konfigurasi diuji dalam jumlah epoch yang minimal (misalnya 5 epoch), kemudian hanya 50% konfigurasi dengan performa teratas yang diizinkan berlanjut ke tahapan berikutnya dengan volume epoch yang ditingkatkan secara bertahap hingga konfigurasi paling optimal ditemukan. Pendekatan ini secara fundamental berbeda dari metode konvensional seperti *Grid Search* atau *Random Search* yang diwajibkan menyelesaikan seluruh proses pelatihan untuk setiap konfigurasi tanpa adanya sistem pemangkasan, di mana prosedur konvensional tersebut terbukti memerlukan waktu komputasi 2 hingga 3 kali lebih lama pada pemrosesan dataset berskala besar (Bischl et al., 2023).

Identifikasi Penyakit Kakao dan Tantangannya

Theobroma cacao L. merupakan komoditas strategis yang produksinya rentan terhadap infeksi patogen jamur, terutama *Anthracoze* yang disebabkan oleh *Colletotrichum spp.* serta *Black Pod Rot* yang diinduksi oleh *Phytophthora spp.* Metode diagnostik konvensional saat ini sering kali terkendala oleh keterbatasan skalabilitas dan subjektivitas interpretasi, yang berimplikasi pada inefisiensi operasional di lapangan. Integrasi sistem computer vision dalam patologi tanaman menawarkan paradigma baru untuk mengatasi kendala tersebut dengan memitigasi ketergantungan pada tenaga kerja ahli, meminimalisir kesalahan diagnostik, serta mencegah aplikasi pestisida yang berlebihan. Praktik penggunaan pestisida yang tidak tepat tidak hanya meningkatkan biaya operasional secara signifikan, tetapi juga memicu risiko resistensi pestisida yang merugikan. Oleh karena itu, pengembangan kerangka kerja diagnostik otomatis yang akurat menjadi prasyarat krusial untuk menjamin stabilitas hasil panen dan keberlanjutan ekonomi pada sektor perkebunan kakao (Sykes et al., 2023).

Tinjauan komprehensif mengenai penerapan computer vision pada budidaya kakao (*Theobroma cacao* L.) mengindikasikan bahwa adaptasi metode standar untuk deteksi patogen memerlukan teknik akuisisi citra yang adaptif guna memitigasi variabilitas kondisi lingkungan lapangan. Signifikansi urgensi ini dipertegas oleh potensi reduksi hasil panen akibat infeksi simultan *Anthracoze* dan *Black Pod Rot*, yang dapat mencapai 30–50% tanpa intervensi preventif yang memadai. Oleh karena itu, pengembangan sistem deteksi dini yang presisi merupakan langkah krusial dalam menjamin ketahanan pangan sekaligus menjaga keberlanjutan ekonomi sektor agrikultur (Logeshwaran et al., 2024; Sykes et al., 2023).

Meskipun metode deep learning telah menunjukkan progresivitas dalam deteksi patogen tanaman, model yang ada saat ini untuk komoditas kakao (*Theobroma cacao* L.) masih menunjukkan keterbatasan fungsional yang signifikan. Studi komparatif pada *Solanum lycopersicum* L. yang mengimplementasikan arsitektur Convolutional Neural Network (CNN) mengonfirmasi bahwa diagnosis manual oleh praktisi agrikultur sering kali rentan terhadap misklasifikasi, sehingga integrasi sistem deteksi otomatis diperlukan untuk menjamin konsistensi dan akurasi diagnostik. Namun, penerapan visi komputer pada patologi tanaman kakao menuntut pertimbangan teknis yang lebih kompleks terutama dalam membedakan variabilitas gejala patogen seperti *Phytophthora palmivora* (Busuk Buah) dan *Colletotrichum gloeosporioides* (*Antraknosa*) yang sering kali belum terakomodasi secara optimal dalam arsitektur model standar. Oleh karena itu, pengembangan kerangka kerja yang tidak hanya memanfaatkan arsitektur mutakhir, tetapi juga menerapkan optimasi sistematis untuk mengatasi heterogenitas data lapangan, menjadi sangat krusial guna memitigasi kehilangan hasil panen yang lebih masif (Soekarta et al., 2023; Sykes et al., 2023).

METODE PENELITIAN

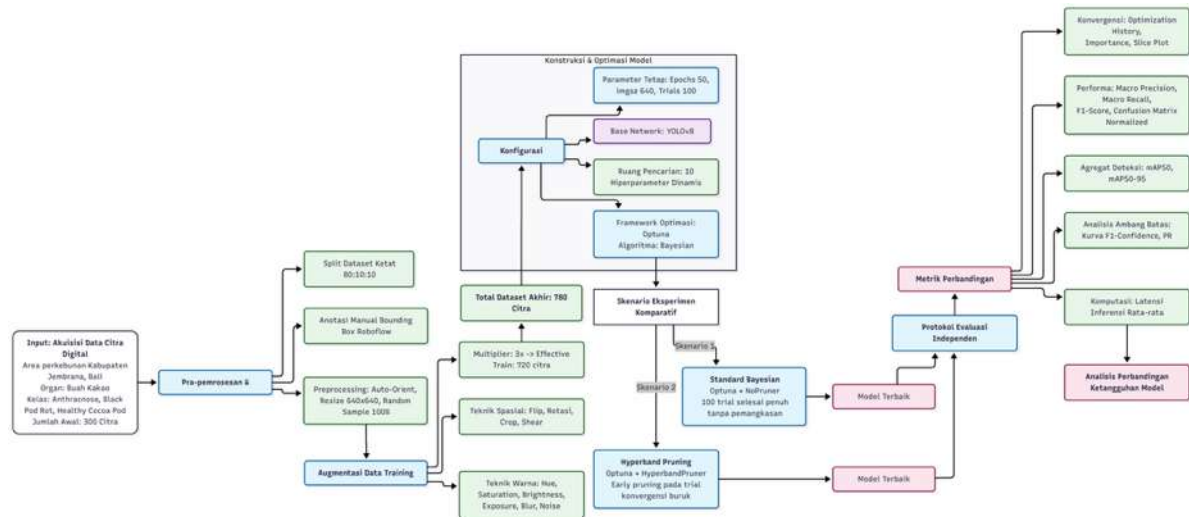
Alur Penelitian

Penelitian ini merupakan jenis Penelitian Pengembangan Eksperimental (*Experimental Development Research*) yang difokuskan pada pembangunan, integrasi, dan pengujian kerangka kerja komputasi berbasis deep learning untuk deteksi penyakit tanaman kakao secara multikelas. Data citra digital diakuisisi dari area perkebunan kakao yang berlokasi di Kabupaten Jembrana, Provinsi Bali. Pengumpulan data diarahkan pada organ buah kakao (*cocoa pod*) untuk mengenali tiga kelas kondisi, yaitu *Anthracoze*, *Black Pod Rot* (*Busuk Buah*), dan

Healthy Cocoa Pod (Kakao Sehat). Distribusi data antar kelas dikondisikan relatif seimbang guna meminimalkan risiko bias klasifikasi (class imbalance) selama proses pelatihan berlangsung.

Secara keseluruhan, penelitian ini menjalankan dua skenario eksperimen yang bersifat komparatif dan paralel, yaitu: (1) optimasi hiperparameter YOLOv8 Nano menggunakan algoritma Bayesian berbasis Optuna dengan strategi NopPruner (Standard

Bayesian), dan (2) optimasi hiperparameter YOLOv8 Nano menggunakan algoritma Bayesian berbasis Optuna yang diperkuat dengan mekanisme pemangkasan trial Hyperband (Hyperband Pruning). Kedua skenario menggunakan dataset, ruang pencarian hiperparameter, dan protokol evaluasi yang identik sehingga perbandingan yang dihasilkan bersifat adil dan terukur secara empiris. Alur umum penelitian disajikan pada Gambar 1.



Gambar 1. Alur Penelitian Deteksi Multikelas Penyakit Kakao berbasis YOLOv8 dan Optuna

Akuisisi dan Pra-Pemrosesan Data

Sebanyak 300 citra digital buah kakao diakuisisi secara langsung di lapangan. Dataset tersebut dibagi secara ketat menjadi tiga bagian independen dengan rasio 80:10:10, yakni training set sebanyak 240 citra, validation set sebanyak 30 citra, dan testing set sebanyak 30 citra. Pembagian ini ditujukan untuk menjamin objektivitas evaluasi kemampuan generalisasi model pada data yang belum pernah terlihat selama fase pelatihan.

Pelabelan objek dilaksanakan pada platform *Roboflow* menggunakan teknik anotasi kotak pembatas (*bounding box*) secara manual, tanpa bantuan fitur pemilihan cerdas otomatis (*smart select*). Pendekatan manual dipilih untuk menjamin keakuratan koordinat piksel pada area patologi tanaman, terutama pada kondisi oklusi alami di lapangan, seperti tumpang tindih daun atau ranting yang kerap menutupi lesi *Anthraco*se dan *Black Pod Rot* berukuran kecil.

Tiga tahap pra-pemrosesan diterapkan pada seluruh subset dataset sebelum digunakan dalam pelatihan model:

1. *Auto Orient*: Orientasi seluruh citra distandarkan secara otomatis untuk mengeliminasi perbedaan

rotasi yang disebabkan oleh metadata perangkat kamera.

2. *Resize* (640 × 640 piksel): Resolusi citra disesuaikan menjadi 640 × 640 piksel agar selaras dengan spesifikasi input arsitektur YOLOv8 tanpa mengorbankan fitur morfologi penting pada lesi *Anthraco*se dan *Black Pod Rot*.
3. *Random Sample*: Seluruh subset (train, val, test) disertakan 100% tanpa pengurangan sampel sehingga tidak ada informasi yang terbuang pada proses pembangunan dataset.

Augmentasi data hanya diterapkan pada training set guna mencegah kebocoran data (*data leakage*). Validation set dan testing set dikunci pada kondisi citra asli (1×) untuk menjaga objektivitas evaluasi. Augmentation Multiplier yang digunakan adalah 3×, sehingga jumlah data latih efektif menjadi 240 × 3 = 720 citra. Total dataset akhir yang digunakan dalam penelitian dihitung berdasarkan persamaan berikut:

$$\begin{aligned} \text{Total Citra Akhir} &= (\text{Train times } M) + \text{Val} + \text{Test} \\ &= (240 \text{ times } 3) + 30 + 30 \\ &= 780 \text{ citra} \end{aligned}$$

Teknik augmentasi yang diterapkan terbagi dalam dua kategori:

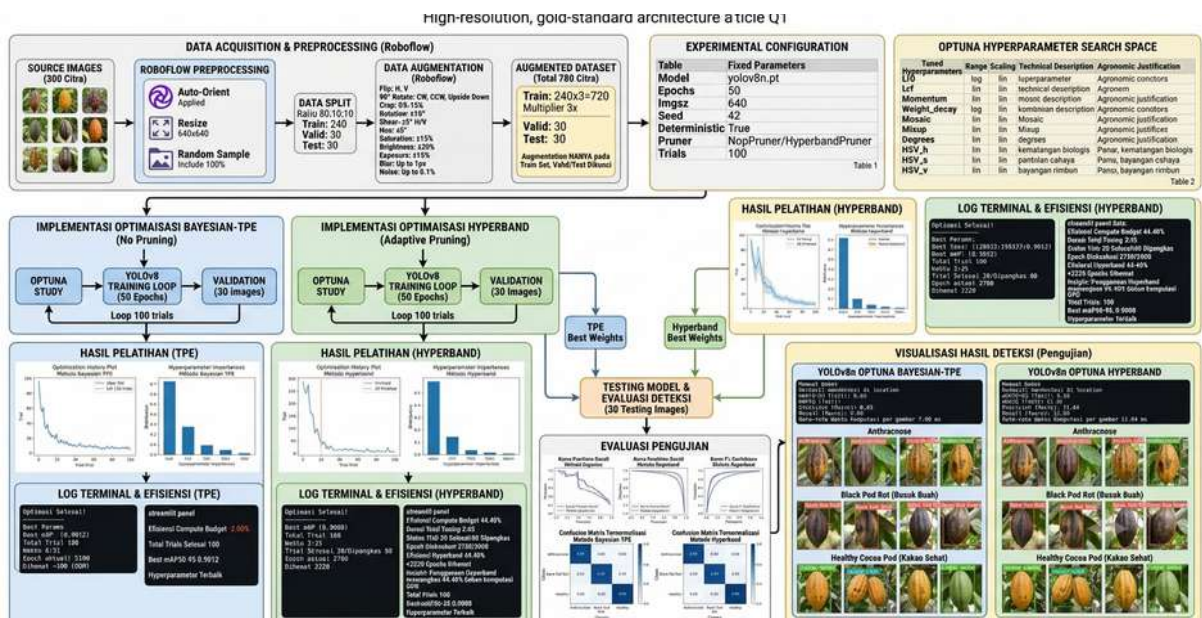
1. Augmentasi Spasial, yang terdiri dari:

- a. *Flip*: Pembalikan citra secara horizontal dan vertikal untuk menyimulasikan variasi orientasi pengambilan gambar di lapangan.
 - b. Rotasi statis 90°: Searah jarum jam (*Clockwise*), berlawanan jarum jam (*Counter-Clockwise*), dan terbalik (*Upside Down*).
 - c. *Crop* (0–15% zoom): Pemotongan acak untuk melatih model mengenali objek pada berbagai tingkat jarak kamera, khususnya lesi patologi berukuran kecil.
 - d. Rotasi dinamis acak (−15° hingga +15°): Menyimulasikan pengambilan gambar dari sudut miring di area perkebunan.
 - e. *Shear* (±5° horizontal dan ±5° vertikal): Menyimulasikan distorsi perspektif yang terjadi saat kamera tidak tegak lurus terhadap permukaan buah.
2. Augmentasi Warna (Spektral), yang terdiri dari:
 - a. *Hue* (±5°): Pergeseran warna dasar untuk menyimulasikan variasi tingkat kematangan biologis buah kakao.
 - b. *Saturation* (±15%): Variasi kejenuhan warna untuk menyimulasikan pantulan cahaya pasca-hujan atau debu daun.
 - c. *Brightness* (±20%): Variasi kecerahan untuk menyimulasikan fluktuasi intensitas cahaya matahari di bawah kanopi perkebunan.
 - d. *Exposure* (±15%): Variasi eksposur untuk meningkatkan ketangguhan model terhadap

- kondisi pencahayaan yang berbeda-beda di lapangan.
- e. *Blur* (hingga 1 piksel): Menyimulasikan efek gerak kamera atau kurangnya fokus pada saat pengambilan gambar.
- f. *Noise* (hingga 0,1% piksel): Menyimulasikan gangguan sensor kamera yang umum terjadi pada kondisi lapangan.

Arsitektur Model dan Optimasi Hiperparameter

Arsitektur YOLOv8 Nano (yolov8n.pt) dipilih sebagai model deteksi objek dasar (base network) karena menawarkan keseimbangan optimal antara kecepatan inferensi dan akurasi deteksi objek secara real-time, sekaligus kompatibel dengan komputasi ringan pada perangkat bergerak. Konfigurasi hiperparameter bawaan (default) dari model ini sering menghasilkan performa suboptimal apabila dihadapkan pada karakteristik dataset patologi lokal yang spesifik, seperti variabilitas morfologi lesi Anthracnose berukuran 2 – 8 mm atau perubahan warna kulit buah pada tahap awal infeksi Black Pod Rot. Oleh karena itu, proses optimasi otomatis diintegrasikan menggunakan kerangka kerja Optuna melalui pendekatan probabilistik Tree-structured Parzen Estimator (TPE). Model integrasi arsitektur YOLOv8 dan mekanisme penalaan otomatis berbasis Optuna tersebut disajikan pada Gambar 2.



Gambar 2. Model Arsitektur Sistem Deteksi Multikelas Penyakit Kakao: Framework YOLOv8 Teroptimasi Bayesian (Optuna)

Dua skenario eksperimen yang bersifat ruang pencarian hiperparameter dan dataset yang komparatif dijalankan secara terpisah menggunakan identik:

1. Skenario 1 Standard Bayesian (Optuna + NopPruner): Seluruh 100 trial dijalankan hingga selesai penuh (maksimal 50 epoch per trial) tanpa mekanisme pemangkasan. Algoritma TPE mengeksplorasi ruang pencarian secara adaptif berdasarkan hasil trial sebelumnya. Skenario ini berfungsi sebagai baseline perbandingan komputasi.
2. Skenario 2 Hyperband Pruning (Optuna + HyperbandPruner): Trial yang menunjukkan konvergensi buruk pada fase awal pelatihan dipangkas (pruned) secara otomatis oleh algoritma Hyperband, sehingga sumber daya GPU dialokasikan secara lebih efisien hanya pada trial yang menunjukkan potensi performa tinggi.

Konfigurasi parameter tetap yang berlaku identik pada kedua skenario eksperimen disajikan pada Tabel 3.

Tabel 3. Konfigurasi Parameter Tetap pada Kedua Skenario Eksperimen

Parameter	Nilai / Konfigurasi	Fungsi Teknis
model	yolov8n.pt	Arsitektur dasar YOLOv8 Nano untuk komputasi ringan

epochs	50	Batas maksimal iterasi pelatihan per trial
imgsz	640	Resolusi input citra (640 × 640 piksel)
seed	42	Pengunci generator angka acak untuk replikabilitas riset
deterministic	True	Memastikan hasil yang dapat direproduksi (<i>reproducible results</i>)
pruner	NopPruner() / HyperbandPruner()	Strategi pemangkasan trial (Skenario 1 vs Skenario 2)
n_trials	100	Total kombinasi hiperparameter yang dievaluasi Optuna

Sepuluh hiperparameter dinamis dieksplorasi oleh Optuna dalam setiap trial, mencakup parameter optimasi gradien dan parameter augmentasi. Ruang pencarian ini dirancang untuk menangkap variabilitas visual yang khas pada agroekosistem perkebunan kakao, seperti fluktuasi pencahayaan kanopi yang tercermin pada parameter *hsv_v*, variasi warna kematangan biologis buah pada parameter *hsv_h*, serta distorsi geometris sudut pengambilan gambar pada parameter *degrees*. Detail ruang pencarian beserta justifikasi teknisnya disajikan pada Tabel 4.

Tabel 4. Ruang Pencarian Hiperparameter Dinamis (Tuned Hyperparameters Search Space)

Kategori	Parameter	Rentang	Skala	Justifikasi Teknis-Agronomis
Optimasi & Gradien	lr0	$10^{-4} - 10^{-2}$	Logaritmik	Laju pembelajaran awal; mengontrol kecepatan adaptasi bobot model
	lrf	0,01 – 0,2	Linear	Rasio akhir laju pembelajaran (<i>OneCycleLR</i>)
	momentum	0,6 – 0,98	Linear	Kontribusi gradien sebelumnya; mencegah <i>local minima</i>
	weight_decay	$10^{-4} - 10^{-2}$	Logaritmik	Regularisasi L2 untuk mencegah <i>overfitting</i>
Augmentasi Spasial	mosaic	0,5 – 1,0	Linear	Penggabungan 4 citra; melatih deteksi objek berukuran kecil
	mixup	0,0 – 0,5	Linear	<i>Blending</i> dua citra untuk menangani objek yang tumpang tindih
	degrees	$0,0^{\circ} - 45,0^{\circ}$	Linear	Rotasi acak; simulasi sudut kamera miring di lapangan perkebunan
Augmentasi Warna	hsv_h	0,0 – 0,1	Linear	Variasi <i>hue</i> ; simulasi tingkat kematangan biologis buah kakao
	hsv_s	0,0 – 0,9	Linear	Variasi <i>saturation</i> ; simulasi pantulan cahaya pasca-hujan atau debu daun
	hsv_v	0,0 – 0,9	Linear	Variasi <i>value</i> ; simulasi bayangan rimbun kanopi pohon pelindung kakao

Metrik Evaluasi Performa

Protokol evaluasi dilaksanakan dalam dua tahap. Pertama, konvergensi proses optimasi dipantau melalui tiga grafik diagnostik Optuna: Optimization History (perkembangan nilai fungsi tujuan terhadap jumlah trial), Hyperparameter Importance (kontribusi relatif tiap parameter terhadap nilai mAP), dan Slice

Plot (pemetaan hubungan parameter individual terhadap metrik evaluasi). Kedua, model dengan bobot terbaik dari masing-masing skenario diuji secara independen pada testing set yang identik (30 citra) guna menjamin perbandingan yang adil.

Kemampuan model dalam meminimalkan prediksi positif palsu (false positive, FP) dan negatif

palsu (false negative, FN) dievaluasi melalui nilai Precision dan Recall. Nilai True Positive (TP) merepresentasikan objek penyakit yang berhasil terdeteksi dengan benar; FP menunjukkan area yang keliru terdeteksi sebagai penyakit; sedangkan FN mengindikasikan objek penyakit aktual yang gagal diidentifikasi oleh model. Kedua metrik tersebut dikalkulasikan menggunakan Persamaan (4):

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

dan Persamaan (5):

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

Nilai F1-Score selanjutnya dikalkulasikan sebagai rata-rata harmonik dari Precision dan Recall untuk setiap kelas, berdasarkan Persamaan (6):

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

Evaluasi distribusi kesalahan prediksi antar kelas (*Anthracoze*, *Black Pod Rot*, dan *Healthy Cocoa Pod*) dilakukan melalui *Confusion Matrix Normalized*, guna memastikan hasil yang tidak bias oleh perbedaan jumlah sampel antar kelas.

Sebagai metrik agregat utama dalam evaluasi deteksi objek, *Average Precision* (AP) dikalkulasikan berdasarkan luas area di bawah kurva *Precision-Recall* (PR) untuk setiap kelas individual, kemudian dirata-ratakan menjadi *mean Average Precision* (mAP) lintas seluruh kelas menggunakan Persamaan (7):

$$AP = \int p(r) dr$$

dan Persamaan (8):

$$mAP = \frac{1}{N} \sum_{text} AP_i$$

Dua ambang batas Intersection over Union (IoU) digunakan secara komplementer: mAP50 (IoU = 0,50) dan mAP50-95 (rata-rata pada rentang IoU 0,50–0,95 dengan langkah 0,05).

Karakteristik sensitivitas dan stabilitas model pada berbagai ambang batas kepercayaan (confidence threshold) dianalisis melalui empat kurva tambahan: kurva F1-Confidence, kurva *Precision-Confidence*, kurva *Precision-Recall* (PR), dan kurva Recall-Confidence. Perbandingan akhir antara kedua skenario (Standard Bayesian dan Hyperband Pruning) dilakukan berdasarkan nilai mAP50-95, mAP50, Precision

makro, Recall makro, dan latensi inferensi rata-rata (ms/gambar) yang diukur pada testing set yang identik. Keseluruhan kurva tersebut berfungsi sebagai instrumen validasi objektif untuk mengukur ketangguhan (robustness) model dalam mengenali patologi Anthracnose, Black Pod Rot, dan Healthy Cocoa Pod pada berbagai variasi kondisi pencitraan lapangan.

HASIL DAN PEMBAHASAN

Perbandingan Skenario Optimasi Hiperparameter

Dua skenario optimasi hiperparameter diimplementasikan secara paralel pada arsitektur YOLOv8n untuk mendeteksi penyakit buah kakao. Skenario 1 menerapkan algoritma Tree-structured Parzen Estimator (TPE) berbasis Bayesian melalui Optuna dengan strategi NopPruner, di mana seluruh 100 trial dieksekusi hingga 50 epoch penuh tanpa pemangkasan dini. Skenario 2 menerapkan mekanisme Hyperband sebagai pruner adaptif, yang secara otomatis menghentikan trial berkinerja rendah pada tahap awal pelatihan. Kedua skenario dievaluasi pada ruang pencarian hiperparameter yang identik (Tabel 4), dengan batas komputasi 100 trial dan 50 epoch per trial sebagai parameter tetap (fixed parameters).

Perbandingan biaya komputasi antara kedua skenario menghasilkan temuan yang substantif. Skenario Bayesian TPE mengeksekusi seluruh 100 trial secara penuh, sehingga mengakumulasi 5.100 epoch GPU dalam total durasi 6 jam 51 menit 10 detik. Skenario Hyperband, sebaliknya, memangkas 80 dari 100 trial pada fase awal pelatihan, umumnya sebelum epoch ke-15, sehingga total epoch yang dieksekusi hanya mencapai 2.780 epoch dalam durasi 3 jam 45 menit 43 detik. Efisiensi komputasi Skenario Hyperband terkuantifikasi melalui rasio penghematan epoch berikut:

$$\eta_{HB} = \frac{5.000 - 2.780}{5.000} \times 100\% = 44,40\%$$

$$\Delta T = 6\text{jam } 51\text{menit } 10\text{detik} - 3\text{jam } 45\text{menit } 43\text{detik} \\ \approx 3\text{jam } 05\text{menit } 27\text{detik} \\ \approx 45\% \text{ lebih cepat}$$


Penghematan sebesar 44,40% beban komputasi GPU dicapai tanpa mengorbankan kualitas hiperparameter optimal secara signifikan. Selisih nilai mAP50-95 terbaik antara kedua skenario hanya sebesar 0,0004 (Bayesian: 0,9012; Hyperband: 0,9008). Nilai ini berada jauh di bawah ambang signifikansi praktis dalam konteks dataset berukuran terbatas (720 citra pelatihan setelah augmentasi). Efisiensi waktu komputasi Hyperband (3 jam 45 menit 43 detik) setara

dengan penghematan 3 jam 5 menit 27 detik dibandingkan Bayesian (6 jam 51 menit 10 detik), yang secara operasional mereduksi biaya cloud computing atau beban termal perangkat GPU secara substansial pada iterasi pengembangan model berikutnya. Ringkasan perbandingan beban komputasi kedua skenario disajikan pada Tabel 5.

Tabel 5. Perbandingan Efisiensi Sumber Daya


Parameter Komputasi	Bayesian TPE (<i>NopPruner</i>)	Hyperband BOHB	Δ (Hyperband - Bayesian)
Total Trial Dievaluasi	100 Trial	100 Trial	—
Trial Selesai (<i>Complete</i>)	100 Trial (100%)	20 Trial (20%)	-80 Trial
Trial Dipangkas (<i>Pruned</i>)	0 Trial	80 Trial (80%)	+80 Trial
Total Epoch Teoritis	5.000 Epoch	5.000 Epoch	—
Total Epoch Aktual (GPU)	5.100 Epoch	2.780 Epoch	-2.320 Epoch
Epoch Dihemat	—	2.220 Epoch	+2.220 Epoch
Durasi Total Tuning	6 j 51 m 10 d	3 j 45 m 43 d	-3 j 5 m 27 d
Efisiensi Komputasi	— (Baseline)	+44,40%	—
Best mAP_{50-95} (Validasi)	0,9012	0,9008	-0,0004

Analisis Optimization History Plot (Gambar 3 dan 4) menunjukkan bahwa kedua skenario berhasil mengidentifikasi koordinat hiperparameter optimal dalam 25 trial pertama dari total 100 trial yang dievaluasi. Pada Skenario Bayesian TPE, nilai mAP_{50-95} terbaik sebesar 0,9012 dikunci pada trial ke-21. Peningkatan nilai terjadi secara bertahap dari $\approx 0,84$ pada trial ke-3 menuju $\approx 0,90$ pada trial ke-12, lalu terkonsolidasi pada trial ke-21. Pada Skenario Hyperband, nilai terbaik 0,9008 tercapai pada trial ke-23, dengan laju konvergensi yang lebih curam pada fase awal karena trial berperforma rendah dieliminasi lebih awal oleh mekanisme *pruning*.




Gambar 3. Optimization History Plot Metode Bayesian TPE

Setelah trial ke-23, kurva Best Value kedua skenario memasuki kondisi plateau yang persisten. Kondisi ini mengindikasikan bahwa ruang hiperparameter di sekitar optimum global telah dieksplorasi secara memadai oleh mesin probabilistik TPE. Penambahan trial ke-24 hingga ke-100 tidak menghasilkan peningkatan nilai objektif yang signifikan pada kedua skenario, mengonfirmasi efisiensi konvergensi algoritma TPE Optuna dalam mengestimasi distribusi posterior ruang pencarian hiperparameter.




Gambar 4. Optimization History Plot Metode Hyperband

Analisis *Hyperparameter Importances* (Gambar 5 dan 6) mengidentifikasi parameter degrees sebagai faktor paling determinan terhadap variasi nilai mAP_{50-95} , dengan skor kepentingan 0,85 pada Skenario Bayesian dan 0,54 pada Skenario Hyperband. Kedua nilai ini melampaui parameter arsitektural seperti lr_0 ($< 0,01$) dan momentum (0,04-0,05) secara signifikan.



Gambar 5. Hyperparameter Importances Metode Bayesian TPE



Gambar 6. Hyperparameter Importances Metode Hyperband

Secara konsisten, kedua skenario secara independen mengkonvergensi nilai optimal degrees ke kisaran mendekati nol (Bayesian: $0,716^\circ$; Hyperband: $0,044^\circ$), meskipun rentang pencarian meliputi 0° hingga 45° . Konvergensi menuju nilai degrees $\approx 0^\circ$ ini mencerminkan fenomena compounding augmentation: rotasi acak $\pm 15^\circ$ yang telah diterapkan pada tahap prapemrosesan dataset di platform Roboflow menjadikan penambahan rotasi on-the-fly melalui parameter degrees bersifat redundan dan kontraproduktif. Distorsi orientasi yang terlalu besar mendegradasi integritas fitur spasial lesi Anthracnose dan Black Pod Rot yang bersifat directionally anisotropic, yakni pola bercak eliptikal Anthracnose

dan pola nekrosis radial difus Black Pod Rot yang sensitif terhadap transformasi rotasi berlebih.

Perbedaan distribusi kepentingan yang menonjol antara kedua skenario adalah kemunculan hsv_h dengan skor 0,21 pada Hyperband (dibandingkan $<0,01$ pada Bayesian). Fenomena ini merupakan konsekuensi mekanisme seleksi Hyperband: dari 100 trial, hanya 20 trial yang menghasilkan nilai akhir lengkap. Pada subset survivor yang terdistilasi ini, variasi hsv_h, yang mengontrol pergeseran rona sebagai proksi variabilitas tingkat kematangan biologis buah kakao, menunjukkan korelasi lebih kuat terhadap variasi nilai objektif. Konfigurasi hiperparameter optimal yang ditemukan oleh kedua skenario dirangkum pada Tabel 6 berikut.

Tabel 6. Konfigurasi Hiperparameter Optimal: Bayesian TPE vs. Hyperband

Hiperparameter	Bayesian Optimal	Hyperband Optimal	Justifikasi Teknis
Laju Pembelajaran Awal (<i>lr₀</i>)	$1,30 \times 10^{-4}$	$2,52 \times 10^{-3}$	LR konservatif (Bayesian) menstabilkan konvergensi bobot pada dataset berukuran terbatas; LR lebih besar (Hyperband) diimbangi oleh momentum tinggi
Learning Rate Akhir (<i>lr_f</i>)	0,052	0,108	Faktor peluruhan LR pada akhir siklus pelatihan; nilai lebih tinggi (Hyperband) mempercepat penurunan LR menuju konvergensi
Momentum Jaringan (<i>momentum</i>)	0,871	0,944	Momentum tinggi pada Hyperband memfasilitasi traversal melewati local minima pada lanskap loss yang kompleks akibat variabilitas visual lesi kakao
Peluruhan Bobot (<i>weight_decay</i>)	$3,49 \times 10^{-3}$	$1,61 \times 10^{-4}$	Regularisasi L2 lebih kuat (Bayesian) mencegah overfitting pada 720 citra pelatihan; Hyperband mengompensasi melalui augmentasi mosaic yang lebih agresif
Probabilitas Augmentasi (<i>mosaic</i>)	0,671	0,950	Penggabungan 4 citra secara acak memperkuat kemampuan deteksi lesi berukuran kecil (2–5 mm) pada kondisi oklusi parsial daun kakao
Probabilitas Augmentasi (<i>mixup</i>)	0,265	0,405	Blending citra moderat menyimulasikan kondisi tumpang-tindih (occlusion) antara daun dan buah dalam agroekosistem perkebunan Jembrana
Distorsi Spektral Hue (<i>hsv_h</i>)	0,024	0,097	Pergeseran rona sebagai simulasi variabilitas warna kulit buah pada berbagai tingkat kematangan biologis
Distorsi Spektral Saturation (<i>hsv_s</i>)	0,619	0,750	Perubahan saturasi menyimulasikan kondisi pantulan cahaya pasca-hujan dan variasi kelembapan permukaan buah
Distorsi Spektral Value/Brightness (<i>hsv_v</i>)	0,867	0,724	Perubahan kecerahan (value) menyimulasikan bayangan dinamis kanopi pohon pelindung pada perkebunan kakao tropis
Batas Batasan Rotasi Spasial (<i>degrees</i>)	$0,716^\circ$	$0,044^\circ$	Minimasi rotasi on-the-fly ($\approx 0^\circ$) karena rotasi $\pm 15^\circ$ telah diterapkan pada tingkat dataset Roboflow

Evaluasi Performa Model pada Data Uji Independen

Evaluasi kuantitatif terhadap kedua skenario optimasi dilaksanakan pada data uji independen (unseen test set) yang terdiri dari 30 citra. Citra-citra tersebut tidak diikutsertakan dalam proses pelatihan maupun validasi selama fase optimasi hiperparameter. Ketiga kelas deteksi mencakup: Anthracnose, Black Pod Rot (Busuk Buah), dan Healthy Cocoa Pod. Metrik utama yang digunakan meliputi mAP50, mAP50-95, Presisi Makro, dan Recall Makro. Seluruh pengujian dilaksanakan pada kondisi deterministik (seed = 42,

deterministic = True) guna menjamin replikabilitas hasil. Rekap komparatif metrik performa disajikan pada Tabel 7.

Dari Tabel 7, model berbasis Hyperband mencapai mAP50 = 0,9913 dan mAP50-95 = 0,8945, sedikit lebih tinggi dibandingkan Bayesian (mAP50 = 0,9840; mAP50-95 = 0,8932). Selisih mAP50-95 antara kedua model sebesar 0,0013 tidak mencapai ambang signifikansi statistik pada ukuran dataset uji 30 citra. Kedua model, dengan demikian, dipandang setara secara kuantitatif dalam dimensi akurasi lokalisasi multi-threshold.

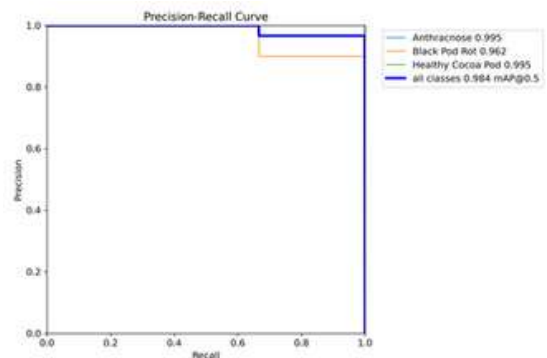
Tabel 7. Komparasi Metrik Performa Model Bayesian TPE vs. Hyperband pada Data Uji Independen

Metrik	Bayesian TPE	Hyperband (BOHB)	Δ (Hyperband - Bayesian)
mAP_{50} (Test)	0,9840	0,9913	+0,0073
mAP_{50-95} (Test)	0,8932	0,8945	+0,0013
AP_{50} Anthracnose	0,995	0,995	0,000
AP_{50} Black Pod Rot	0,962	0,984	+0,022
AP_{50} Healthy Cocoa Pod	0,995	0,995	0,000
Precision Makro	0,9310	0,9138	-0,0172
Recall Makro	1,0000	0,9985	-0,0015
Peak F1 (semua kelas)	0,96@ conf. 0,805	0,95 @ conf. 0,710	-0,01
Latensi Inferensi	7,60 ms/citra	11,64 ms/citra	+4,04 ms
mAP_{50-95} (Training)	0,9012	0,9008	-0,0004
Generalization Gap (Δ_{gen})	0,0080	0,0063	-0,0017

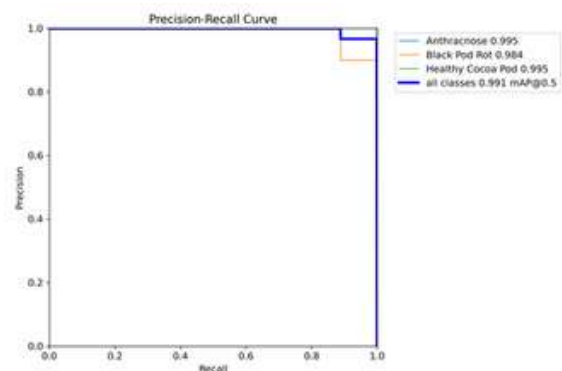
Sebaliknya, model Bayesian unggul pada metrik Presisi Makro (0,9310 vs. 0,9138) dan Recall Makro (1,0000 vs. 0,9985). Keunggulan pada dimensi Recall Makro = 1,0000 mengindikasikan bahwa tidak ada satu pun instansi penyakit, baik Anthracnose maupun Black Pod Rot, yang terlewatkan selama pengujian. Nilai Recall = 1,0000 ini bernilai kritis dalam konteks aplikasi deteksi penyakit tanaman, di mana false negative (penyakit tidak terdeteksi) berpotensi memicu penyebaran patogen yang tidak terkendali di lahan perkebunan.

Latensi inferensi model Bayesian (7,60 ms/citra) tercatat 34,7% lebih rendah dibandingkan Hyperband (11,64 ms/citra). Perbedaan 4,04 ms ini signifikan dalam konteks deployment ke perangkat edge berdaya komputasi terbatas (seperti Raspberry Pi atau perangkat Android mid-range), di mana latensi inferensi secara langsung memengaruhi responsivitas antarmuka aplikasi deteksi lapangan.

Kurva *Precision-Recall* (PR Curve) kedua model (Gambar 1 dan 2) memperlihatkan geometri "L terbalik" mendekati sempurna untuk kelas Anthracnose ($AP_{50} = 0,995$) dan Healthy Cocoa Pod ($AP_{50} = 0,995$) pada kedua skenario. Geometri ini menandakan bahwa sistem deteksi mempertahankan presisi $\approx 1,0$ di sepanjang hampir seluruh rentang recall hingga mendekati nilai maksimal.



Gambar 7. Kurva Precision-Recall Metode Bayesian



Gambar 8. Kurva Precision-Recall Metode Hyperband

Capaian $AP_{50} = 0,995$ untuk kelas Anthracnose secara fungsional mencerminkan kontras fitur visual yang substansial antara bercak coklat-kehijauan berbentuk eliptikal khas infeksi *Colletotrichum theobromicola* dengan permukaan buah sehat berpigmen kuning-oranye atau merah-hijau. Batas lesi Anthracnose yang relatif tegas dan ukurannya yang konsisten (bercak 3 – 8 mm) memudahkan anchor box YOLOv8n menggeneralisasi pola deteksi pada berbagai orientasi dan skala.

Kelas Black Pod Rot mencatatkan peningkatan AP_{50} yang substansial pada skenario Hyperband (0,984) dibandingkan Bayesian (0,962), dengan selisih +0,022 yang merupakan delta terbesar di antara semua metrik per kelas. Peningkatan ini mengindikasikan bahwa konfigurasi Hyperband, khususnya nilai mosaik tinggi (0,950) dan hsv_s besar (0,750), berhasil membangun representasi fitur Black Pod Rot yang lebih robust di seluruh rentang confidence threshold. Secara agronomis, $hsv_s = 0,750$ menyimulasikan variabilitas visual lesi *Phytophthora palmivora* pada kondisi kelembapan tinggi pasca-hujan di perkebunan kakao Jembrana, di mana permukaan buah yang basah menghasilkan reflektansi warna yang berbeda dari kondisi kering.

Kesenjangan antara mAP50 dan mAP50-95 pada kedua model—masing-masing sebesar 0,0908 (Bayesian: 0,9840 – 0,8932) dan 0,0968 (*Hyperband*: 0,9913 – 0,8945)—mencerminkan tantangan lokalisasi geometri bounding box yang inheren pada lesi penyakit kakao berukuran 2–8 mm. Penurunan nilai mAP pada ambang IoU yang lebih ketat ($\geq 0,75$) disebabkan oleh dua karakteristik morfologi lesi yang sulit dilokalisasi secara presisi:

Pertama, lesi *Black Pod Rot* memiliki batas nekrotik yang difus dan ireguler, yang terbentuk karena penyebaran miselium *Phytophthora palmivora* secara radial di bawah permukaan kulit buah sebelum gejala eksternal terlihat. Akibatnya, bounding box prediksi sering kali sedikit lebih besar atau lebih kecil dari anotasi ground truth pada threshold IoU $\geq 0,75$. Kedua, lesi Anthracnose bersifat eliptikal-gradasi, yakni intensitas kerusakan menurun secara progresif dari pusat menuju tepi lesi, sehingga penentuan batas bounding box yang tepat bersifat ambigu secara visual bagi anotator manusia maupun model.

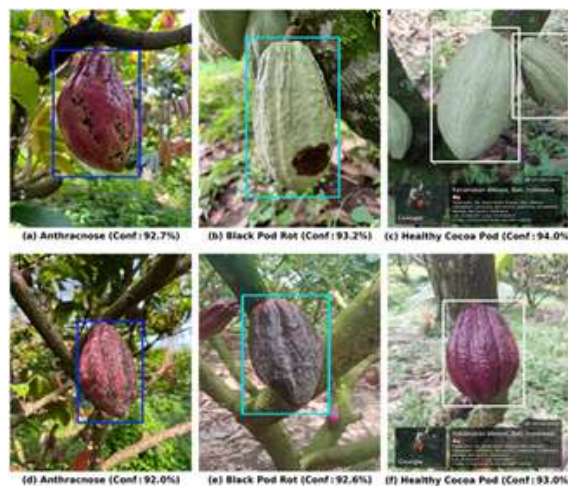
Terlepas dari tantangan tersebut, nilai mAP50-95 > 0,89 yang dicapai kedua model menggunakan arsitektur YOLOv8 Nano, arsitektur terkecil dalam hierarki YOLOv8 dengan $\approx 3,2$ juta parameter, mengkonfirmasi efektivitas optimasi hiperparameter berbasis Optuna dalam mengompensasi kapasitas representasional yang terbatas.

Generalization Gap kedua model (Gap Bayesian = 0,0080; Gap Hyperband = 0,0063) mengkonfirmasi bahwa kedua model memiliki ketahanan terhadap overfitting meskipun dataset pelatihan berukuran terbatas (720 citra setelah augmentasi $3\times$). Model Hyperband menunjukkan gap yang lebih kecil (0,0063), mengindikasikan kapasitas generalisasi yang sedikit lebih baik sebagai hasil seleksi adaptif trial berbasis performa early-epoch oleh mekanisme pruning.

Analisis Visual Deteksi pada Citra Uji Kakao

Konfirmasi kualitatif kemampuan deteksi model dilaksanakan melalui analisis visual terhadap contoh citra uji dari masing-masing kelas penyakit. Sebanyak 6 citra contoh (2 citra per kelas) divisualisasikan untuk setiap skenario, menghasilkan 12 pasang visualisasi total. Citra-citra tersebut diakuisisi secara in-field di Kecamatan Melaya, Kabupaten Jembrana, Bali, Indonesia pada November 2025 - Februari 2026, sebagaimana terindikasi oleh watermark GPS yang tertampil pada beberapa citra uji. Perbedaan warna bounding box yang diterapkan bersifat konvensional: biru untuk kelas Anthracnose,

sian/hijau-toska, untuk kelas *Black Pod Rot*, dan putih untuk kelas *Healthy Cocoa Pod*.



Gambar 9. Contoh Hasil Deteksi Skenario YOLOv8n Optuna Bayesian TPE

Pada Gambar 9 yang menampilkan hasil deteksi model Bayesian TPE, visualisasi berikut teramat:

1. Deteksi Kelas Anthracnose (Conf: 92,7% dan 92,0%): Dua citra buah kakao berwarna merah-keunguan berhasil dilokalisasi oleh bounding box biru. Bercak patologis kelas Anthracnose yang teridentifikasi berupa lesi coklat-kehitaman berbentuk eliptikal tersebar di permukaan kulit buah. Skor kepercayaan (confidence) 92,7% dan 92,0% mencerminkan kemampuan model dalam memisahkan fitur lesi *Colletotrichum theobromicola*, yang bersifat kering, diskret, dan berbatas relatif tegas, dari pigmentasi alami kulit buah yang bervariasi antar buah pada tingkat kematangan berbeda.
2. Deteksi Kelas Black Pod Rot (Conf: 93,2% dan 92,6%): Citra pertama menampilkan buah kakao berwarna hijau muda dengan satu zona nekrosis berwarna coklat gelap pada permukaan bawah buah, representatif dari stadium infeksi *Phytophthora palmivora* tahap awal, di mana lesi masih terlokalisasi dan belum menyebar ke seluruh permukaan. Citra kedua menampilkan buah kakao dengan nekrosis lebih lanjut, ditandai oleh perubahan pigmentasi permukaan secara menyeluruh menjadi coklat-kehitaman intens. Skor kepercayaan 93,2% dan 92,6% mengindikasikan bahwa model berhasil mengenali kedua stadium morfologi Black Pod Rot yang berbeda secara visual.
3. Deteksi Kelas Healthy Cocoa Pod (Conf: 94,0% dan 93,0%): Dua buah kakao tanpa gejala patologis berhasil dilokalisasi dengan bounding box putih.

Buah pertama berwarna hijau, sedangkan buah kedua berwarna ungu, keduanya merepresentasikan variasi pigmentasi klorofil dan anthosianin pada kultivar kakao yang berbeda atau pada tingkat kematangan yang berbeda. Model Bayesian mengklasifikasikan kedua buah sebagai Healthy Cocoa Pod dengan skor kepercayaan 94,0% dan 93,0%, tanpa penambahan bounding box patologis yang tidak semestinya.



Gambar 10. Contoh Hasil Deteksi Skenario YOLOv8n Optuna Hyperband

Pada Gambar 10 yang menampilkan hasil deteksi model Hyperband, pola deteksi berikut teramati:

1. Deteksi Kelas Anthracnose (Conf: 95,3% dan 92,9%): Pola lesi Anthracnose berhasil dilokalisasi dengan bounding box biru. Skor kepercayaan 95,3% pada citra pertama menunjukkan peningkatan 2,6 poin persentase dibandingkan model Bayesian (92,7%) pada citra yang ekuivalen. Peningkatan ini konsisten dengan AP50 kelas Anthracnose yang identik antara kedua model (0,995), namun mengindikasikan distribusi skor kepercayaan yang lebih terkonsentrasi pada nilai tinggi untuk model Hyperband pada kelas ini.
2. Deteksi Kelas Black Pod Rot (Conf: 93,5% dan 90,1%): Citra pertama menampilkan buah kakao hijau dengan zona nekrosis coklat yang berhasil dilokalisasi dengan skor kepercayaan 93,5%. Citra kedua menampilkan buah kakao dengan pigmentasi keseluruhan yang lebih gelap (ungu kehitaman), dengan skor kepercayaan yang lebih rendah yaitu 90,1%. Penurunan skor kepercayaan pada citra kedua mencerminkan tantangan diskriminasi yang lebih tinggi ketika warna keseluruhan buah (pod color) mendekati warna lesi nekrotik, kondisi yang terjadi pada buah dengan infeksi Black Pod Rot stadium lanjut atau buah dari kultivar berpigmen

gelap. Hal ini konsisten dengan tipologi kegagalan yang teridentifikasi pada analisis matriks konfusi.

3. Deteksi Kelas Healthy Cocoa Pod (Conf: 99,1% dan 99,0%): Temuan yang paling mencolok pada skenario Hyperband adalah skor kepercayaan yang sangat tinggi untuk kelas Healthy Cocoa Pod, yaitu 99,1% dan 99,0%. Skor ini meningkat secara substansial dibandingkan model Bayesian (94,0% dan 93,0%), dengan selisih 5,1 dan 6,0 poin persentase. Peningkatan kepercayaan pada deteksi Healthy Cocoa Pod ini secara kuantitatif mengkonfirmasi kontribusi konfigurasi mosaik tinggi (0,950) dan mixup yang lebih besar (0,405) pada model Hyperband: augmentasi yang lebih agresif tersebut memaksa model untuk membangun representasi internal buah kakao sehat yang lebih diskriminatif dan robust terhadap variasi kondisi pencahayaan lapangan.

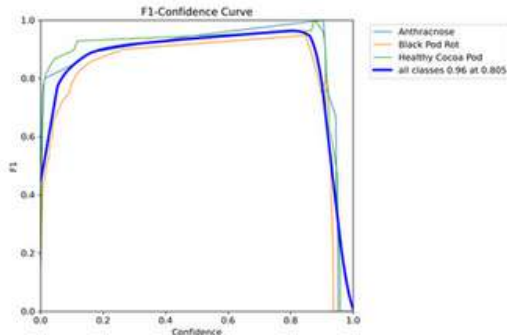
Terdapat Tiga temuan komparatif utama teridentifikasi dari analisis visual lintas kedua skenario. Pertama, model menghasilkan bounding box yang secara konsisten melingkupi keseluruhan objek buah (whole-pod bounding), bukan hanya area lesi. Strategi ini secara fungsional sesuai dengan kebutuhan deteksi penyakit kakao in-field, di mana identifikasi buah terinfeksi secara keseluruhan, bukan hanya penentuan area lesi, merupakan output yang relevan bagi petugas lapangan. Kedua, Peningkatan skor kepercayaan sebesar 5 – 6 poin persentase pada deteksi Healthy Cocoa Pod oleh model Hyperband mengindikasikan bahwa pemilihan survivor trial secara adaptif oleh mekanisme pruning menghasilkan model dengan representasi kelas Healthy Cocoa Pod yang lebih definitif. Secara praktis, ini mereduksi risiko false positive pengklasifikasian buah sehat sebagai terinfeksi (over-detection). Ketiga, Selisih skor kepercayaan antara dua contoh Black Pod Rot pada Hyperband (93,5% vs. 90,1%) lebih besar dibandingkan selisih pada Bayesian (93,2% vs. 92,6%). Hal ini mengindikasikan sensitivitas model Hyperband yang lebih tinggi terhadap variasi warna buah keseluruhan, sebagai konsekuensi dari hsv_s yang lebih tinggi (0,750) pada konfigurasi optimalnya, sehingga stadium infeksi Black Pod Rot pada buah berpigmen gelap lebih sulit dibedakan dari fitur buah sehat berpigmen gelap.

Profil Stabilitas Operasional: Kurva F1-Confidence


Kurva F1-Confidence (Gambar 11 dan 12) digunakan untuk mengidentifikasi ambang kepercayaan (confidence threshold) optimal yang memaksimalkan harmoni antara presisi dan cakupan deteksi (recall). Model Bayesian mencapai F1 puncak sebesar 0,96 pada confidence threshold 0,805. Kurva

ini mempertahankan $F1 \geq 0,90$ pada rentang confidence 0,10 hingga $\approx 0,85$.

Rentang plateau yang lebar ini mengindikasikan robustisitas operasional: kinerja model tetap tinggi meskipun threshold kepercayaan disesuaikan dalam rentang yang signifikan. Karakteristik ini bernilai tinggi untuk deployment di lapangan perkebunan dengan variabilitas kondisi pencahayaan yang berfluktuasi sepanjang hari akibat dinamika kanopi.



Gambar 11. Kurva F1-Confidence Skenario Bayesian TPE



Gambar 12. Kurva F1-Confidence Skenario Hyperband

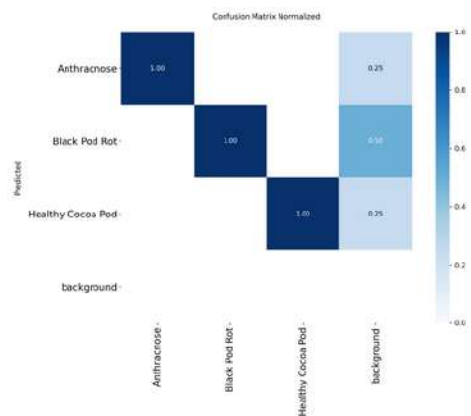
Model Hyperband mencatatkan F1 puncak 0,95 pada confidence yang lebih rendah (0,710), dengan plateau yang sedikit lebih sempit. Perbedaan threshold optimal sebesar 0,095 antara kedua model mengindikasikan bahwa distribusi skor kepercayaan prediksi Hyperband secara sistematis lebih tersebar. Kondisi ini merupakan konsekuensi dari nilai momentum yang tinggi (0,944) pada konfigurasi optimalnya, yang menghasilkan bobot model dengan distribusi posterior kepercayaan yang lebih konservatif. Pada konteks deployment praktis, perbedaan threshold ini mensyaratkan kalibrasi ulang confidence threshold saat model diimplementasikan di luar kondisi pengujian standar laboratorium.

Pada kedua kurva, kelas Black Pod Rot secara konsisten menampilkan nilai F1 lebih rendah dibandingkan kelas Anthracnose dan Healthy Cocoa


Pod pada rentang confidence menengah (0,3–0,7). Hal ini merupakan manifestasi langsung dari tantangan diskriminasi visual antara lesi Black Pod Rot dan elemen latar belakang perkebunan dengan pencahayaan yang relatif gelap.

Dekonstruksi Matriks Konfusi: Tipologi dan Kuantifikasi Kegagalan Klasifikasi

Matriks konfusi ternormalisasi (Gambar 13 dan 14) mengungkap perbedaan kualitatif yang fundamental dalam tipologi kesalahan antara kedua model. Pada model Bayesian, diagonal utama matriks menunjukkan nilai normalisasi 1,00 untuk ketiga kelas penyakit. Nilai ini mengkonfirmasi zero false negative pada seluruh kelas patologis, tidak ada satu pun instansi penyakit yang terlewat maupun salah diklasifikasikan ke kelas lain. Satu-satunya sumber kesalahan berasal dari background: 25% instansi latar belakang salah diklasifikasikan sebagai Anthracnose, 50% sebagai Black Pod Rot, dan 25% sebagai Healthy Cocoa Pod. Dari data mentah, 2 dari 4 instansi latar belakang yang memicu false positive teridentifikasi sebagai Black Pod Rot.



Gambar 13. Matriks Konfusi Ternormalisasi Skenario Bayesian



Gambar 14. Matriks Konfusi Ternormalisasi Skenario Hyperband

Konfigurasi zero false negative menghasilkan Recall Makro = 1,0000, nilai yang optimal secara klinis untuk aplikasi deteksi penyakit tanaman, di mana prioritas utama adalah memastikan tidak ada buah terinfeksi yang terlewatkan selama pemindaian.

Pada model Hyperband, profil kesalahan lebih kompleks dengan dua tipologi yang berbeda:

1. Tipologi I Konfusi Lintas Kelas: Sebesar 11% instansi Black Pod Rot diprediksi sebagai Anthracnose (elemen matriks [Pred = Anthracnose, True = Black Pod Rot] = 0,11). Akibatnya, Recall kelas Black Pod Rot turun menjadi 0,89. Konfusi lintas kelas ini sepenuhnya absen pada model Bayesian. Secara agronomis, ambiguitas ini terjadi karena lesi Black Pod Rot pada stadium inkubasi awal, sebelum pigmentasi hitam penuh akibat sporulasi *Phytophthora palmivora* berkembang, menampilkan warna coklat muda yang berdekatan secara spektral dengan lesi Anthracnose stadium awal. Nilai mosaic yang sangat tinggi (0,950) pada konfigurasi Hyperband berpotensi memperkenalkan ambiguitas representasi fitur lintas kelas ini melalui penggabungan agresif citra dari berbagai kelas.
2. Tipologi II False Positive Background-to-Black Pod Rot: Tingkat misklasifikasi latar belakang sebagai Black Pod Rot mencapai 0,83 pada Hyperband, meningkat dari 0,50 pada Bayesian. Secara konkret, 83% dari seluruh instansi latar belakang yang diusulkan oleh komponen lokalisasi YOLOv8 sebagai Region of Interest (RoI) diklasifikasikan oleh classification head sebagai Black Pod Rot. Inilah sumber utama penurunan Presisi Makro pada Hyperband (0,9138 vs. 0,9310 Bayesian).

Ringkasan komparatif tipologi kesalahan pada kedua model disajikan pada Tabel 8.

Tabel 8. Komparasi Tipologi Kegagalan Klasifikasi pada Data Uji Independen

Tipologi Kesalahan	Bayesian	Hyperband	Dampak Operasional
<i>False Negative</i> (penyakit tidak terdeteksi)	0 instansi	1 instansi (BPR)	Berisiko terhadap penyebaran penyakit yang tidak terdeteksi
Konfusi BPR→ <i>Anthracnose</i>	0,00	0,11	Risiko salah diagnosis, penanganan fungsida keliru
Background→ Black Pod Rot FP	0,50	0,83	Pemicu <i>false alarm</i> , meningkatkan beban verifikasi manual

Background→ <i>Anthracnose</i> FP	0,25	0,11	Lebih rendah pada Hyperband
Background→ Healthy FP	0,25	0,17	Lebih rendah pada Hyperband

Persistennya *false positive* dari latar belakang yang diklasifikasikan sebagai *Black Pod Rot*, sebagai sumber kesalahan dominan pada kedua model, berakar pada ambiguitas visual antara karakteristik lesi Black Pod Rot dan sejumlah elemen agroekosistem perkebunan kakao. Infeksi *Phytophthora palmivora* menghasilkan ciri khas lesi berupa: (a) pigmentasi coklat kehitaman intens, (b) batas nekrotik tidak teratur dan difus, (c) tekstur permukaan yang mengeras (*leathery necrosis*), serta (d) profil warna dengan nilai luminansi rendah (*hsv-v* rendah) dan saturasi tinggi pada saluran coklat.

Kegagalan ini dapat dijelaskan melalui sifat *decoupled detection head* pada YOLOv8. Komponen lokalisasi (*objectness head*) mengusulkan region of interest di sekitar objek gelap yang memenuhi kriteria geometris, termasuk elemen latar belakang yang disebutkan di atas. Selanjutnya, *classification head* yang telah terkondisi untuk mengasosiasikan pola warna gelap-difus dengan kelas Black Pod Rot mengklasifikasikan proposal tersebut berdasarkan kemiripan distribusi warna pada feature map konvolusional. *Classification head* tidak memiliki akses terhadap konteks semantik keseluruhan citra untuk membedakan "lesi pada permukaan buah" dari "komponen latar belakang berpigmen gelap".

Dari perspektif mitigasi teknis, permasalahan ini dapat diatasi melalui penambahan kelas background sebagai kelas eksplisit keempat dalam dataset pelatihan (*hard negative mining*). Strategi ini memungkinkan *classification head* belajar secara aktif untuk menolak proposal dari latar belakang, bukan hanya belajar menerima proposal dari kelas target. Penambahan citra latar belakang perkebunan kakao Jembrana yang teranotasi, mencakup ranting kering, batang tua, dan pola bayangan kanopi, ke dalam dataset pelatihan pada iterasi pengembangan berikutnya direkomendasikan sebagai prioritas untuk menekan tingkat false positive secara substansial.

KESIMPULAN

Integrasi arsitektur ringan YOLOv8 Nano (*yolov8n.pt*) dengan kerangka kerja optimasi hiperparameter otomatis berbasis Optuna yang mengimplementasikan algoritma Tree-structured Parzen Estimator (TPE) Bayesian terbukti efektif dalam membangun sistem deteksi multikelas penyakit

buah *Theobroma cacao* L. Sistem tersebut berhasil mengenali tiga kelas kondisi secara simultan, yaitu Anthracnose, Black Pod Rot, dan Healthy Cocoa Pod, dengan akurasi lokalisasi yang substantif pada data uji independen yang tidak diikutsertakan selama fase optimasi. Skenario Standard Bayesian (NopPruner) mencatatkan mAP50 sebesar 0,9840 dan mAP50-95 sebesar 0,8932 pada testing set, disertai Precision Makro 0,9310 dan Recall Makro 1,0000. Capaian Recall Makro 1,0000 mengindikasikan bahwa tidak ada satu pun instansi penyakit Anthracnose maupun Black Pod Rot yang terlewatkan selama pengujian, sebuah properti yang bernilai kritis dalam aplikasi deteksi fitosanitas, mengingat false negative berpotensi memicu penyebaran patogen *Colletotrichum theobromicola* dan *Phytophthora palmivora* yang tidak terkendali di lahan perkebunan. Skenario Hyperband BOHB menghasilkan performa yang bersaing ketat, dengan mAP50 sebesar 0,9913 dan mAP50-95 sebesar 0,8945, sekaligus mencatatkan Generalization Gap yang lebih kecil (0,0063) dibandingkan Bayesian (0,0080). Keseluruhan capaian mAP50-95 > 0,89 yang diraih kedua skenario, menggunakan arsitektur YOLOv8 terkecil dengan $\approx 3,2$ juta parameter, mengkonfirmasi bahwa optimasi hiperparameter sistematis berbasis Optuna mampu mengompensasi kapasitas representasional model yang terbatas secara efektif pada domain agroekosistem perkebunan kakao dengan variabilitas pencahayaan kanopi dan heterogenitas morfologi lesi yang tinggi.

Komparasi antara kedua strategi optimasi mengungkap kontribusi krusial mekanisme pemangkasan trial (pruning) terhadap efisiensi komputasi secara keseluruhan. Skenario Hyperband BOHB memangkas 80 dari 100 trial pada fase pelatihan awal, sehingga total epoch yang dieksekusi hanya mencapai 2.780 epoch aktual dari 5.000 epoch teoritis, setara dengan reduksi beban komputasi GPU sebesar 44,40%. Penghematan tersebut mereduksi durasi optimasi dari 6 jam 51 menit 10 detik (Bayesian TPE) menjadi 3 jam 45 menit 43 detik (Hyperband BOHB), yakni penghematan 3 jam 5 menit 27 detik per siklus tuning, tanpa mengorbankan kualitas hiperparameter optimal secara signifikan: selisih nilai mAP50-95 terbaik pada fase validasi antara kedua skenario hanya sebesar 0,0004 (Bayesian: 0,9012; Hyperband: 0,9008). Tradeoff utama yang teridentifikasi adalah pada dimensi latensi inferensi, di mana model Bayesian TPE mencatatkan latensi 7,60 ms per citra, 34,7% lebih rendah dibandingkan Hyperband (11,64 ms per citra), sebuah perbedaan yang relevan dalam skenario deployment pada perangkat tepi (edge device) berdaya komputasi terbatas. Secara komparatif, Hyperband

BOHB merepresentasikan pilihan strategis yang optimal pada iterasi pengembangan yang dibatasi oleh anggaran komputasi, sedangkan Bayesian TPE dengan Recall Makro 1,0000 mempertahankan keunggulan dalam skenario yang memprioritaskan zero false negative pada sistem deteksi penyakit tanaman berbasis presisi.

Sebagai kelanjutan riset, bobot model terbaik (best.pt) dari masing-masing skenario direkomendasikan untuk diimplementasikan dan divalidasi secara langsung pada perangkat komputasi tepi (edge device) seperti NVIDIA Jetson Nano, atau diintegrasikan ke dalam aplikasi mobile berbasis framework Flutter, guna mengevaluasi performa inferensi real-time di bawah kondisi lapangan perkebunan kakao yang sesungguhnya, mencakup fluktuasi pencahayaan dinamis akibat pergerakan kanopi pohon pelindung, variabilitas kelembapan permukaan buah pasca-hujan, serta heterogenitas latar belakang tanah. Selain itu, perluasan variabilitas dataset melalui akuisisi citra in-field yang lebih ekstensif direkomendasikan sebagai prioritas, dengan penekanan pada pengumpulan sampel Black Pod Rot pada stadium inkubasi awal di mana ambiguitas spektral lesi *Phytophthora palmivora* dengan elemen agroekosistem berpigmen gelap (ranting kering, batang tua, dan pola bayangan kanopi) menjadi sumber kesalahan klasifikasi dominan, serta penambahan citra latar belakang perkebunan Jembrana yang teranotasi sebagai kelas negatif eksplisit (hard negative mining) guna menekan tingkat false positive secara substansial pada iterasi pengembangan model berikutnya.

DAFTAR PUSTAKA

- Abid, M. S. Z., Jahan, B., Mamun, A. A., Hossen, M. J., & Mazumder, S. H. (2024). Bangladeshi Crops Leaf Disease Detection using YOLOv8. *Heliyon*, 10(18).
<https://doi.org/10.1016/j.heliyon.2024.e36694>
- Bischl, B., Binder, M., Lang, M., Pielok, T., Richter, J., Coors, S., Thomas, J., Ullmann, T., Becker, M., Boulesteix, A.-L., Deng, D., & Lindauer, M. (2023). Hyperparameter Optimization: Foundations, Algorithms, Best Practices, and Open Challenges. *WIREs Data Mining and Knowledge Discovery*, (2).
<https://doi.org/10.1002/widm.1484>
- Chen, Z., Wu, R., Lin, Y., Li, C., Chen, S., Yuan, Z., Chen, S., & Zou, X. (2022). Plant Disease Recognition Model Based on Improved YOLOv5. *Agronomy*, 12(2), 365.
<https://doi.org/10.3390/agronomy12020365>
- Gao, Y., Liu, W., Chui, H.-C., & Chen, X. (2024). Large Span Sizes and Irregular Shapes Target Detection Methods Using Variable Convolution-Improved YOLOv8. *Sensors (Basel)*,

- Switzerland), 24(8), 2560.
<https://doi.org/10.3390/s24082560>
- Gomez, D., Selvaraj, M. G., Casas, J., Mathiyazhagan, K., Rodriguez, M., Assefa, T., Mlaki, A., Nyakunga, G., Kato, F., Mukankusi, C., Girma, E., Mosquera, G., Arredondo, V., & Espitia, E. (2024). Advancing Common Bean (*Phaseolus vulgaris* L.) Disease Detection with YOLO Driven Deep Learning to Enhance Agricultural AI. *Scientific Reports*, 14, 15596.
<https://doi.org/10.1038/s41598-024-66281-w>
- Logeshwaran, J., Srivastava, D., Kumar, K. S., Rex, M. J., Al-Rasheed, A., Getahun, M., & Soufiene, B. O. (2024). Improving Crop Production using an Agro-Deep Learning Framework in Precision Agriculture. *BMC Bioinformatics*, 25, 341.
<https://doi.org/10.1186/s12859-024-05970-9>
- Noon, S. K., Amjad, M., Qureshi, M. A., Mannan, A., & Awan, T. (2024). An Improved Detection Method for Crop & Fruit Leaf Disease under Real-Field Conditions. *AgriEngineering*, 6(1), 344–360.
<https://doi.org/10.3390/agriengineering6010021>
- Singh, R., Singh, L. K., Gupta, V. K., & Kaur, M. (2025). Tomato Leaf Disease Detection Using a Hybrid of CNN and Whale Optimization Algorithm. *2025 2nd Global AI Summit - International Conference on Artificial Intelligence and Emerging Technology (AI Summit)*, 393–398.
<https://doi.org/10.1109/AISummit66170.2025.1411119>
- Soekarta, R., Nurdjan, N., & Syah, A. (2023). Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN). *Insect (Informatics and Security): Jurnal Teknik Informatika*, 8(2), 143–151. <https://doi.org/10.33506/insect.v8i2.2356>
- Sykes, J. R., Denby, K. J., & Franks, D. W. (2023). Computer Vision for Plant Pathology: A Review with Examples from Cocoa Agriculture. *Applications in Plant Sciences*, 12(2), e11559.
<https://doi.org/10.1002/aps3.11559>
- Utomo, R. H., Idhom, M., & Trimono, T. (2025). Rice Leaf Disease Classification Using EfficientNetV2 with Hyperparameter Tuning. *Bit-Tech*, 8(2), 2038–2047.
<https://doi.org/10.32877/bt.v8i2.3194>