E-ISSN : 2962-9713
P-ISSN : 2963-928X

Analisis Perbandingan YOLO11, YOLO26, Dan RF-DETR Untuk Deteksi Kematangan Pisang Serta Implementasi Pada Aplikasi Mobile

Geovani Pradipta Nurbelen[1], Monalisa Hermina mose[2], Raflif Fadhlurrohman[3], Waeisul Bismi[4], Imam Budiawan[5], Nila Hardi[6],
[1]Universitas Bina Sarana Informatika, 15240052@bsi.ac.id
[2]Universitas Bina Sarana Informatika, 15240174@bsi.ac.id
[3]Universitas Bina Sarana Informatika, 15240526@bsi.ac.id
[4]Universitas Bina Sarana Informatika, Waeisul.wbn@bsi.ac.id
[5]Universitas Bina Sarana Informatika, imam.imb@bsi.ac.id
[6]Universitas Bina Sarana Informatika, nila.nad@bsi.ac.id

Abstrak

Deteksi tingkat kematangan pisang secara otomatis dapat membantu pengguna mengenali kondisi buah melalui citra digital. Penelitian ini bertujuan membandingkan kinerja tiga model deteksi objek, yaitu YOLO11 Small, YOLO26 Small, dan RF-DETR Small, serta mengimplementasikan model terpilih pada aplikasi mobile Banana Ripeness Vision. Penelitian menggunakan dataset citra pisang yang sama untuk ketiga model, terdiri atas 7.546 citra dengan enam kelas, yaitu FreshRipe, FreshUnripe, Overripe, Ripe, Rotten, dan Unripe. Dataset dibagi menjadi 5.264 citra pelatihan, 1.525 citra validasi, dan 757 citra pengujian. Evaluasi kinerja menggunakan metrik precision, recall, F1-score, dan mean Average Precision pada ambang Intersection over Union 0,50 (mAP@50). YOLO11 Small memperoleh mAP@50 sebesar 88,7%, precision 89,6%, recall 87,6%, dan F1-score 88,6%. YOLO26 Small memperoleh mAP@50 sebesar 90,3%, precision 87,3%, recall 88,7%, dan F1-score 87,9%. RF-DETR Small memperoleh mAP@50 sebesar 94,9%, precision 88,6%, recall 90,0%, dan F1-score 89,3%. RF-DETR Small menghasilkan mAP@50, recall, dan F1-score tertinggi berdasarkan hasil evaluasi yang tercatat. Model tersebut diintegrasikan ke dalam aplikasi Flutter dengan memanfaatkan Roboflow Hosted API dan Supabase. Hasil penelitian menunjukkan potensi RF-DETR Small untuk mendukung deteksi tingkat kematangan pisang melalui aplikasi mobile.

Kata Kunci: *Deteksi Objek, Kematangan Pisang, YOLO11, YOLO26, RF-DETR.*

Abstract

Automatic banana ripeness detection can help users identify fruit conditions through digital images. This study aims to compare three object detection models, namely YOLO11 Small, YOLO26 Small, and RF-DETR Small, and implement the selected model in the Banana Ripeness Vision mobile application. The same banana image dataset was used for all three models, comprising 7,546 images across six classes: FreshRipe, FreshUnripe, Overripe, Ripe, Rotten, and Unripe. The dataset was divided into 5,264 training images, 1,525 validation images, and 757 test images. Model performance was evaluated using precision, recall, F1-score, and mean Average Precision at an Intersection over Union threshold of 0.50 (mAP@50). YOLO11 Small achieved an mAP@50 of 88.7%, precision of 89.6%, recall of 87.6%, and F1-score of 88.6%. YOLO26 Small achieved an mAP@50 of 90.3%, precision of 87.3%, recall of 88.7%, and F1-score of 87.9%. RF-DETR Small achieved an mAP@50 of 94.9%, precision of 88.6%, recall of 90.0%, and F1-score of 89.3%. Based on the recorded evaluation results, RF-DETR Small obtained the highest mAP@50, recall, and F1-score. The

E-ISSN : 2962-9713
P-ISSN : 2963-928X

selected model was integrated into a Flutter application using the Roboflow Hosted API and Supabase. These findings indicate the potential of RF-DETR Small for banana ripeness detection in a mobile application.

Keywords: *Object Detection, Banana Ripeness, YOLO11, YOLO26, RF-DETR.*

Corresponding Author:
Geovani Pradipta Nurbelen

Universitas Bina Sarana Informatika; 15240052@bsi.ac.id

PENDAHULUAN

Pisang merupakan salah satu buah yang banyak dikonsumsi masyarakat dan memiliki karakteristik visual yang berubah selama proses pematangan. Perubahan warna kulit dan kondisi fisik dapat menjadi petunjuk untuk membedakan tingkat kematangan pisang. Namun, penilaian kematangan secara visual masih dapat dipengaruhi oleh subjektivitas pengamat sehingga hasilnya berpotensi tidak konsisten. Permasalahan tersebut juga dibahas oleh (Ramadhan & Pramana, 2026), yang menerapkan metode Convolutional Neural Network (CNN) untuk mengenali tingkat kematangan pisang berdasarkan citra. Pendekatan berbasis deep learning dapat dimanfaatkan untuk membantu proses pengenalan tingkat kematangan secara otomatis. Dalam penelitian ini, pendekatan object detection digunakan untuk mendeteksi tingkat kematangan pisang sekaligus menentukan lokasi objek pada gambar. Kinerja model dievaluasi menggunakan metrik precision, recall, F1-score, mean Average Precision (mAP), serta waktu respons API untuk membandingkan kemampuan deteksi dan kecepatan inferensi.

Seiring berkembangnya metode object detection, pemilihan model yang sesuai menjadi penting untuk memperoleh hasil deteksi yang baik. Penelitian ini membandingkan YOLO11 Small, YOLO26 Small, dan RF-DETR Small berdasarkan perbedaan generasi dan pendekatan arsitekturnya. YOLO11 Small merepresentasikan generasi YOLO dari Ultralytics yang lebih dahulu dirilis, sedangkan YOLO26 Small merupakan generasi yang lebih baru dengan sejumlah pembaruan arsitektur dan mekanisme inferensi. (Hidayatullah et al., 2026), menjelaskan bahwa YOLO26 mengadopsi beberapa perubahan, termasuk penghilangan Distribution Focal Loss (DFL) dan inferensi end-to-end tanpa Non-Maximum Suppression (NMS), yang ditujukan untuk meningkatkan efisiensi proses deteksi. Penerapan YOLOv8 Nano untuk mendeteksi fase pertumbuhan jamur tiram oleh (Nopiandi et al., 2025) juga menunjukkan pemanfaatan keluarga model YOLO untuk tugas deteksi objek. Sementara itu, RF-DETR Small menjadi pembanding dengan pendekatan deteksi berbasis transformer yang dikembangkan oleh Roboflow. Perbandingan ketiga model ini digunakan untuk mengevaluasi kinerja deteksi tingkat kematangan pisang berdasarkan metrik yang telah ditentukan.

Untuk menempatkan perbandingan tersebut dalam konteks penelitian yang lebih luas, penelitian terdahulu mengenai penerapan model kecerdasan buatan pada pengolahan citra juga perlu diperhatikan.(Futri et al., 2025), menerapkan Vision Transformer untuk mengklasifikasikan jenis kulit wajah dan mengintegrasikannya ke dalam aplikasi berbasis website. Sementara itu, (Saputra & Yanni, 2025) menerapkan

E-ISSN : 2962-9713
P-ISSN : 2963-928X

YOLOv8 untuk mendeteksi kualitas pisang berdasarkan kategori Good Quality Banana dan Bad Quality Banana. Kedua penelitian tersebut menunjukkan penerapan model pengolahan citra pada objek dan kebutuhan aplikasi yang berbeda. Berbeda dari penelitian tersebut, penelitian ini membandingkan YOLO11 Small, YOLO26 Small, dan RF-DETR Small untuk mendeteksi enam kelas tingkat kematangan pisang serta mengimplementasikan model terpilih pada aplikasi Banana Ripeness Vision.

Perbandingan ketiga model dilakukan menggunakan dataset yang sama, dengan evaluasi berdasarkan precision, recall, F1-score, mAP@50, mAP@50:95, dan waktu respons API. Penelitian (Sapkota et al., 2025) juga membandingkan model YOLO dan RF-DETR untuk deteksi buah dalam lingkungan kebun yang kompleks, sehingga relevan sebagai penelitian pembanding dalam bidang deteksi objek pertanian. Meskipun sumber data yang digunakan sama, beberapa konfigurasi preprocessing dan augmentasi mengikuti pengaturan masing-masing model. Dengan demikian, hasil evaluasi ditafsirkan berdasarkan konfigurasi eksperimen yang diterapkan, bukan sebagai perbandingan dalam kondisi pelatihan yang sepenuhnya identik.

Selain membandingkan kinerja model, penelitian ini mengimplementasikan model terpilih pada Banana Ripeness Vision, aplikasi berbasis Flutter yang dapat diakses melalui Progressive Web App (PWA) dan perangkat Android. Penerapan model deteksi objek ke dalam aplikasi Flutter juga dilakukan oleh (Wisnawa et al., 2026) untuk mendeteksi penyakit pada buah kakao melalui perangkat Android. Roboflow Hosted API digunakan untuk menjalankan inferensi model, sedangkan Supabase mendukung autentikasi dan pengelolaan data aplikasi. Implementasi ini memungkinkan hasil evaluasi model diterapkan dalam aplikasi yang memproses gambar pisang dan menampilkan hasil deteksi kepada pengguna.

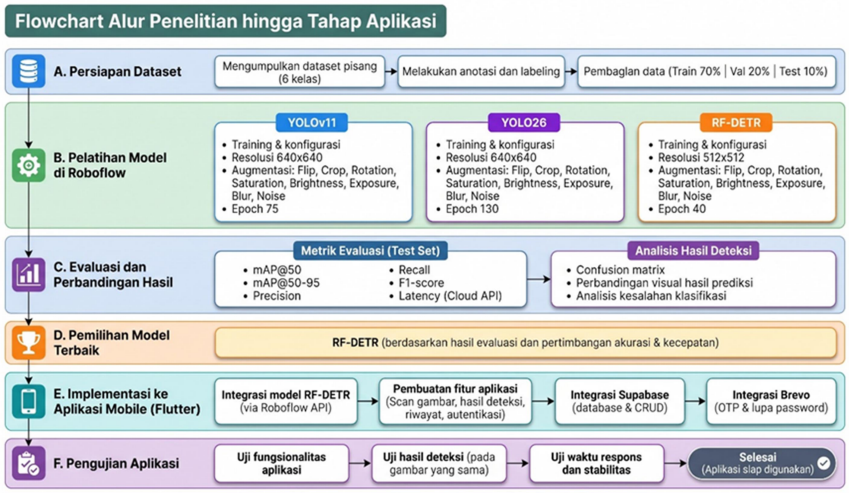
Berdasarkan uraian tersebut, penelitian ini bertujuan membandingkan kinerja YOLO11 Small, YOLO26 Small, dan RF-DETR Small dalam mendeteksi tingkat kematangan pisang, menentukan model terbaik berdasarkan hasil evaluasi, serta mengimplementasikannya pada aplikasi Banana Ripeness Vision. Kontribusi penelitian ini terletak pada evaluasi komparatif ketiga model menggunakan dataset yang sama dengan mempertimbangkan konfigurasi eksperimen masing-masing, serta penerapan model terpilih ke dalam aplikasi mobile. Dengan demikian, penelitian ini menghubungkan evaluasi kinerja model deteksi objek dengan implementasinya dalam aplikasi yang dapat digunakan oleh pengguna.

METODE

Penelitian ini menggunakan pendekatan eksperimen kuantitatif dengan rancangan komparatif untuk membandingkan kinerja tiga model deteksi objek, yaitu YOLO11 Small, YOLO26 Small, dan RF-DETR Small, dalam mendeteksi tingkat kematangan pisang. Pendekatan kuantitatif digunakan karena evaluasi dilakukan berdasarkan nilai numerik dari metrik kinerja model, sedangkan rancangan komparatif digunakan untuk menganalisis perbedaan hasil yang diperoleh dari ketiga model. (Tampubolon, 2023), menjelaskan bahwa penelitian komparatif bertujuan membandingkan dua kelompok atau lebih berdasarkan variabel tertentu, sementara pendekatan kuantitatif menggunakan data berupa angka untuk memperoleh informasi dan menarik kesimpulan. Tahapan penelitian meliputi persiapan dataset, prapemrosesan dan augmentasi citra, pelatihan model, evaluasi kinerja, pemilihan model terbaik, serta implementasi model terpilih pada aplikasi mobile Banana Ripeness Vision. Alur keseluruhan penelitian ditunjukkan pada Gambar 1.

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Gambar 1. Flowchart Alur Penelitian



Gambar 1 memperlihatkan urutan pelaksanaan penelitian, mulai dari persiapan dataset, penerapan preprocessing dan augmentasi, pelatihan ketiga model, evaluasi hasil, hingga pemilihan model untuk implementasi aplikasi. Penyajian tahapan penelitian dalam bentuk diagram alir juga digunakan oleh (Hastungkoro et al., 2024) dalam penelitian klasifikasi kualitas dan kematangan pisang Cavendish menggunakan Convolutional Neural Network (CNN). Alur penelitian ini disesuaikan dengan tujuan penelitian, yaitu membandingkan YOLO11, YOLO26, dan RF-DETR, sehingga setiap tahap dilaksanakan secara terstruktur dan hasil evaluasi menjadi dasar pemilihan model untuk implementasi pada aplikasi mobile.

Data penelitian berupa dataset citra pisang yang dikelola melalui platform Roboflow. Dataset terdiri atas 7.546 citra yang terbagi menjadi 5.264 citra pelatihan, 1.525 citra validasi, dan 757 citra pengujian. Dataset tersebut memiliki enam kelas, yaitu FreshRipe, FreshUnripe, Overripe, Ripe, Rotten, dan Unripe. Data pelatihan digunakan untuk melatih model, data validasi digunakan untuk memantau kinerja selama pelatihan, sedangkan data pengujian digunakan untuk mengevaluasi kemampuan model pada data yang tidak digunakan dalam pelatihan.

Tabel 1. Pembagian Dataset

Jenis Data	Jumlah Citra	Persentase
Training	5.264	69,76%
Validation	1.525	20,21%
Test	757	10,03%
Total	**7.546**	**100,00%**

Sebelum pelatihan, citra diproses menggunakan pengaturan preprocessing dan augmentasi yang tersedia pada Roboflow. Preprocessing dilakukan untuk menyesuaikan citra dengan kebutuhan masukan model, sedangkan augmentasi digunakan untuk memperkaya variasi citra selama pelatihan. (Saragih et al., 2024) menerapkan preprocessing dan augmentasi citra dalam penelitian deteksi kematangan pisang dan mangga menggunakan YOLOv8. Sejalan dengan penelitian tersebut, penelitian ini menerapkan preprocessing dan augmentasi pada dataset citra pisang, dengan pengaturan yang disesuaikan berdasarkan kebutuhan masing-masing model. Pengaturan yang diterapkan meliputi penyesuaian orientasi dan ukuran citra serta transformasi citra sesuai konfigurasi masing-masing model.

Tabel 2. Konfigurasi preprocessing & augmentasi ketiga model

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Konfigurasi	YOLO11	YOLO26	RF-DETR
Resolusi	640 × 640	640 × 640	512 × 512
Resize	Fit Within	Fit Within	Stretch
Horizontal flip	Aktif	Aktif	Aktif
Crop maksimum	15%	15%	15%
Rotasi	±15°	±15°	±15°
Saturasi	±15%	±15%	±15%
Brightness	±15%	±15%	±15%
Exposure	±10%	±10%	±10%
Blur maksimum	2,5 px	2,5 px	3 px
Noise maksimum	0,1%	0,1%	1%

Tabel 2 menunjukkan bahwa ketiga model menggunakan dataset yang sama, tetapi beberapa pengaturan preprocessing dan augmentasi disesuaikan dengan konfigurasi masing-masing model. YOLO11 Small dan YOLO26 Small menggunakan resolusi 640 × 640 dengan metode Fit Within, sedangkan RF-DETR Small menggunakan resolusi 512 × 512 dengan metode Stretch. Pengaturan blur maksimum dan noise maksimum juga berbeda. Perbedaan tersebut dicatat agar proses eksperimen dapat dijelaskan secara transparan dan menjadi pertimbangan dalam interpretasi hasil perbandingan. Oleh karena itu, hasil penelitian menggambarkan kinerja model berdasarkan konfigurasi eksperimen yang digunakan, bukan semata-mata pengaruh arsitektur secara terpisah.

Pengembangan aplikasi Banana Ripeness Vision dilakukan menggunakan Flutter dengan bahasa pemrograman Dart untuk membangun antarmuka dan mengelola interaksi pengguna. (Laudri, 2025), menerapkan Flutter dalam pengembangan aplikasi Android untuk klasifikasi kematangan pisang menggunakan model Convolutional Neural Network (CNN). Berbeda dengan penelitian tersebut, penelitian ini menggunakan Roboflow Hosted API untuk menjalankan inferensi model RF-DETR Small. Supabase digunakan untuk mendukung layanan backend, autentikasi, dan pengelolaan data aplikasi, sedangkan Supabase Auth yang terintegrasi dengan SMTP Brevo digunakan untuk pengiriman kode verifikasi melalui email. Aplikasi disiapkan agar dapat diakses melalui Progressive Web App (PWA) dan perangkat Android dalam bentuk Android Package Kit (APK). Rincian komponen teknologi dan fungsinya disajikan pada Tabel 3.

Tabel 3. Teknologi dan Komponen Pengembangan Aplikasi Banana Ripeness Vision

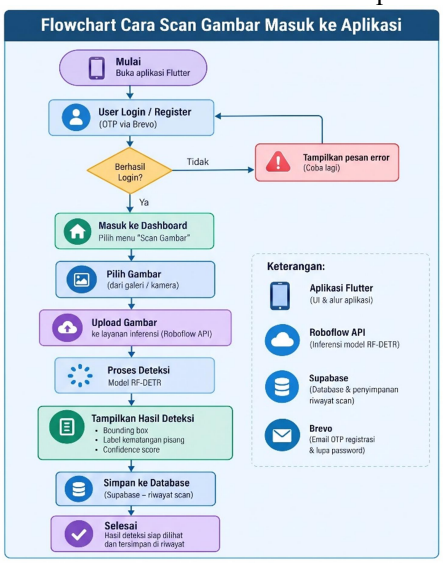
Komponen	Teknologi	Fungsi
Frontend	Flutter dan Dart	Membangun antarmuka aplikasi dan mengatur interaksi pengguna
Platform aplikasi	Progressive Web App (PWA) dan Android APK	Menyediakan akses melalui browser dan perangkat Android
Backend dan layanan aplikasi	Supabase	Mendukung autentikasi dan pengelolaan data aplikasi
Basis data	PostgreSQL melalui Supabase	Menyimpan data aplikasi, termasuk riwayat pemindaian
Autentikasi	Supabase Auth	Mengelola proses registrasi dan autentikasi pengguna

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Pengiriman email OTP	SMTP Brevo	Mengirim kode verifikasi melalui email
Model deteksi objek	RF-DETR Small	Mendeteksi objek dan memprediksi kelas kematangan pisang
Layanan inferensi AI	Roboflow Hosted API	Menerima gambar dan menyediakan hasil inferensi model
Fungsi backend khusus	Supabase Edge Function berbasis TypeScript/Deno	Menjalankan logika sisi server yang diterapkan pada fungsi pemindaian
Build aplikasi Android	Flutter build APK	Menghasilkan berkas aplikasi Android

Proses pemindaian pada aplikasi Banana Ripeness Vision dimulai ketika pengguna masuk ke aplikasi dan memilih menu pemindaian gambar. Pengguna kemudian memilih gambar pisang dari galeri atau kamera untuk diproses oleh model deteksi. Hasil pemrosesan ditampilkan dalam bentuk label kelas kematangan, bounding box, dan confidence score. Hasil pemindaian selanjutnya disimpan ke dalam basis data agar dapat ditampilkan kembali melalui riwayat pemindaian. Alur proses pemindaian gambar pada aplikasi ditunjukkan pada Gambar 2.

Gambar 2. Flowchart Scan Pada Aplikasi



Gambar 2 menunjukkan alur pemindaian gambar pada Banana Ripeness Vision, dimulai dari autentikasi pengguna, pemilihan gambar, pengiriman permintaan deteksi, hingga penampilan hasil dan penyimpanan riwayat pemindaian. Pada tahap inferensi, aplikasi menggunakan model RF-DETR melalui Roboflow Hosted API. Supabase mendukung autentikasi dan pengelolaan data sesuai fungsi yang diterapkan pada aplikasi.

HASIL DAN PEMBAHASAN

Penelitian ini mengevaluasi kinerja YOLO11 Small, YOLO26 Small, dan RF-DETR Small dalam mendeteksi tingkat kematangan pisang. Ketiga model menggunakan dataset yang sama, yaitu 7.546 citra dengan enam kelas: FreshRipe, FreshUnripe, Overripe, Ripe, Rotten, dan Unripe. Evaluasi mencakup precision, recall, F1-score, mAP@50, mAP@50:95, serta waktu respons API. Hasil perbandingan metrik ketiga model disajikan pada Tabel 4.

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Tabel 4. Perbandingan Metrik Evaluasi Ketiga Model

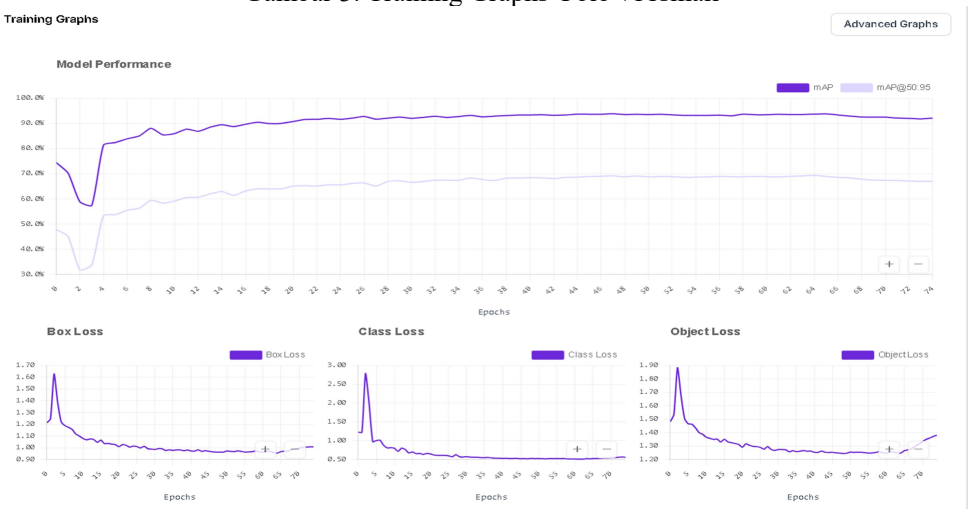
Metrik	YOLO11	YOLO26	RF-DETR
Precision	89,6%	87,3%	88,6%
Recall	87,6%	88,7%	90,0%
F1-score	88,6%	87,9%	89,3%
mAP@50	88,7%	90,3%	94,9%
mAP@50:95	66,6%	65,8%	71,6%
Latency API	4,9 ms	13,3 ms	7,1 ms

Berdasarkan Tabel 4, hasil pengujian menunjukkan bahwa RF-DETR memperoleh nilai mAP@50 sebesar 94,9%, lebih tinggi dibandingkan YOLO11 sebesar 88,7% dan YOLO26 sebesar 90,3%. Hasil ini dapat dikaitkan dengan penelitian (Fatahna et al., 2025) yang menggunakan YOLOv8n untuk mendeteksi kualitas pisang susu dan memperoleh nilai mAP50 sebesar 92%. Kedua penelitian sama-sama membahas deteksi kualitas atau kematangan pisang menggunakan pendekatan object detection, meskipun menggunakan model dan konfigurasi eksperimen yang berbeda. Hasil tersebut menunjukkan bahwa pemilihan arsitektur model dapat memengaruhi performa deteksi pada citra pisang.

Perbandingan waktu respons API menunjukkan bahwa YOLO11 Small memiliki nilai terendah sebesar 4,9 ms, diikuti RF-DETR Small sebesar 7,1 ms dan YOLO26 Small sebesar 13,3 ms. Dengan demikian, RF-DETR Small bukan model dengan waktu respons API tercepat. Pemilihan RF-DETR Small untuk implementasi aplikasi didasarkan pada hasil evaluasi deteksi secara keseluruhan, khususnya nilai mAP@50, mAP@50:95, recall, dan F1-score. Perlu diperhatikan bahwa waktu respons API tersebut tidak menggambarkan keseluruhan waktu pemrosesan pada aplikasi, karena proses end-to-end juga dapat mencakup pengiriman gambar, penerimaan respons, dan penampilan hasil pada antarmuka.

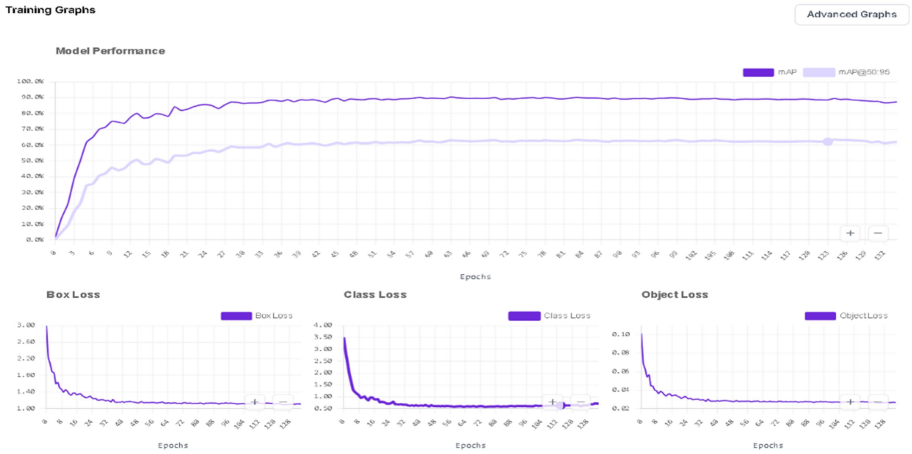
Selain metrik evaluasi akhir, proses pelatihan ketiga model dianalisis melalui grafik training untuk melihat perkembangan kinerja selama pelatihan. Grafik YOLO11 Small, YOLO26 Small, dan RF-DETR Small disajikan pada Gambar 3 hingga Gambar 5. Penyajian ketiga grafik diperlukan untuk memperlihatkan perkembangan masing-masing model berdasarkan hasil pelatihan yang tercatat.

Gambar 3. Training Graphs Yolo v11small

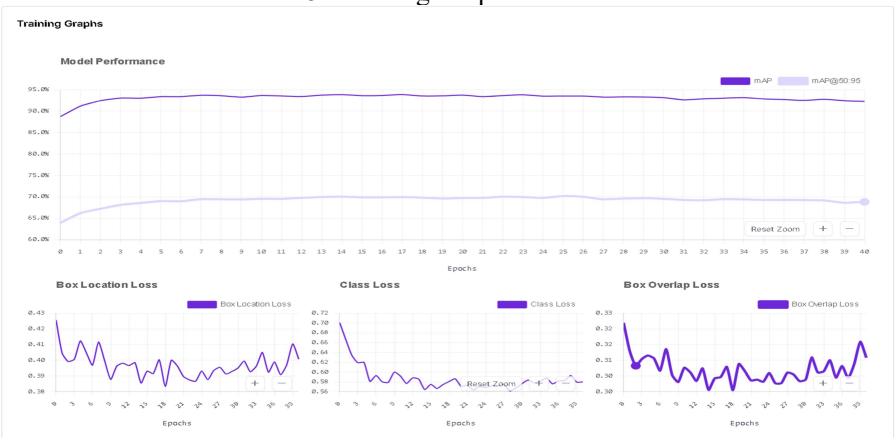


E-ISSN : 2962-9713
P-ISSN : 2963-928X

Gambar 4. Training Graphs Yolo 26small



Gambar 5. Training Graphs RF DETRsmall



Grafik pelatihan YOLO11 Small, YOLO26 Small, dan RF-DETR Small disajikan pada Gambar 3, Gambar 4, dan Gambar 5. Ketiga grafik menunjukkan perubahan metrik performa dan nilai loss selama pelatihan. YOLO11 dan YOLO26 memperlihatkan peningkatan mAP yang cenderung stabil, sedangkan RF-DETR menunjukkan metrik yang relatif stabil dengan beberapa fluktuasi loss. Pola penurunan loss dan kestabilan metrik ini sejalan dengan penelitian (R. Dwi Ananda, 2025) pada deteksi kematangan pisang menggunakan YOLOv11. Namun, pemilihan model terbaik tetap didasarkan pada hasil evaluasi akhir yang disajikan pada Tabel 4.

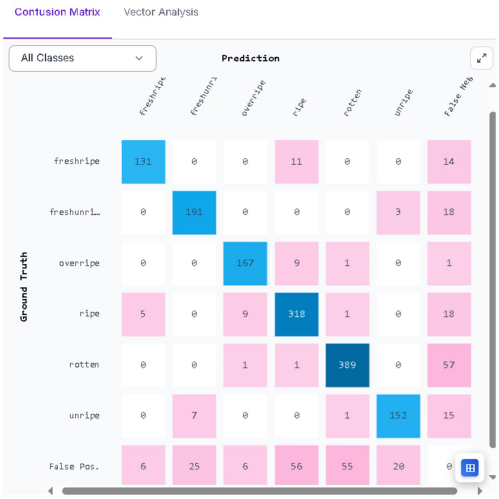
Untuk meninjau pola prediksi pada masing-masing kelas, Gambar 6, Gambar 7, & Gambar 8 menyajikan confusion matrix YOLO11 Small, YOLO26 Small, dan RF-DETR Small. Matriks tersebut memperlihatkan jumlah prediksi pada setiap kelas aktual dan kelas hasil prediksi, sehingga kesalahan antarkelas dapat diamati lebih terperinci daripada melalui satu nilai mAP keseluruhan. Evaluasi menggunakan confusion matrix juga diterapkan oleh (Prasetyo et al., 2026) dalam penelitian klasifikasi kematangan pisang menggunakan YOLOv12. Penggunaan evaluasi ini membantu mengidentifikasi pola kesalahan klasifikasi pada setiap kelas, sehingga hasil prediksi ketiga model dalam penelitian ini dapat dianalisis secara lebih terperinci.

E-ISSN : 2962-9713
P-ISSN : 2963-928X

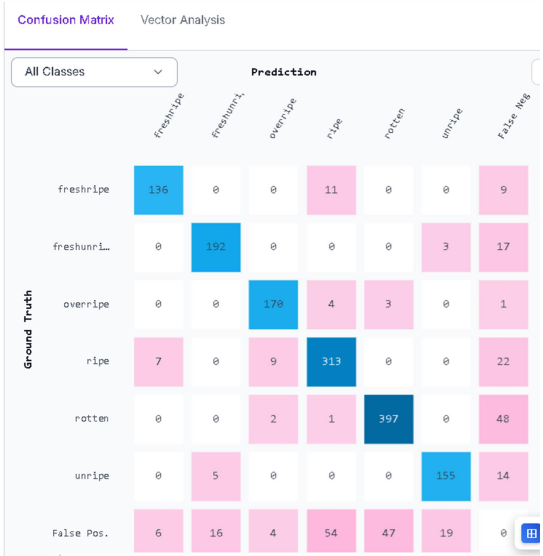
Gambar 6. Confusion Matrix Yolo v11



Gambar 7. Confusion Matrix Yolo 26



Gambar 8. Confusion Matrix RF DETR



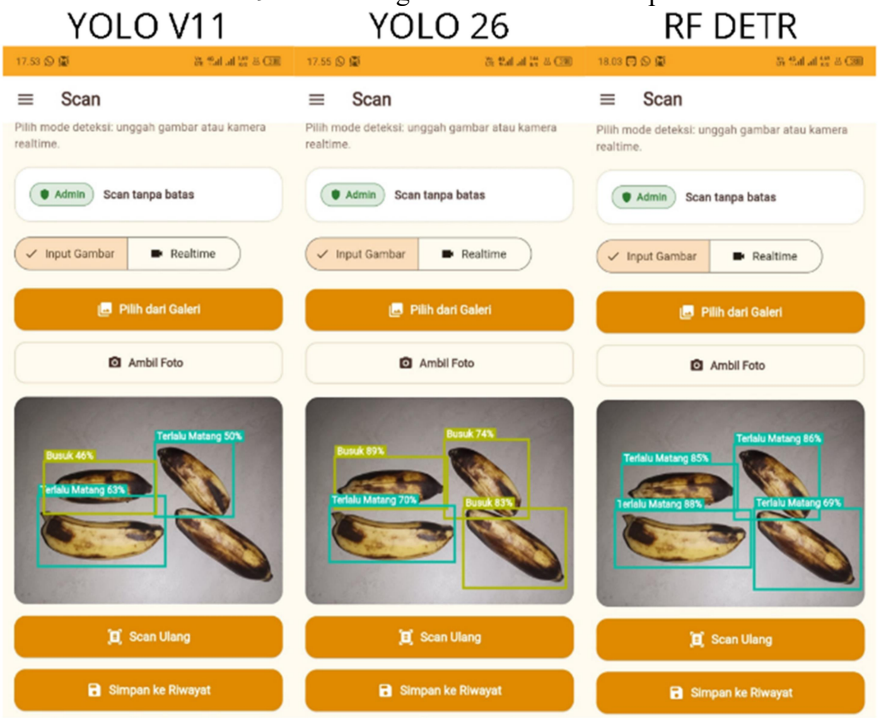
Berdasarkan confusion matrix, ketiga model menunjukkan prediksi benar pada diagonal matriks, tetapi masih terdapat kesalahan ketika objek diprediksi sebagai kelas lain. Salah satu pola yang terlihat adalah sebagian objek kelas FreshRipe diprediksi

E-ISSN : 2962-9713
P-ISSN : 2963-928X

sebagai Ripe, masing-masing sebanyak 8 pada YOLO11 Small, 11 pada YOLO26 Small, dan 11 pada RF-DETR Small. Kesalahan lain terlihat pada kelas FreshUnripe yang diprediksi sebagai Unripe, masing-masing sebanyak 4, 3, dan 3 pada ketiga model. Pada kelas Overripe, prediksi sebagai Ripe tercatat sebanyak 3 pada YOLO11 Small, 9 pada YOLO26 Small, dan 4 pada RF-DETR Small. Temuan ini memperlihatkan bahwa sebagian kesalahan terjadi pada kelas dengan karakteristik kematangan yang berdekatan. Meskipun demikian, pola kesalahan tersebut tidak dapat digunakan sendirian untuk menentukan model terbaik; hasilnya perlu dibaca bersama metrik evaluasi keseluruhan pada Tabel 4.

Selain evaluasi kuantitatif, pengamatan kualitatif dilakukan dengan membandingkan hasil pemindaian pada citra pisang yang sama melalui aplikasi Banana Ripeness Vision. Ketiga model diuji dengan confidence threshold aplikasi sebesar 40%. Perbandingan hasil deteksi, termasuk jumlah bounding box, label kelas, dan nilai confidence, ditampilkan pada Gambar 9.

Gambar 9. Perbandingan Hasil Scan Pada Aplikasi



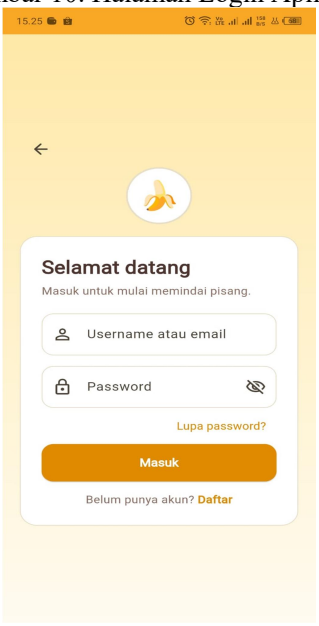
Berdasarkan Gambar 9, YOLO11 Small menghasilkan tiga bounding box dengan label Busuk dan Terlalu Matang, sedangkan YOLO26 Small dan RF-DETR Small masing-masing menghasilkan empat bounding box. YOLO26 Small menampilkan kombinasi label Busuk dan Terlalu Matang, sementara RF-DETR Small mengklasifikasikan seluruh objek yang terdeteksi sebagai Terlalu Matang. Pengujian dilakukan menggunakan citra pisang yang sama dengan posisi objek, pencahayaan, dan kondisi pengambilan gambar yang identik. Berdasarkan label acuan pada dataset, pisang tersebut termasuk kelas Terlalu Matang, sehingga hasil RF-DETR Small lebih sesuai dengan label acuan dibandingkan keluaran kedua model lainnya pada pengujian ini. Hasil ini memperlihatkan bahwa RF-DETR Small mampu memberikan prediksi yang lebih sesuai pada contoh citra yang diuji, sekaligus melengkapi hasil evaluasi kuantitatif pada Tabel 4 yang menjadi dasar pemilihan model untuk diimplementasikan pada aplikasi Banana Ripeness Vision.

Penerapan model deteksi objek dalam aplikasi menjadi salah satu bentuk pemanfaatan computer vision untuk mendukung kebutuhan praktis, sebagaimana

E-ISSN : 2962-9713
P-ISSN : 2963-928X

ditunjukkan oleh (Ramadhani & Widyaningrum, 2025) melalui implementasi YOLOv11 untuk deteksi dan klasifikasi sampah berbasis citra. Berdasarkan hasil evaluasi kuantitatif dan pengujian pada Gambar 9, RF-DETR Small dipilih untuk diimplementasikan pada aplikasi Banana Ripeness Vision. Aplikasi ini dikembangkan menggunakan Flutter serta dilengkapi dengan fitur autentikasi pengguna dan dashboard yang menampilkan informasi aplikasi. Tampilan halaman login disajikan pada Gambar 10, sedangkan dashboard yang diakses melalui Progressive Web App (PWA), termasuk navigasi sidebar, ditunjukkan pada Gambar 11.

Gambar 10. Halaman Login Aplikasi



Gambar 11. Menu Dashboard & Sidebar Aplikasi



Gambar 10 memperlihatkan halaman login yang digunakan pengguna untuk mengakses aplikasi. Sementara itu, Gambar 11 menunjukkan dashboard sebagai halaman utama setelah pengguna masuk, beserta navigasi menuju fitur-fitur yang tersedia sesuai hak aksesnya. Kedua tampilan tersebut melengkapi hasil perbandingan deteksi pada Gambar 9 dengan memperlihatkan antarmuka aplikasi tempat model terpilih diterapkan. Dengan demikian, penelitian ini mencakup evaluasi komparatif tiga

E-ISSN : 2962-9713
P-ISSN : 2963-928X

model dan implementasi model terpilih dalam aplikasi, sedangkan hasil perbandingan kuantitatif tetap menjadi dasar utama pemilihan model.

SIMPULAN

Penelitian ini membandingkan kinerja YOLO11 Small, YOLO26 Small, dan RF-DETR Small dalam mendeteksi tingkat kematangan pisang serta mengimplementasikan model terpilih pada aplikasi Banana Ripeness Vision. Berdasarkan hasil evaluasi, RF-DETR Small memperoleh nilai mAP@50 sebesar 94,9%, mAP@50:95 sebesar 71,6%, recall sebesar 90,0%, dan F1-score sebesar 89,3%. Hasil tersebut menjadikan RF-DETR Small sebagai model terpilih berdasarkan keunggulan pada sebagian besar metrik evaluasi yang digunakan. Meskipun demikian, YOLO11 Small memperoleh precision tertinggi sebesar 89,6% dan waktu respons API tercepat sebesar 4,9 ms. Temuan ini menunjukkan bahwa pemilihan model perlu mempertimbangkan beberapa metrik, bukan hanya satu indikator kinerja. RF-DETR Small selanjutnya diintegrasikan ke dalam aplikasi Banana Ripeness Vision berbasis Flutter dengan memanfaatkan Roboflow Hosted API untuk deteksi objek dan Supabase untuk mendukung autentikasi serta pengelolaan data aplikasi. Implementasi ini menunjukkan penerapan hasil perbandingan model ke dalam aplikasi yang dapat digunakan untuk memproses gambar pisang dan menampilkan hasil deteksi. Penelitian selanjutnya disarankan menguji model menggunakan variasi kondisi pencahayaan, latar belakang, dan kualitas gambar yang lebih luas, serta mengukur waktu pemrosesan secara menyeluruh pada aplikasi untuk memperoleh gambaran yang lebih lengkap mengenai kinerja sistem dalam penggunaan nyata.

DAFTAR PUSTAKA

Fatahna, I., Sari, P. D. K., Wulanningrum, R., & Utomo, W. C. (2025). Implementasi Computer Vision Terhadap Jenis Kualitas Pisang Susu Menggunakan Metode YOLOv8n Berbasis WebApps. *Seminar Nasional Teknologi & Sains*, *4*(1), 1–10.

Futri, D. A., Kharisma, I. L., & Somantri, S. (2025). The Implementasi Model Vision Transfomers Pada Klasifikasi Jenis Kulit Wajah Berbasis Website. *Jurnal CoSciTech (Computer Science and Information Technology)*, *6*(2), 214–229.

Hastungkoro, A. W., Dwi, A., Wicaksono, P., Rosita, Y. D., Informatika, T., & Informatika, F. (2024). Klasifikasi Kualitas dan Kematangan Pisang Cavendish Menggunakan Convolutional Neural Network Pisang merupakan Faktor-faktor perorangan. *Jurnal Saintekom: Sains, Teknologi, Komputer Dan Manajemen*, *14*(2), 185–194.

Hidayatullah, P., Tubagus, R., & Bandung, P. N. (2026). YOLO26 : A Comprehensive Architecture Overview and Key Improvements. *ArXiv Preprint ArXiv:2602.14582*.

Laudri, S. P. (2025). IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK DALAM APLIKASI ANDROID UNTUK KLASIFIKASI KEMATANGAN BUAH PISANG: IMPLEMENTATION OF CONVOLUTIONAL NEURAL NETWORK IN AN ANDROID APPLICATION FOR CLASSIFYING BANANA RIPENESS. *HOAQ (High Education of Organization Archive Quality): Jurnal Teknologi Informasi*, *16*(2), 225–232.

Nopiandi, A., Yasin, F. R., Prayoga, R. H., & Kharisma, I. L. (2025). The IMPLEMENTASI YOLOV8 NANO PADA SISTEM MONITORING BUDIDAYA JAMUR TIRAM BERBASIS IOT. *Jurnal CoSciTech (Computer Science and Information Technology)*, *6*(3), 491–508.

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Prasetyo, S. E., Wijaya, G., & Kwan, A. (2026). Klasifikasi Kematangan Buah Pisang Menggunakan YOLOv12 Berbasis Deep Learning. *STORAGE: Jurnal Ilmiah Teknik Dan Ilmu Komputer*, *5*(1), 30–39.

R. Dwi Ananda, A. D. K. (2025). Klasifikasi Tingkat Kematangan Pisang dengan YOLOv11 untuk Pengurangan Food Loss and Waste. *Jurnal Manajemen Sistem Informasi Dan Teknologi*, *15*(2).

Ramadhan, M. R. Z., & Pramana, A. L. (2026). Pengenalan tingkat kematangan buah pisang berbasis citra dengan metode convolutional neural network. *JATI (Jurnal Mahasiswa Teknik Informatika)*, *10*(3), 4191–4199.

Ramadhani, L. K., & Widyaningrum, B. N. (2025). Implementation of YOLO v11 for image-based litter detection and classification in environmental management efforts. *Journal of Applied Informatics and Computing*, *9*(3), 617–624.

Sapkota, R., Cheppally, R. H., Sharda, A., & Karkee, M. (2025). Rf-detr object detection vs yolov12: A study of transformer-based and cnn-based architectures for single-class and multi-class greenfruit detection in complex orchard environments under label ambiguity. *ArXiv Preprint ArXiv:2504.13099*.

Saputra, G. E., & Yanni, R. R. P. (2025). Evaluation of Deep Learning Model for Detection of Banana Consumption Feasibility Using Yolov8 Method. *ILKOM Jurnal Ilmiah*, *17*(3), 213–226.

Saragih, R. E., Purnajaya, A. R., Syafrinal, I., & Pernando, Y. (2024). Mango and Banana Ripeness Detection based on Lightweight YOLOv8. *Jurnal Buana Informatika*, *15*(2), 79–88.

Tampubolon, M. (2023). *Metode Penelitian*. www.globaleksekutifteknologi.co.id

Wisnawa, I. P. O., Prihatini, P. M., Dewi, N. L. P. L., Damayanti, N. W. W., Sulastra, I. M. D. J., & Gunawan, I. M. A. O. (2026). On-Device Deployment of Optuna-Optimized YOLOv8n via Flutter for Real-Time and Explainable Cocoa Pod Disease Detection. *International Conference on Sustainable Green Tourism Applied Science-Engineering Applied Science 2026 (ICOSTAS-EAS 2026)*, 334–346.