

ANALISIS PERFORMA DETR UNTUK DETEKSI PENYAKIT PADA BUAH KAKAO

Ni Luh Putu Listya Dewi¹, Putu Manik Prihatini², I Putu Oka Wisnawa³

^{1,2,3} Program Studi Sarjana Terapan Teknologi Rekayasa Perangkat Lunak, Jurusan Teknologi Informasi, Politeknik Negeri Bali, Indonesia

¹listyadewi844@gmail.com, ² manikprihatini@pnb.ac.id, ³ okawisnawa@pnb.ac.id

Abstrak

Kakao merupakan komoditas perkebunan bernilai ekonomi tinggi, namun ancaman infeksi penyakit pada tanaman seringkali memicu penurunan drastis terhadap kualitas maupun kuantitas hasil panen buah kakao. Selama ini, upaya identifikasi dini cenderung mengandalkan observasi visual secara manual yang tidak hanya memakan banyak waktu, melainkan juga sangat rentan terhadap bias subjektivitas pengamat. Untuk mengatasi permasalahan tersebut, studi ini mengusulkan inovasi otomatisasi deteksi penyakit pada buah kakao dengan memanfaatkan teknologi *computer vision*, secara khusus mengimplementasikan algoritma *Detection Transformer* (DETR) berbasis pengolahan citra RGB. Metode penelitian yang dilakukan meliputi pengumpulan dataset citra kakao, *preprocessing*, anotasi *bounding box* pada citra, pelatihan model, dan pengujian model. Model DETR dilatih selama 300 *epoch* dengan menggunakan 720 citra yang dibagi ke dalam data *train*, *validation*, dan *test* dengan perbandingan sebesar 70:15:15. Selanjutnya dilakukan pengukuran kinerja dengan menggunakan metrik *mean Average Precision* (mAP). Hasil eksperimen menunjukkan performa yang sangat kompetitif, dengan model berhasil memperoleh nilai *mean Average Precision* (mAP) sebesar 0.86. Kesimpulan dari penelitian ini membuktikan bahwa arsitektur berbasis transformer mampu memberikan keunggulan dalam ekstraksi fitur penyakit kakao dengan tingkat konvergensi yang stabil meskipun dalam keterbatasan parameter pelatihan. Efektivitas yang dihasilkan memberikan kontribusi signifikan bagi pengembangan sistem monitoring pertanian cerdas yang handal dan ekonomis untuk diimplementasikan dalam skala perkebunan secara nyata.

Kata kunci: DETR, computer vision, deep learning, penyakit buah kakao

1. Pendahuluan

Sebagai negara agraris, Indonesia menempatkan kakao sebagai salah satu komoditas strategis yang menjadi tumpuan sektor perkebunan (Yulia Siska et al., 2025). Komoditas ini tidak hanya menopang perekonomian jutaan petani di berbagai daerah, tetapi juga menyumbang devisa negara secara signifikan. Laporan *International Cocoa Organization* (ICCO) pada tahun 2023 memosisikan Indonesia sebagai produsen kakao terbesar keempat secara global sekaligus yang teratas di kawasan Asia (Dröge et al., 2024). Fakta ini menegaskan besarnya prospek sektor kakao nasional untuk terus dikembangkan di masa mendatang.

Namun, upaya optimalisasi produksi kerap terhambat oleh serangan penyakit tanaman yang memicu kemerosotan hasil panen secara drastis (S. Putra et al., 2022). Secara umum, penyakit pada tanaman mengacu pada proses fisiologis abnormal akibat infeksi patogen yang dapat menghambat pertumbuhan, menurunkan hasil panen, hingga menyebabkan kematian (Gai & Wang, 2024). Salah satu ancaman utama adalah penyakit busuk buah akibat infeksi jamur patogen, yang mengubah fisik buah menjadi coklat kehitaman dan merusak nilai

jualnya di pasaran (Atik et al., 2022; Berckemas et al., 2025). Namun, langkah pengendalian sering terkendala oleh minimnya pemahaman petani. Saat ini, identifikasi penyakit masih sangat mengandalkan inspeksi visual secara manual. Pendekatan ini rentan terhadap bias subjektivitas, berisiko tinggi terjadi salah identifikasi, dan kerap berujung pada keterlambatan penanganan sehingga infeksi menyebar ke pohon lain. Walaupun tindakan preventif mekanis seperti pemangkasan untuk menjaga sirkulasi udara dapat dilakukan (Fauziah Ahmad Abdillah et al., 2024), hal tersebut belum cukup spesifik untuk mengatasi jenis penyakit yang beragam. Maka dari itu, diperlukan sebuah solusi identifikasi yang lebih cepat, otomatis, dan akurat guna memandu langkah penanganan yang tepat sasaran.

Sebagai respons atas keterbatasan inspeksi manual tersebut, pemanfaatan teknologi komputasi cerdas, khususnya *Machine Learning*, menawarkan solusi yang sangat menjanjikan. *Machine Learning* memungkinkan sistem komputasi untuk mempelajari pola dari suatu data secara otomatis melalui proses pelatihan (*training*) dan pengujian (*testing*) guna menghasilkan keputusan yang presisi (Aliwijaya & Suyono, 2023). Mengingat identifikasi penyakit

kakao sangat bergantung pada indikator visual, penerapan kecerdasan buatan ini secara spesifik diarahkan pada domain *Computer Vision*. Bidang ini dirancang agar komputer mampu meniru penglihatan manusia dalam mengekstrak, menganalisis, dan menafsirkan informasi visual berbasis citra guna mendukung pengambilan keputusan dikarenakan bersifat konsisten (Alsakka et al., 2023; Juliandy & Darwin, 2024). Kehadiran *deep learning* yang merupakan sebuah struktur jaringan saraf tiruan dengan banyak lapisan, membuat integrasi kedua bidang ini makin solid terutama karena ketangguhannya dalam mengolah gambar digital yang kompleks.

Berbagai riset terdahulu telah mengeksplorasi potensi *Deep Learning* dalam mendiagnosis penyakit tanaman kakao. Pendekatan berbasis klasifikasi *Convolutional Neural Network* (CNN) telah diimplementasikan oleh (Tovurawa et al., 2025) pada daun kakao dengan akurasi 94%, (Fadhila Tunnur Putri Aji, 2022) pada citra buah dengan akurasi 98%, serta (Komang et al., 2024) yang memanfaatkan ResNet152V2 dengan akurasi 88%. Di sisi lain, metode deteksi objek berbasis bounding box konvensional juga marak digunakan. Studi oleh (Naibaho, 2023; Putu et al., 2025) secara konsisten membuktikan bahwa varian algoritma seperti YOLOv5, YOLOv7, dan YOLOv8 mampu mendeteksi hama dan penyakit pada kakao dengan tingkat akurasi yang kompetitif di atas 87%.


Meskipun metode konvensional seperti CNN, Faster R-CNN (Khan et al., 2025), maupun keluarga YOLO menunjukkan performa yang baik, terdapat celah penelitian (*research gap*) yang membatasi efisiensinya. Sebagian besar model tersebut masih memiliki ketergantungan tinggi pada komponen pasca-pemrosesan yang diatur secara manual (*hand-crafted*), seperti penyesuaian *Anchor Boxes* dan *Non-Maximum Suppression* (NMS). Ketergantungan ini membuat model kurang adaptif saat mendeteksi objek penyakit yang bertumpuk atau memiliki skala ukuran yang sangat bervariasi. Lebih dari itu, model berbasis konvolusi murni sering kali kesulitan untuk menangkap hubungan spasial dan konteks global antar objek dalam satu citra secara komprehensif.

Untuk mengatasi celah penelitian tersebut, penelitian ini mengusulkan pengembangan sistem deteksi penyakit buah kakao menggunakan arsitektur *Detection Transformer* (DETR) yang beroperasi secara eksklusif menggunakan masukan berupa data citra. DETR merupakan kerangka kerja *End-to-End* pertama yang murni berbasis *Transformer*, sehingga sepenuhnya menghilangkan kebutuhan akan komponen manual yang kompleks seperti *Anchor Boxes* dan NMS (Yu et al., 2025) Melalui mekanisme *self-attention*, sistem ini mampu merepresentasikan karakteristik masukan melalui token dan memahami konteks visual global dengan jauh lebih baik (Chen et al., 2023). Potensi keunggulan *transformer* ini telah dibuktikan pada ranah pertanian lain, seperti riset

(Yang et al., 2025) yang berhasil meningkatkan mAP dan efisiensi parameter menggunakan LDW-DETR pada penyakit daun tomat. Melalui implementasi DETR, penelitian ini diharapkan mampu memberikan solusi otomatisasi sistem monitoring yang arsitekturnya lebih ringkas, namun memiliki kemampuan deteksi yang lebih tangguh dan stabil untuk diterapkan di perkebunan kakao.

2. Metode Penelitian

Tahapan penelitian dirancang secara sistematis agar proses eksperimen dapat berlangsung dengan terstruktur dan terarah. Tahapan tersebut meliputi akuisisi data, *data cleaning*, anotasi data, data *split*, *preprocessing* data, *training* model DETR, serta tahapan evaluasi model. Rangkaian tahapan dalam penelitian ini disajikan secara visual pada Gambar 1 di bawah ini.



Gambar 1. Tahapan Penelitian

2.1 Akuisisi Data

Data yang diaplikasikan dalam studi ini merupakan dataset primer, dimana proses pengumpulannya dilakukan secara mandiri oleh peneliti. Data berupa citra buah kakao yang diperoleh secara langsung menggunakan perangkat kamera *smartphone* pada kondisi lingkungan nyata. Pengambilan data dilakukan di Desa Ekasari, dengan beragam kondisi pencahayaan serta sudut pengambilan citra untuk meningkatkan keberagaman dataset.

Seluruh data yang telah dikumpulkan kemudian melalui proses anotasi menggunakan *bounding box* untuk menandai area objek penyakit. Proses anotasi dilakukan menggunakan *tools* anotasi *Roboflow* dan disusun sesuai dengan format yang diperlukan oleh

model DETR. Secara keseluruhan, dataset terdiri dari 300 citra yang dibagi ke dalam tiga kelas, yaitu kelas sehat, busuk buah, dan antraknosa. Masing-masing kelas terdiri dari 100 buah citra.

2.2 Data Cleaning

Langkah pembersihan data (*data cleaning*) merupakan prosedur krusial dalam rangkaian pra-pemrosesan sebelum memasuki fase pelatihan model. Pada tahap ini dilakukan seleksi dan penyaringan ketat terhadap keseluruhan dataset awal dengan mengeliminasi citra yang teridentifikasi duplikat, mengalami keburaman (*blur*), atau memiliki kerusakan berkas (*corrupt*). Tujuannya untuk menghindari bias pembelajaran dan mencegah terjadinya kebocoran data yang dapat memicu *overfitting*. Sementara itu, eliminasi citra yang buram dilakukan karena kondisi tersebut dapat mengaburkan karakteristik visual dan tekstur spesifik dari penyakit buah kakao

2.3 Anotasi Data

Anotasi data dilakukan dengan proses *labeling* pada citra berwarna dan penggambaran *bounding box* secara presisi mengelilingi objek target sesuai dengan kelasnya, yaitu sehat, busuk buah, dan antraknosa. Gambar 2 merupakan contoh anotasi citra yang dilakukan.



Gambar 2. Anotasi Citra Kelas Busuk Buah, Sehat, dan Antraknosa

Gambar 2 di atas mengilustrasikan contoh hasil anotasi pada tiga kelas data yang digunakan. Pada citra sebelah kiri, *bounding box* menandai area buah kakao yang terinfeksi penyakit busuk buah. Citra di bagian tengah menunjukkan anotasi pada buah kakao yang sehat, sedangkan citra di sebelah kanan menunjukkan penandaan pada buah yang terinfeksi penyakit antraknosa. Pemberian *bounding box* ini bertujuan untuk menentukan titik koordinat lokasi objek di dalam citra, yang nantinya akan diekstrak beserta label kelasnya sebagai informasi kebenaran dasar (*ground truth*) untuk proses pelatihan model deteksi objek (P. Y. Putra et al., 2023). Seluruh informasi hasil anotasi direpresentasikan menggunakan standar format *Common Object in Context* (COCO) JSON.

Guna menjamin validitas data, kebenaran kelas pada seluruh dataset citra buah kakao dalam penelitian ini telah melalui tahapan validasi pakar. Proses verifikasi ini dilakukan secara langsung oleh Penyuluh Pertanian Lapangan (PPL) kecamatan Melaya, yang bertugas di bawah naungan Dinas Pertanian, Perikanan, dan Pangan Kabupaten Jembrana, Bali. Dengan adanya validasi tersebut,

dataset yang digunakan dalam pelatihan model memiliki tingkat kredibilitas yang tinggi dan dapat dipertanggungjawabkan secara ilmiah.

2.4 Data Split

Pasca anotasi, dilakukan pemisahan dataset menjadi tiga himpunan utama. Proporsi dataset didistribusikan menjadi 70% untuk proses pelatihan, 15% sebagai data validasi, dan 15% sisanya dialokasikan untuk pengujian model. Adapun distribusi pembagian data dapat dilihat pada Tabel 1.

Tabel 1. Distribusi Pembagian Data

Jenis Data	Jumlah
Data Latih	630
Data Validasi	45
Data Uji	45

- Data latih (*training set*) sebanyak 70%, dimanfaatkan untuk pelatihan model dalam mengidentifikasi pola dan karakteristik penyakit pada buah kakao.
- Data validasi (*validation set*) sebanyak 15%, dimanfaatkan selama proses pelatihan berlangsung guna memantau performa model secara rutin serta membantu dalam penyesuaian parameter untuk mencegah terjadinya *overfitting*.
- Tahap akhir pengujian menggunakan 15% data uji (*test set*) yang berisi citra-citra baru dan belum pernah dipelajari oleh model. Hal ini bertujuan untuk mengukur keandalan model secara objektif sehingga hasil evaluasinya benar-benar merepresentasikan kemampuan model di lapangan.

2.5 Preprocessing Data

Tahap ini merupakan langkah krusial dalam mempersiapkan data masukan berupa citra berwarna sebelum dilatih pada model DETR. Proses ini bertujuan untuk menyeragamkan format citra dan memperkaya variasi representasi visual agar model memiliki kemampuan generalisasi yang lebih baik terhadap kondisi nyata di lapangan. Rangkaian proses pada tahap ini meliputi:

- Penyesuaian Resolusi (*Resizing*) merupakan proses dimana seluruh citra buah kakao diubah ukurannya (*resize*) untuk menyesuaikan dengan standar dimensi masukan yang dibutuhkan oleh arsitektur model DETR, khususnya untuk mengoptimalkan ekstraksi fitur pada *Backbone* ResNet-50. Penyesuaian ini memastikan bahwa fitur spasial dari objek target tidak terdistorsi secara signifikan.
- Normalisasi Nilai Pixel yakni rentang nilai intensitas piksel pada ketiga kanal warna (RGB) dinormalisasi. Normalisasi ini berfungsi untuk menstabilkan gradien selama


proses optimasi, sehingga mempercepat waktu konvergensi model saat fase pelatihan.

- Augmentasi Data berguna untuk mengatasi keterbatasan jumlah dataset dan mencegah terjadinya *overfitting*. Teknik augmentasi diterapkan secara ekstensif pada data latih. Parameter transformasi dirancang untuk menyimulasikan variasi kondisi lingkungan di perkebunan kakao yang meliputi transformasi spasial (*flip, rotation, crop, dan shear*), variasi fotometrik (*hue, saturation, brightness, dan exposure*), simulasi penurunan kualitas (*blur dan noise*)

Penerapan metode augmentasi spasial dan fotometrik ini berhasil mengekspansi dataset latih dengan menghasilkan tambahan 720 citra baru. Peningkatan kuantitas dan variasi fitur visual ini diharapkan dapat memperkuat performa model dalam mendeteksi dan mengklasifikasikan kelas sehat, busuk buah, dan antraknosa dengan tingkat akurasi yang lebih tinggi.

2.6 Training Model DETR

Model yang diterapkan adalah DETR dengan *backbone* ResNet-50. Ilustrasi arsitektur model DETR digambarkan pada Gambar 3.



Gambar 3. Arsitektur Model DETR (Sumber : Rizqi Okta Ekoputris, 2021)

Arsitektur DETR pada Gambar 3 memanfaatkan *Convolutional Neural Network* (CNN), secara spesifik menggunakan arsitektur ResNet-50 sebagai *backbone* untuk menghasilkan fitur representasi dua dimensi dari citra masukan. Fitur-fitur visual yang dihasilkan kemudian diratakan (*flattened*) dan diintegrasikan dengan informasi posisi spasial (*positional encoding*) sebelum diproses lebih lanjut oleh modul *transformer encoder*. Selanjutnya *transformer decoder* menerima sejumlah kecil representasi posisi yang dapat dipelajari, yang dikenal sebagai *object queries*, sekaligus melakukan komputasi attention terhadap hasil keluaran dari *encoder*. Pada tahap akhir, setiap representasi (*embedding*) yang dihasilkan oleh *decoder* diteruskan menuju arsitektur *Feed Forward Network* (FFN) untuk menghasilkan prediksi akhir. Prediksi ini mencakup identifikasi kelas target (sehat, busuk buah, dan antraknosa), koordinat kotak pembatas (*bounding box*), maupun memprediksi ketiadaan objek (*no object*) pada area tersebut.

Eksperimen pelatihan model dijalankan menggunakan akselerator komputasi grafis berupa NVIDIA GeForce RTX 3050 6GB. Dalam proses tersebut, model dievaluasi menggunakan serangkaian variasi *hyperparameter*. Variasi *hyperparameter*

yang dioperasikan pada penelitian ini, seperti *learning rate, backbone learning rate, epoch, batch size, dan GloU loss weight* memiliki tujuan untuk mendapatkan konfigurasi terbaik yang menghasilkan keseimbangan antara akurasi dan stabilitas model. Kombinasi parameter yang tepat akan membantu mode mencapai konvergensi lebih cepat serta menghasilkan performa deteksi yang optimal. Rincian dari seluruh konfigurasi parameter pelatihan yang diujikan dipetakan pada Tabel 2.

Tabel 2. Hyperparameter Pengujian

No	Hyperparameter	Nilai Uji
1	Learning Rate	1e-5, 5e-5 dan 1e-4
2	Backbone Learning Rate	1e-6, 1e-5
3	Epoch	100, 300, 500
4	Batch Size	2
5	GloU Loss Weight	2

Berdasarkan Tabel 2, pengujian parameter pada penelitian ini tidak menerapkan kombinasi persilangan secara menyeluruh terhadap semua nilai yang tersedia. Terdapat batasan arsitektural pada model DETR yang mewajibkan konfigurasi *learning rate* untuk *backbone* ResNet-50 harus bernilai lebih kecil, umumnya dengan skala logaritmik satu tingkat lebih rendah dibandingkan dengan *learning rate* utama (*transformer head*).

Batasan ini merujuk pada landasan teoritis yang menyatakan bahwa arsitektur *backbone* pada umumnya memanfaatkan bobot pralatih (*pre-trained weights*) yang diekstraksi dari dataset berukuran masif, sehingga sudah memiliki representasi fitur visual yang matang (Liu et al., 2022). Penggunaan nilai *learning rate* yang setara atau lebih besar dari *learning rate* utama akan berisiko merusak bobot *pre-trained* tersebut (*catastrophic forgetting*). Sebaliknya, modul *transformer head* diinisialisasi dari awal sehingga memerlukan *learning rate* yang relatif lebih besar untuk beradaptasi dengan dataset penyakit kakao secara spesifik. Maka dari itu, pada konfigurasi model terbaik di penelitian ini, diterapkan *learning rate* utama sebesar 5e-05 yang dipasangkan dengan *backbone learning rate* sebesar 1e-06. Konfigurasi spesifik ini terbukti efektif dalam menjaga stabilitas ekstraksi fitur *backbone* sekaligus mengoptimalkan konvergensi model pada saat proses pelatihan.

2.7 Evaluasi Model

Evaluasi dilaksanakan dengan memanfaatkan data uji untuk mengukur performa model. Penelitian ini menggunakan *mean Average Precision* (mAP) sebagai metrik primer guna menguji reliabilitas model dalam mengenali objek secara presisi dan stabil.

Perhitungan dilakukan dengan mengambil rata-rata nilai akurasi pada semua posisi ketika dokumen atau artikel berita yang relevan ditemukan. Rata-rata presisi ini kemudian dirata-rata lagi untuk

memperoleh nilai mAP sebagaimana digambarkan pada Persamaan (1).

$$mAP = \frac{1}{C} \sum_{C=1}^C AP_C \quad (1)$$

Keterangan:

mAP = *mean Average Precision* adalah metrik evaluasi utama untuk mengukur performa model

AP_C = nilai *Average Precision* untuk kelas ke-C

Sebelum menghitung mAP, perlu dilakukan perhitungan untuk mencari *Average Precision* (AP). AP dihitung dari *Precision-Recall Curve* (PR), yaitu hubungan antara *precision* dan *recall* pada beragam *threshold confidence*. Adapun metode perhitungan AP yaitu pada Persamaan (2).

$$AP = \sum_{n=1}^N R_n - R_{n-1} \cdot P_n \quad (2)$$

Keterangan:

AP = *Area Under Curve* (AUC) dari *Precision-Recall*

P_n = *precision* pada titik ke-n

R_n = *recall* pada titik ke-n

R_n - R_{n-1} = selisih *recall* antar titik

N = jumlah titik pada kurva PR

Metrik *Intersection over Union* (IoU) diaplikasikan sebagai standar utama dalam komparasi antara *bounding box* prediksi dengan *ground truth*. Merujuk pada nilai IoU dan ambang batas (*threshold*) yang ditetapkan, hasil prediksi kemudian dikategorikan menjadi *True Positive* (TP), *False Positive* (FP), atau *False Negative* (FN).

Merujuk pada pengelompokan tersebut, diperoleh nilai untuk menghitung *precision* dan *recall*. *Precision* dan *recall* dihitung untuk berbagai *confidence threshold*, kemudian digambarkan dalam kurva *Precision-Recall*. Perhitungan AP dilakukan melalui cara mengukur luas area pada bawah kurva *Precision-Recall*. Berdasarkan nilai AP, nilai mAP dapat diperoleh sebagai rata-rata AP dari seluruh kelas objek yang dievaluasi. Persamaan (3) digunakan untuk menghitung IoU.

$$IoU = J(BB_{predict}, BB_{ground}) = \frac{\text{area of intersection of predicted and ground truth boxes}}{\text{area of union of predicted and ground truth boxes}} \quad (3)$$

Keterangan:

IoU = nilai evaluasi yang mengukur tumpang tindih antara dua kotak atau *Bounding Boxes* (BB)

BB_{predict} = kotak pembatas yang diperoleh dari model

BB_{ground} = kotak pembatas sebenarnya sebagai acuan

J = melambangkan fungsi *Jaccard Similarity Coefficient*, yaitu metode statistik untuk membandingkan kemiripan antara dua himpunan

Penghitungan *precision* bisa menggunakan Persamaan (4).

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} = \frac{True\ Positive}{All\ Observations} \quad (4)$$

Keterangan :

Precision = perbandingan prediksi benar dengan semua prediksi model

True Positive = kondisi dimana model mendeteksi objek dengan benar

False Positive = kondisi dimana model gagal mendeteksi

All Observations = semua hasil deteksi oleh model, baik benar ataupun salah

Perhitungan *recall* bisa dilakukan menggunakan Persamaan (5).

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} = \frac{True\ Positive}{All\ Ground\ Truth} \quad (5)$$

Keterangan :

Recall = kemampuan model dalam mendeteksi seluruh objek yang benar ada

False Negative = kondisi saat model gagal mendeteksi objek yang sebenarnya ada

All Ground Truth = semua objek asli yang benar-benar ada di dalam dataset

Evaluasi dilakukan menggunakan tiga skema mAP, yaitu:

- mAP@0.5
Dengan menerapkan ambang batas IoU sebesar 0.5, skema pengukuran ini dirancang untuk mengevaluasi keandalan model dalam mengenali objek secara umum, sembari memberikan toleransi yang *relative* longgar terhadap ketidakakuratan posisi *bounding box*.
- mAP@0.75
Menggunakan *threshold* IoU sebesar 0.75. Skema ini memberikan evaluasi yang lebih ketat dibandingkan mAP@0.5, karena memerlukan kesesuaian *bounding box* yang lebih presisi.
- mAP@0.5:0.95

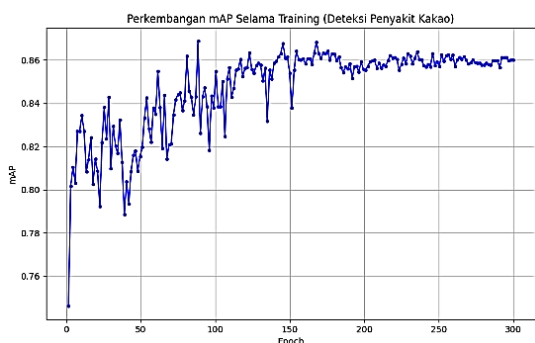
Metrik ini merepresentasikan nilai rerata mAP yang dihitung pada serangkaian *threshold* IoU, dimulai dari angka 0.5 hingga mencapai angka 0.95 dengan interval peningkatan sebesar 0.05. Pendekatan ini menyajikan skema evaluasi yang paling komprehensif, karena kapabilitas model diuji secara menyeluruh melintasi berbagai tingkatan presisi deteksi.

3. Hasil dan Pembahasan

3.1 Hasil Eksperimen

Visualisasi pada Gambar 4 menunjukkan kurva perkembangan nilai *mean Average Precision* (mAP) selama proses pelatihan model deteksi penyakit pada

buah kakao yang dilakukan selama 300 *epoch*. Berdasarkan grafik tersebut, proses pembelajaran model dapat dibagi menjadi tiga fase utama.

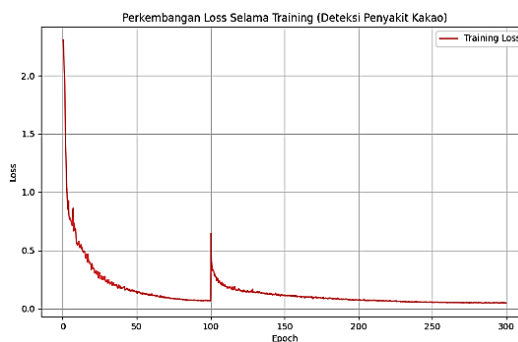


Gambar 4. Kurva nilai mAP

1. Fase Pembelajaran Awal (*Epoch* 1-50)
 Pada fase ini, model menunjukkan peningkatan nilai mAP yang sangat signifikan dan cepat, bergerak dari angka yang rendah (sekitar 0.74) menembus angka 0.84. Peningkatan tajam ini menandakan bahwa model mengenali pola-pola dasar dan fitur visual utama dari citra RGB buah kakao yang diberikan dengan cepat.
2. Fase Fluktuasi dan Eksplorasi (*Epoch* 50-150)
 Memasuki pertengahan pelatihan, grafik menunjukkan fluktuasi yang cukup tinggi dengan lonjakan mAP maksimum dan penurunan yang tajam secara bergantian. Pemanfaatan *batch size* yang kecil menyebabkan penyesuaian bobot (*weight update*) pada model menjadi lebih sensitif terhadap variasi data pada setiap iterasinya, sehingga menghasilkan kurva yang bergejolak saat model berusaha mencari titik optimal.
3. Fase Konvergensi (*Epoch* 150-300)
 Setelah melewati *epoch* 150, model mulai menunjukkan tanda-tanda konvergensi. Kurva pergerakan mAP menjadi jauh lebih stabil dengan rentang variasi yang sangat sempit, bertengger secara konsisten di kisaran angka 0.85 hingga 0.86. Kestabilan di akhir proses pelatihan ini membuktikan bahwa model telah menemukan representasi fitur yang optimal untuk mendeteksi penyakit pada buah kakao dan tidak menunjukkan tanda-tanda penurunan performa yang mengidentifikasi *overfitting*.

Gambar 5 menggambarkan pergerakan nilai *Training Loss* selama proses pelatihan model pendeteksi penyakit pada buah kakao yang berlangsung selama 300 *epoch*. Nilai *loss* merepresentasikan tingkat kesalahan prediksi model, yang mana jika nilainya semakin mendekati nol maka semakin akurat model dalam memetakan fitur citra. Pada awal pelatihan nilai *loss* menurun secara tajam dari angka 2.0 hingga menyentuh 0.5 yang mengindikasikan bahwa arsitektur DETR mampu beradaptasi dan mengenali fitur visual objek dengan

sangat cepat. Meskipun terdapat lonjakan kesalahan sesaat (*spike*) tepat pada *epoch* ke-100 yang mengindikasikan adanya penyesuaian parameter sistem seperti *learning rate*, model menunjukkan ketahanan yang baik dengan langsung memulihkan proses penurunannya. Memasuki akhir pelatihan, kurva melandai secara konsisten dan stabil mendekati angka 0.05. Kestabilan di nilai yang sangat rendah ini menegaskan bahwa model telah mencapai konvergensi optimal dan berhasil meminimalkan kesalahan prediksi secara maksimal.



Gambar 5. Kurva *Training Loss*

Gambar 6 menampilkan visualisasi hasil deteksi menggunakan model DETR terbaik terhadap beberapa sampel citra RGB buah kakao dari *testing set* yang belum pernah dikenali oleh model saat proses pelatihan berlangsung. Setiap objek yang berhasil dideteksi akan divisualisasikan menggunakan *bounding box* dan label penyakit, beserta *confidence score*. Nilai keyakinan ini berfungsi sebagai indikator yang merepresentasikan seberapa besar tingkat kepastian model terhadap kebenaran prediksinya.



Gambar 6 Hasil Prediksi Penyakit Buah Kakao

Berdasarkan visualisasi tersebut, kinerja model dapat dianalisis sebagai berikut:

1. Deteksi Kelas Antraknosa
 Model berhasil mendeteksi keberadaan penyakit antraknosa dengan skor keyakinan yang sangat tinggi yaitu 0.93 (93%).
2. Deteksi Kelas Busuk Buah
 Pengujian ini menunjukkan ketangguhan (*robustness*) model dalam menangani lebih dari satu objek dalam satu frame. Model mendeteksi penyakit busuk buah pada objek utama di latar depan dengan skor 0.95, melokalisasi area nekrotik (pembusukan berwarna gelap) yang jelas pada bagian bawah buah. Model juga

mampu mendeteksi penyakit buah kakao lain yang terinfeksi di latar belakang dengan skor 0.60, meskipun objek tersebut berukuran kecil dan sebagian terpotong oleh frame gambar.

3. Deteksi Kelas Sehat

Model mengklasifikasikan buah kakao yang bebas dari penyakit dengan tingkat keyakinan hampir sempurna, yaitu 0.99 (99%). Hal ini membuktikan bahwa model tidak hanya sensitif terhadap fitur penyakit, tetapi juga mampu membedakan dengan tegas karakteristik fisik buah kakao yang normal dari yang terinfeksi sehingga dapat menekan risiko *false positive*.

4. Kesimpulan

Penelitian ini telah berhasil mengembangkan dan mengimplementasikan arsitektur DETR untuk keperluan deteksi otomatis penyakit pada buah kakao menggunakan dataset citra RGB. Evaluasi performa menunjukkan hasil yang sangat baik dengan capaian nilai *mean Average Precision* (mAP) keseluruhan sebesar 0.86. Visualisasi hasil inferensi lebih lanjut menegaskan ketangguhan model dalam mengklasifikasikan kelas penyakit dan melokalisasi target dengan *bounding box* yang presisi, bahkan dalam kondisi buah kakao yang saling bertumpuk.

Sebagai saran untuk riset lanjutan (*future works*), penelitian mendatang direkomendasikan untuk mengoptimalkan pengaturan *logging* saat pelatihan agar dapat merekam nilai AP untuk masing-masing kelas penyakit secara spesifik, sehingga analisis kesulitan deteksi visual per kelas dapat dilakukan secara lebih mendalam. Studi komparatif juga perlu dilakukan secara eksperimental antara arsitektur DETR dengan algoritma lain yang berfokus pada kecepatan seperti varian YOLO, khususnya membandingkan metrik kecepatan inferensi (*Frames Per Second*).

Daftar Pustaka:

- Aliwijaya, A., & Suyono, H. C. (2023). *Peluang Pemanfaatan Big Data di Perpustakaan*. Info Bibliotheca: Jurnal Perpustakaan Dan Ilmu Informasi, 4(2), 1–17. <https://doi.org/10.24036/IB.V4I2.397>
- Alsakka, F., Assaf, S., El-Chami, I., & Al-Hussein, M. (2023). *Computer vision applications in offsite construction*. Automation in Construction, 154, 104980. <https://doi.org/10.1016/J.AUTCON.2023.104980>
- Atik, A., Hasanah, N., Suwondo, A., & Artikel, R. (2022). *Identifikasi organisme pengganggu tanaman pada buah kakao menggunakan algoritma forward chaining berbasis web*. Storage: Jurnal Ilmiah Teknik Dan Ilmu Komputer, 1(2), 23–33. <https://doi.org/10.55123/STORAGE.V1I2.324>
- Berckemas, Y., Eka, P., Ariati, P., & Sujana, P. (2025). *Eksplorasi kejadian penyakit busuk buah (phytophthora palmivora) pada tanaman kakao di desa cau kecamatan marga kabupaten tabanan*. Agrofarm: Jurnal Agroteknologi, 4(1), 30–36. <https://doi.org/10.36733/AGROFARM.V4I1.11787>
- Chen, Y., Chen, S., Deng, Y., & Wang, K. (2023). *HA-Transformer: Harmonious aggregation from local to global for object detection*. Expert Systems with Applications, 230, 120539. <https://doi.org/10.1016/J.ESWA.2023.120539>
- Dröge, S., Bemelmans, J., Depoorter, C., Jusrin, M. J. M., Marx, A., Verbist, B., Prasetyo, L. B., Maertens, M., & Muys, B. (2024). *From chocolate to palm oil: The future of Indonesia's cocoa plantations*. Ambio, 54(1), 151–161. <https://doi.org/10.1007/S13280-024-02061-0/METRICS>
- Fadhila Tunnur Putri Aji. (2022). *Identifikasi jenis penyakit buah kakao (theobroma cacao l.) Berbasis citra buah menggunakan metode deep learning convolutional neural networks (cnn)*.
- Fauziyah Ahmad Abdillah, Fitria Nugraheni, & Muhammad Asmar. (2024). *Perbandingan Metode Pemangkasan untuk Mencapai Efisiensi Maksimum dalam Tim Pemangkasan Tanaman Kakao (Theobroma cacao L.) di Mars Cocoa Research Station, Pangkep, Sulawesi Selatan*. Prosiding Seminar Nasional Pembangunan Dan Pendidikan Vokasi Pertanian, 5(1), 1372–1380. <https://doi.org/10.47687/SNPPVP.V5I1.1209>
- Gai, Y., & Wang, H. (2024). *Plant Disease: A Growing Threat to Global Food Security*. Agronomy 2024, Vol. 14, Page 1615, 14(8), 1615. <https://doi.org/10.3390/AGRONOMY14081615>
- Juliandy, C., & Darwin, D. (2024). *Pengenalan Computer Vision Berbasis Convolutional Neural Network melalui DewataTalks*. Sarwahita, 21(01), 45–52. <https://doi.org/10.21009/SARWAHITA.211.4>
- Khan, Z., Shen, Y., & Liu, H. (2025). *ObjectDetection in Agriculture: A Comprehensive Review of Methods, Applications, Challenges, and Future Directions*. Agriculture 2025, Vol. 15, Page 1351, 15(13), 1351. <https://doi.org/10.3390/AGRICULTURE15131351>
- Komang, I., Pariyana, T. A., Agung, A., Mahendra, N., Putra, A., Sumartana, G. G., & Prathama, J. D. (2024). *Identifikasi penyakit buah kakao jembrana menggunakan metode resnet152v2*. JOURNAL OF INFORMATICS ENGINEERING AND TECHNOLOGY, 5(1), 12–20.

- <https://jietech.triatmamulya.ac.id/index.php/Jietech/article/view/70>
- Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). *A ConvNet for the 2020s*. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2022-June, 11966–11976. <https://doi.org/10.1109/CVPR52688.2022.01167>
- Naibaho, D. M. T. (2023). *Deep learning Model Untuk Deteksi Hama dan Penyakit Pada Buah Kakao (Theobroma cacao L.)*. <http://repository.ipb.ac.id/handle/123456789/121856>
- Putra, P. Y., Seto Arifianto, A., Fitri, Z. E., Puspitasari, T. D., Informatika, T., Informasi, J. T., & Jember, P. N. (2023). *Deteksi Kendaraan Truk pada Video Menggunakan Metode Tiny-YOLO v4*. Jurnal Informatika Polinema, 9(2), 215–222. <https://doi.org/10.33795/JIP.V9I2.1243>
- Putra, S., Ferry, Y., & Harni, R. (2022). *Pengendalian penyakit busuk buah kakao menggunakan Trichoderma dan pupuk Kalium*. Kultivasi, 21(2), 173–180. <https://doi.org/10.24198/kultivasi.v21i2.36807>
- Putu, I., Wisnawa, O., Nyoman, N., Puspita, H., Bagus, P., Pradnyana, A., Komang Wiratama, I., Dwi, M., & Sulastra, J. (2025). *Deep Learning-Based Computer Vision Framework for Early Detection of Cocoa Plant Diseases in Precision Agriculture*. 233–242. https://doi.org/10.2991/978-94-6463-878-3_27
- Rizqi Okta Ekoputris. (2021). *Review Metode Objek Deteksi: DETR — End-to-End Object Detection with Transformers | by Rizqi Okta Ekoputris | Data Science Indonesia | Medium*. <https://medium.com/data-science-indo/review-metode-objek-deteksi-end-to-end-object-detection-with-transformers-a43d1baa681>
- Tovurawa, E., Dlamini, B., Moore, S. E., Marivate, V., & Modupe, A. (2025). *Cacao Plant Disease Detection and Classification*. <https://doi.org/10.21203/RS.3.RS-5763786/V1>
- Yang, H., Xue, H., Lyu, Y., Mu, M., Tang, T., & Huang, Z. (2025). *LDW-DETR: An Efficient Tomato Leaf Disease Detection Algorithm Based on Enhanced RT-DETR*. Applied Sciences 2025, Vol. 15, Page 11620, 15(21), 11620. <https://doi.org/10.3390/APP152111620>
- Yu, L., Tang, L., & Mu, L. (2025). *A Review of DETECTION TRansformer: From Basic Architecture to Advanced Developments and Visual Perception Applications*. Sensors (Basel, Switzerland), 25(13), 3952. <https://doi.org/10.3390/S25133952>
- Yulia Siska, Rahmi, Zulhelmi, & Sandra Dewi. (2025). *Strategi Petani Kakao Dalam Meningkatkan Produksi Dari Perspektif Ekonomi Islam (Studi Kasus: Kecamatan Padang Gelugur, Kabupaten Pasaman)*. ISTIKHLAF: Jurnal Ekonomi, Perbankan Dan Manajemen Syariah, 7, 175–190.