

Klasifikasi Tingkat Kematangan Pisang dengan YOLOv11 untuk Pengurangan *Food Loss and Waste*

Rezky Dwi Ananda¹, Anna Dina Kalifia²

^{1,2}Informatika, Fakultas Sains & Teknologi, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia

^{1*}rezkydwia13@gmail.com, ²ad.kalifia@uty.ac.id

ABSTRACT – Food loss and waste (FLW) is a serious issue in the global food system, including in the banana commodity sector. One of the main challenges lies in the manual fruit sorting process, which is prone to errors and inconsistencies due to human subjectivity. Although various deep learning approaches have been applied to fruit ripeness classification, most previous studies still rely on earlier versions of the YOLO model or conventional CNNs, which are limited in handling visual variations and detecting small objects in real-time. This study proposes the application of the YOLOv11 algorithm, a state-of-the-art deep learning model in computer vision, to automate the visual classification of banana ripeness levels. Leveraging YOLOv11's strengths in real-time object detection, the system is designed to categorize bananas into four ripeness classes. Experimental results show that the model achieved an mAP@0.5 of 0.835, with the highest precision of 0.934 and an average inference time of 63.8 milliseconds per image. Extreme classes such as unripe and overripe yielded high accuracy, while transitional classes experienced performance drops due to visual similarity. This approach is expected to support food loss reduction, improve sorting efficiency, and enhance the competitiveness of horticultural products in both domestic and export markets.

Keywords: banana ripeness classification; deep learning; food loss and waste; YOLOv11 computer vision.

ABSTRAK – Food loss and waste (FLW) merupakan permasalahan serius dalam sistem pangan global, termasuk pada komoditas pisang. Salah satu tantangan utama terletak pada proses pemilahan buah secara manual yang rentan terhadap kesalahan dan inkonsistensi dikarenakan subjektivitas mata manusia. Meskipun berbagai pendekatan deep learning telah digunakan untuk klasifikasi kematangan buah, sebagian besar penelitian sebelumnya masih mengandalkan model YOLO versi terdahulu atau CNN konvensional, yang memiliki keterbatasan dalam menangani variasi visual dan objek berukuran kecil secara real-time. Penelitian ini mengusulkan penerapan algoritma YOLOv11, sebuah model deep learning terkini dalam bidang computer vision, untuk mengotomatisasi klasifikasi tingkat kematangan buah pisang secara visual. Dengan memanfaatkan keunggulan YOLOv11 dalam deteksi objek real-time, sistem ini dirancang untuk membedakan buah pisang ke dalam empat kelas tingkat terlalu matang. Hasil pengujian menunjukkan bahwa model mencapai mAP@0.5 sebesar 0,835, dengan precision tertinggi 0,934 dan waktu inferensi rata-rata 63,8 milidetik per citra. Kelas ekstrem seperti belum matang dan kematangan menunjukkan akurasi tinggi, sedangkan kelas transisi mengalami penurunan performa akibat kemiripan visual.

Kata Kunci: klasifikasi kematangan pisang; food loss and waste; YOLOv11; computer vision; deep learning.

1. PENDAHULUAN

Food loss and waste (FLW) merupakan permasalahan serius dalam sistem pangan global yang berdampak pada aspek ekonomi, sosial, dan lingkungan. Di Indonesia, FLW telah mencapai tingkat yang mengkhawatirkan. Studi oleh Bappenas pada 2021 menemukan bahwa Indonesia menghasilkan antara 23 hingga 48 juta ton FLW per tahun, atau setara dengan 115 hingga 184 kilogram per kapita per tahun. Kerugian ekonomi yang disebabkan oleh FLW diperkirakan mencapai Rp551 triliun per tahun, atau sekitar 4 hingga 5 persen dari Produk Domestik Bruto (PDB).

Pisang merupakan komoditas hortikultura tropis dengan nilai ekonomi tinggi dan kandungan nutrisi yang kaya. Indonesia termasuk salah satu negara penghasil pisang terbesar di dunia. Data Badan Pusat Statistik (BPS)

pada 2024 memperkirakan produksi pisang nasional adalah sekitar 96.87 juta kuintal pada 2025 atau setara dengan $\pm 32\%$ dari total produksi buah nasional. Namun, potensi ekonomi pisang belum dioptimalkan secara maksimal, terutama dalam proses pascapanen dan distribusi. Secara umum, kerusakan pascapanen komoditas hortikultura di Indonesia dilaporkan mencapai sekitar 23-40% dari produksi. Angka tersebut mencerminkan masih lemahnya sistem penanganan pascapanen dan klasifikasi buah di tingkat produsen. Kualitas buah yang tidak memenuhi standar pasar ekspor, baik dari segi kematangan maupun tampilan fisik, menyebabkan banyaknya buah yang terbuang atau dialihkan ke pemrosesan non-premium. Padahal, pasar ekspor memiliki permintaan tinggi terhadap buah berkualitas tinggi dengan standar kematangan yang presisi. Oleh karena itu, pengelolaan kematangan pisang secara akurat menjadi aspek krusial untuk memperpanjang umur simpan, meningkatkan nilai jual, dan menurunkan angka food loss secara signifikan.



Klasifikasi tingkat kematangan pisang secara akurat sangat penting untuk menentukan waktu panen optimal guna meningkatkan kualitas dan efisiensi hasil panen. Tingkat kematangan saat panen mempengaruhi umur simpan, rasa, aroma, dan kualitas buah. Pisang yang dipetik terlalu muda cenderung kurang optimal dalam rasa dan aroma, sedangkan pisang yang terlalu matang memiliki umur simpan lebih pendek. Kematangan buah juga mempengaruhi grading untuk keperluan pemasaran di pasar ritel modern.

Berbagai studi telah menggunakan algoritma You Only Look Once (YOLO) yang merupakan ____ untuk klasifikasi dan deteksi kematangan buah dikarenakan akurasi dan kecepatannya. Ramadhan (2025) menggunakan YOLOv5 untuk sistem pendeteksi kematangan pisang antara 5 pisang segar dan 5 pisang busuk dengan akurasi 100%. [1] Sementara Majdudin (2025) menggunakan YOLOv8 untuk mendeteksi kematangan nanas menjadi tiga kelas kematangan. [2] Pendekatan pada penelitian sebelumnya masih terlalu luas dan belum dapat menangkap variasi visual pada buah dengan karakteristik warna dan tekstur yang berubah bertahap seperti pisang. Pengaruh pencahayaan dalam klasifikasi gambar juga dapat mempengaruhi hasil dalam membedakan kelas yang memiliki kemiripan tinggi, seperti antara pisang setengah matang dan matang. Hal ini krusial untuk menentukan periode waktu yang tepat untuk proses transportasi dan konsumsi pisang. Oleh karena itu, dibutuhkan pendekatan yang mampu meningkatkan sensitivitas model terhadap perbedaan visual yang tipis serta memiliki arsitektur yang lebih adaptif terhadap kondisi pencitraan yang kompleks.

YOLOv11 merupakan pengembangan terbaru dari algoritma YOLO yang dirilis oleh Ultralytics pada tahun 2024. YOLOv11 menggunakan blok C3k2 dan modul C2PSA (Convolutional block with Parallel Spatial Attention) yang dirancang untuk meningkatkan kemampuan dalam mendeteksi objek berukuran kecil atau yang sebagian tertutup. Selain itu, mekanisme perhatian multi-skala yang diadopsi pada model ini memungkinkan deteksi yang lebih akurat pada variasi visual yang hasil, seperti perbedaan warna dan tekstur kulit pisang antar tingkat kematangan. Sehingga, YOLOv11 dinilai memiliki potensi yang lebih tinggi untuk diterapkan pada sistem klasifikasi kematangan buah secara otomatis.

2. DASAR TEORI

Computer Vision atau visi komputer adalah sebuah bidang dalam kecerdasan buatan yang berfokus pada bagaimana komputer dapat memahami dan menafsirkan informasi visual dari gambar atau video. [3] Teknologi ini memungkinkan mesin untuk meniru dan bahkan melampaui kemampuan sistem visual manusia dalam melakukan tugas analisis secara lebih cepat dan akurat, seperti mengenali karakteristik visual pada suatu objek [4]. *Computer Vision* merupakan terobosan pesat di bidang informatika dan memberikan kontribusi penting dalam

berbagai aspek kehidupan, termasuk teknologi, bisnis, pendidikan, dan secara signifikan di sektor pertanian, di mana teknologi ini menjadi pendorong revolusi pertanian menuju digitalisasi dan otomatisasi [5],[6].

Dalam konteks pertanian, *Computer Vision* memungkinkan sistem untuk memproses data citra yang diperoleh untuk berbagai aplikasi kunci seperti pemantauan, deteksi stres pada tanaman, manajemen gulma dan penyemprotan bertarget, estimasi hasil panen, dan kontrol kualitas produk pasca panen. Implementasi tersebut mencakup deteksi cacat pada bahan atau produk [7]. Hal ini termasuk deteksi cacat pada buah, klasifikasi tingkat kematangan [8], dan deteksi objek seperti buah itu sendiri atau musang pandan untuk pemantauan aktivitas [9]. Teknologi ini sangat berguna dalam mengatasi keterbatasan pengamatan manual yang memakan waktu, tenaga, dan rentan terhadap kesalahan atau inkonsistensi penilaian individu.

Berbagai metode *deep learning*, terutama *Convolutional Neural Network (CNN)* dan algoritma deteksi objek real-time seperti keluarga YOLO (*You Only Look Once*), menjadi dasar penting dalam pengembangan sistem *Computer Vision*, yang memungkinkan ekstraksi fitur visual secara otomatis dari citra, sehingga menghasilkan performa tinggi pada tugas klasifikasi dan deteksi objek dalam berbagai domain, mulai dari deteksi kematangan buah dan penyakit tanaman hingga inspeksi cacat industri dan deteksi kendaraan [10], [11].

Penerapan *Computer Vision* dalam pertanian mendukung otomatisasi proses, meningkatkan efisiensi operasional, dan memberikan solusi yang lebih objektif dibandingkan metode tradisional [12], [13]. Meskipun menawarkan potensi besar, implementasi sistem berbasis *Computer Vision* di lingkungan pertanian menghadapi beberapa tantangan, diantaranya adalah variasi kondisi lingkungan seperti pencahayaan dan cuaca yang dapat mempengaruhi performa, kebutuhan akan dataset pelatihan yang besar dan representatif, kesulitan dalam mendapatkan pelabelan data (*ground truth*) yang akurat dan konsisten, kurangnya kemampuan generalisasi model yang dilatih untuk satu jenis tanaman agar berfungsi baik pada jenis lain, serta kebutuhan akan sumber daya komputasi yang signifikan untuk pemrosesan real-time dalam skala besar [14]. Meski dengan tantangan ini, *Computer Vision* terus berkembang dan menjadi tren utama dalam mendorong otomatisasi dan inteligensi di sektor pertanian [15].

Convolutional Neural Network (CNN) merupakan tipe jaringan saraf tiruan yang tersusun dalam lapisan-lapisan hierarkis secara mendalam (*deep feed-forward multilayered*). Arsitektur ini terinspirasi dari cara kerja medan reseptif pada sistem biologis. Sebagai bagian dari pendekatan *deep learning*, CNN menjadi salah satu model yang paling umum diterapkan dalam algoritma pengolahan citra komputer [16].

YOLO (*You Only Look Once*) adalah sebuah algoritma atau metode deteksi objek yang sangat populer dalam bidang *Visi Komputer (Computer Vision)*. Konsep

utama YOLO adalah memproses seluruh citra dalam satu kali tahapan saja untuk mendeteksi objek. Cara kerjanya adalah dengan membagi gambar menjadi grid. Setiap sel di dalam grid tersebut bertanggung jawab untuk memprediksi kotak pembatas (bounding boxes) dan probabilitas kelas (class probabilities) objek yang mungkin ada di dalamnya, dilakukan secara simultan. Pendekatan ini membingkai tugas deteksi objek sebagai masalah regresi. YOLO umumnya dibangun CNN sebagai dasar arsitekturnya [17]. Keunggulan utama YOLO terletak pada kecepatan dan akurasi yang tinggi, terutama dalam skenario deteksi real-time. Hal ini menjadikannya solusi terobosan dibandingkan metode deteksi objek dua tahap yang lebih kompleks. Evaluation Metrics adalah ukuran kuantitatif yang digunakan untuk menilai kinerja dan efektivitas dari suatu model atau sistem, khususnya dalam bidang seperti Computer Vision dan Machine Learning. Metrik ini memungkinkan peneliti dan praktisi untuk secara objektif menilai seberapa baik model dapat menyelesaikan tugasnya, membandingkan performa antar model, dan mengidentifikasi kekuatan serta kelemahannya [18]. Banyak metrik evaluasi penting, terutama dalam tugas klasifikasi dan deteksi objek, dihitung berdasarkan Confusion Matrix.

Confusion matrix adalah tabel ringkasan yang menampilkan hasil prediksi model dibandingkan dengan kondisi sebenarnya (ground truth). Pada klasifikasi multi-kelas dengan K kelas, confusion matrix berbentuk matriks berukuran $K \times K$. Confusion matrix juga dapat disajikan dalam bentuk dinormalisasi, yaitu setiap baris dinyatakan sebagai proporsi/persentase. Representasi ini memudahkan analisis distribusi kesalahan, terutama untuk melihat kelas mana yang sering tertukar dan seberapa besar proporsi prediksi yang tepat pada setiap kelas.

Pada klasifikasi multi-kelas, terdapat komponen TP, FP, FN, dan TN dapat didefinisikan untuk setiap kelas dengan pendekatan *one-vs-rest*. Dengan contoh sebuah kelas c , TP_c adalah jumlah sampel kelas c yang diprediksi sebagai c ; FP_c adalah jumlah sampel dari kelas lain yang diprediksi sebagai c ; FN_c adalah jumlah sampel kelas c yang diprediksi sebagai kelas lain; TN_c adalah jumlah sampel bukan kelas c yang tidak diprediksi sebagai c .

Berdasarkan komponen di atas, metrik performa dapat dihitung sebagai berikut.

a. Precision

Precision digunakan untuk mengukur proporsi prediksi positif yang benar dari seluruh prediksi yang dinyatakan positif oleh model. Ini mencerminkan kemampuan model dalam menghindari false positive. Presisi tinggi menunjukkan sedikitnya prediksi positif yang salah.

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

b.

c. Recall

Recall digunakan untuk mengukur kemampuan model dalam mengidentifikasi seluruh sampel positif yang sebenarnya ada dalam dataset. Recall yang tinggi menunjukkan sedikitnya false negative (kasus positif yang terlewat).

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

d. F1-score

F1-Score merupakan rata-rata harmonis dari Precision dan Recall. Memberikan keseimbangan antara Precision dan Recall, berguna saat keduanya sama pentingnya. Nilai F1 yang tinggi menunjukkan model memiliki presisi dan recall yang seimbang.

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

e. mAP

mAP atau *mean Average Precision* merupakan metrik evaluasi utama dalam deteksi objek yang mengukur rata-rata nilai *Average Precision* (AP) seluruh kelas. AP dihitung berdasarkan kurva Precision-Recall untuk setiap kelas, sedangkan mAP menggambarkan performa keseluruhan model dalam mendeteksi dan mengklasifikasi objek secara akurat.

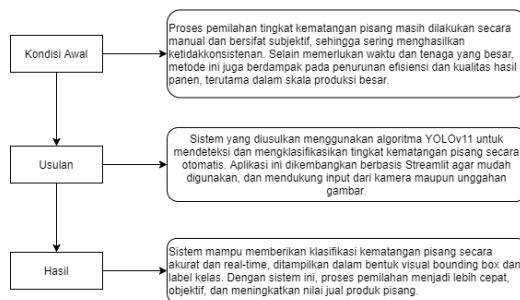
$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AP_k$$

mAP yang sering digunakan adalah mAP@50 atau IoU threshold 0.50 di mana deteksi dianggap benar jika IoU ≥ 0.5 dan mAP@50-95 di mana IoU dihitung pada 0.50 sampai dengan 0.95.

3. METODOLOGI

1. Kerangka Penelitian

Kerangka penelitian disusun sebagai panduan untuk memperjelas alur proses yang dilakukan dalam penelitian ini. Penyusunan kerangka ini bertujuan untuk menggambarkan hubungan logis antara permasalahan awal, solusi yang ditawarkan, serta hasil akhir yang diharapkan. Dengan adanya kerangka tersebut, langkah-langkah dalam proses penelitian menjadi lebih terarah dan mudah dipahami oleh semua pihak. Adapun kerangka penelitian yang digunakan dalam studi ini dapat dilihat pada Gambar 1.



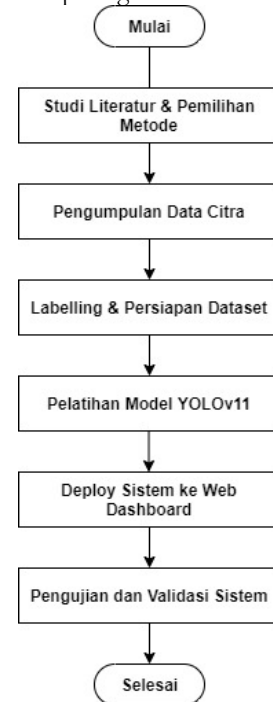
Gambar 1. Kerangka penelitian

Saat ini, proses pemilihan tingkat kematangan pisang umumnya masih dilakukan secara manual. Penilaian tingkat kematangan dilakukan berdasarkan pengamatan visual terhadap warna kulit dan tekstur buah. Metode ini bersifat subjektif, sangat bergantung pada persepsi individu, serta memiliki tingkat ketidakakuratan yang tinggi. Selain itu, proses manual ini membutuhkan waktu dan tenaga yang signifikan, terutama ketika dilakukan dalam skala produksi besar, yang pada akhirnya dapat menurunkan efisiensi serta berdampak pada kualitas dan nilai jual pisang. Keterbatasan metode manual ini memunculkan kebutuhan akan sistem pemilihan yang lebih objektif, efisien, dan akurat.

Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan pengembangan sistem deteksi otomatis tingkat kematangan pisang berbasis algoritma YOLOv11. Pemanfaatan teknologi computer vision dan deep learning memungkinkan proses pemilihan dilakukan secara objektif dan cepat, dengan akurasi yang tinggi. Model YOLOv11 dipilih karena kemampuannya yang unggul dalam deteksi objek real-time serta efisiensi arsitektur yang mendukung penerapan pada aplikasi berbasis sistem ringan. Algoritma YOLOv11 telah terbukti efektif dalam berbagai studi serupa untuk klasifikasi kematangan buah tropis.

Agar solusi yang dikembangkan mudah digunakan oleh pengguna akhir (seperti petani atau penyedia pasar ritel modern), sistem ini diimplementasikan dalam bentuk aplikasi. Dengan pendekatan ini, pengguna dapat mengakses sistem melalui antarmuka web sederhana, di mana mereka dapat mengunggah gambar pisang atau

menggunakan input kamera secara langsung untuk proses deteksi. Tahapan-tahapan yang dilakukan dalam penelitian ini dapat dilihat pada gambar 2 di bawah:



Gambar 2. Flowchart Tahapan Penelitian

Hasil akhir yang diharapkan dari penelitian ini adalah sebuah aplikasi yang mampu mendeteksi dan mengklasifikasi tingkat kematangan pisang secara otomatis dan real-time. Dengan kehadiran sistem ini, proses pemilihan pisang dapat dilakukan dengan lebih cepat, objektif, dan konsisten, sehingga membantu meningkatkan efisiensi proses pemilihan, memperbaiki kualitas produk yang disajikan ke pasar ritel modern, serta meningkatkan nilai ekonomi bagi petani.

2. Data Penelitian dan Pelatihan Data

Sumber data utama pada penelitian ini adalah data primer berupa citra buah pisang yang diperoleh melalui pengambilan gambar secara langsung pada berbagai tingkat kematangan. Data primer digunakan sebagai bahan utama dalam proses pelatihan dan evaluasi model YOLOv11 untuk membangun sistem deteksi otomatis tingkat kematangan pisang. Selain itu, penelitian ini juga memanfaatkan data sekunder yang diperoleh melalui studi literatur untuk memperkuat landasan teori dan mendukung penyusunan metodologi penelitian.

Pengumpulan data primer dilakukan dengan memotret objek pisang menggunakan kamera smartphone dengan resolusi minimal 12 MP. Pengambilan citra dilakukan pada variasi kondisi pencahayaan dan latar belakang untuk meningkatkan kemampuan generalisasi model terhadap kondisi nyata. Setelah proses pengambilan data selesai, seluruh citra diunggah ke platform Roboflow untuk dikelola dan dipersiapkan pada tahap anotasi.

Pengumpulan data primer dilakukan dengan memotret objek pisang menggunakan kamera smartphone dengan resolusi minimal 12 MP. Pengambilan citra dilakukan pada variasi kondisi pencahayaan dan latar belakang untuk meningkatkan kemampuan generalisasi model terhadap kondisi nyata. Setelah proses pengambilan data selesai, seluruh citra diunggah ke platform Roboflow untuk dikelola dan dipersiapkan pada tahap anotasi.

Anotasi dilakukan menggunakan antarmuka labeling online pada Roboflow dengan memberikan label tingkat kematangan sesuai kategori yang ditetapkan, yaitu Belum Matang, Setengah Matang, Matang, dan Terlalu Matang. Proses anotasi dilakukan secara manual oleh penulis untuk menjaga konsistensi dan akurasi label. Setelah anotasi selesai, dataset diekspor dari Roboflow dalam format YOLO (termasuk file YAML) yang kompatibel untuk proses pelatihan model YOLOv11.

Dataset kemudian dibagi menjadi tiga subset, yaitu data training, data validation, dan data testing dengan rasio 70% : 20% : 10%. Pembagian dilakukan secara proporsional agar distribusi kelas pada setiap subset tetap representatif.

Tingkat Kematangan	Training (70%)	Testin g(20%)	Valida si (10%)	Jumlah Dataset
Belum matang	350	100	50	500
Setengah Matang	350	100	50	500
Matang	350	100	50	500
Terlalu matang	350	100	50	500
Total Dataset				2.000

Tabel 1. Training, Testing, dan Validasi

Proses pelatihan dan evaluasi model dilakukan pada lingkungan komputasi dengan spesifikasi perangkat keras dan perangkat lunak sebagaimana dirangkum pada tabel berikut.

Komponen	Spesifikasi
Laptop	Legion 5 15ITH6
GPU	NVIDIA GeForce RTX
CPU	Intel Core i7 Gen 11
RAM	16 GB
Penyimpanan	512 GB SSD
Webcam	HD 720p

Tabel 2. Spesifikasi Perangkat Keras

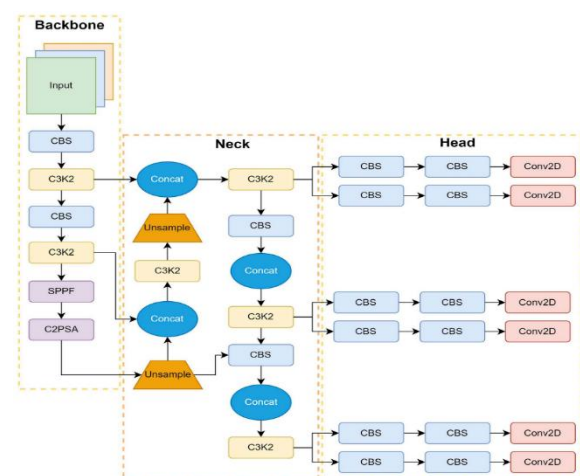
Komponen	Keterangan
Windows 11	Sistem operasi
Python 3.10.8	Bahasa pemrograman utama
Ultralytics	Framework utama
YOLOv11	Optimasi model
OpenVINO Toolkit	Menampilkan Website
Google Chrome	
Visual Studio Code	IDE pengembangan

Tabel 3. Spesifikasi Perangkat Lunak

Data sekunder diperoleh melalui studi literatur dari sumber terpercaya seperti buku, jurnal ilmiah, dan artikel akademik yang relevan dengan computer vision, deep learning, serta penggunaan algoritma YOLO untuk deteksi objek dan klasifikasi kematangan buah. Studi literatur ini digunakan untuk memperkuat dasar teori dan mendukung pengambilan keputusan metodologis dalam penelitian.

3. Arsitektur Model

Arsitektur model global sistem klasifikasi tingkat kematangan pisang berbasis algoritma YOLOv11 dirancang untuk mendeteksi dan mengklasifikasikan pisang ke dalam empat kategori, yaitu Belum Matang, Setengah Matang, Matang, dan Kematangan dengan efisiensi dan akurasi tinggi. Model ini mengintegrasikan teknologi computer vision dan deep learning untuk menganalisis fitur visual seperti warna kulit dan tekstur buah secara kuantitatif. Arsitektur ini terbagi menjadi tiga komponen utama yaitu Backbone, Neck, dan Head, yang masing-masing memiliki peran spesifik dalam proses ekstraksi fitur, pengolahan fitur, dan klasifikasi. Penjelasan rinci arsitektur ini dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur YOLOv11

Komponen Backbone berfungsi sebagai bagian awal yang bertugas mengekstraksi fitur dasar dari gambar

input. Proses dimulai dengan lapisan Input, yang menerima citra pisang dalam format JPEG/PNG dengan resolusi minimal 512x512 piksel. Fitur kemudian diproses melalui serangkaian lapisan CBS (Convolutional, Batch Normalization, SiLU activation), diikuti oleh blok C3k2 yang menggabungkan konvolusi dan koneksi residual untuk meningkatkan kemampuan ekstraksi fitur. Lapisan tambahan seperti SPPF (Spatial Pyramid Pooling Fast) dan C2PSA (Convolutional block with Parallel Spatial Attention) digunakan untuk menangkap fitur multi-skala dan memperhatikan detail kecil seperti tekstur kulit pisang. Proses ini menghasilkan representasi fitur awal yang kaya, yang kemudian diteruskan ke komponen Neck.

Komponen Neck bertugas mengolah fitur yang diekstraksi dari Backbone untuk menghasilkan representasi yang lebih abstrak dan robust. Proses ini melibatkan operasi Upsample untuk meningkatkan resolusi fitur, diikuti oleh lapisan Concat yang menggabungkan fitur dari berbagai tingkatan resolusi. Lapisan C3k2 digunakan kembali untuk menyempurnakan pengolahan fitur melalui konvolusi dan koneksi residual. Struktur ini memungkinkan model untuk menangkap hubungan spasial antar fitur, yang penting untuk membedakan perbedaan halus antara kategori Belum Matang dan Matang berdasarkan warna dan tekstur. Hasil dari Neck kemudian diteruskan ke komponen Head untuk tahap klasifikasi.

Komponen Head bertugas melakukan klasifikasi dan deteksi berdasarkan fitur yang telah diolah. Lapisan CBS digunakan untuk menyesuaikan dimensi fitur, diikuti oleh lapisan Conv2D yang menghasilkan output prediksi. Lapisan ini menghasilkan bounding box untuk lokasi pisang dalam citra serta skor probabilitas untuk empat kategori kematangan (Belum Matang, Setengah matang, matang, dan Terlalu Matang). Proses ini didukung oleh pendekatan anchor-free detection dari YOLOv11, yang memungkinkan deteksi real-time dengan latency target di bawah 100 ms per gambar. Hasil akhir dari Head adalah label kematangan beserta koordinat bounding box, yang divisualisasikan melalui antarmuka aplikasi.

Arsitektur model ini diintegrasikan ke dalam aplikasi, yang memungkinkan pengguna mengunggah gambar pisang atau menggunakan input kamera secara langsung. Proses pra-pemrosesan (normalisasi intensitas piksel, augmentasi seperti rotasi dan flipping) dilakukan sebelum input masuk ke Backbone, sementara output dari Head diterjemahkan ke dalam antarmuka web untuk keperluan pengguna akhir seperti petani dan penyedia pasar ritel.

4. Analisis dan Perancangan

Saat ini, proses pemilahan tingkat kematangan pisang umumnya masih dilakukan secara manual. Penilaian tingkat kematangan dilakukan berdasarkan pengamatan visual terhadap warna kulit dan tekstur buah. Metode ini bersifat subjektif, sangat bergantung pada persepsi individu, serta memiliki tingkat ketidakkonsistenan yang tinggi. Selain itu, proses manual ini membutuhkan waktu dan tenaga yang signifikan, terutama ketika dilakukan dalam skala produksi besar, yang pada akhirnya dapat

menurunkan efisiensi serta berdampak pada kualitas dan nilai jual pisang. Keterbatasan metode manual ini memunculkan kebutuhan akan sistem pemilahan yang lebih objektif, efisien, dan akurat.

4. HASIL DAN PEMBAHASAN

Untuk menilai efektivitas model YOLOv11, dilakukan evaluasi kinerja berdasarkan metrik precision, recall, F1-score, dan mAP@0.5. Hasil evaluasi per kelas kematangan pisang disajikan pada Tabel 4, yang kemudian digunakan sebagai acuan dalam mengidentifikasi kelas yang paling mudah sampai dengan kelas yang paling sulit dikenali oleh model.

Tabel 4 menunjukkan kinerja terbaik pada kelas belum matang dengan precision 93,4%, recall 93,8%, F1-score 0,94, dan mAP@0,5 sebesar 96,6%. Sebaliknya, performa terendah terlihat pada kelas setengah matang, khususnya pada precision 58,2% dan F1-score 0,57, meskipun nilai recall tetap tinggi (92%). Pola tersebut mengindikasikan bahwa model masih menghasilkan prediksi berlebih (*false positive*) pada kelas transisi, yang kemungkinan disebabkan oleh kemiripan karakteristik visual antara setengah matang dan matang. Sementara itu, kelas matang dan terlalu matang menunjukkan performa yang relatif stabil dengan mAP@0,5 masing-masing 82,6%, menandakan kemampuan model yang cukup konsisten pada tingkat kematangan menengah hingga akhir.

Pada Gambar 4, confusion matrix menunjukkan bahwa model YOLOv11 memiliki akurasi tertinggi pada kelas belum matang dengan nilai prediksi benar sebesar 0,93, diikuti oleh terlalu matang 0,83 dan setengah matang 0,78. Namun, terdapat indikasi kebingungan yang cukup jelas pada kelas transisi, khususnya antara matang dan setengah matang, di mana sekitar 0,14 data matang salah diprediksi sebagai setengah matang dan sekitar 0,14 data setengah matang salah diprediksi sebagai matang. Selain itu, sebagian data matang juga keliru diprediksi sebagai terlalu matang sebesar 0,08, yang menunjukkan bahwa kemiripan karakteristik visual pada tingkat kematangan yang berdekatan masih menjadi sumber utama kesalahan klasifikasi.

Pada gambar 5, grafik menunjukkan konvergensi yang baik, yang ditandai oleh penurunan konsisten pada *train/box_loss*, *train/cls_loss*, dan *train/dfl_loss*, serta pola serupa pada metrik validasi (*val/box_loss*, *val/cls_loss*, *val/dfl_loss*) yang menurun tajam pada fase awal pelatihan dan kemudian relatif stabil hingga akhir epoch. Seiring penurunan loss, metrik evaluasi precision dan recall meningkat dan stabil pada kisaran 0,80–0,85, sedangkan mAP@0,5 mencapai sekitar 0,80 dan mAP@0,5–0,95 berada pada kisaran 0,45, yang menunjukkan kemampuan model dalam mendeteksi dan mengklasifikasikan tingkat kematangan pisang secara akurat dan konsisten pada data validasi. Fluktuasi kecil pada beberapa epoch diperkirakan berkaitan dengan variasi kondisi citra (pencahayaan dan

latar belakang) serta kemiripan karakteristik visual pada kelas transisi.

Gambar 6 menyajikan evaluasi sensitivitas ambang *confidence* terhadap kinerja model. Kurva F1–Confidence pada gambar 6(a) menunjukkan bahwa performa agregat seluruh kelas mencapai titik optimum pada $F1=0,79$ dengan *confidence* $\approx 0,277$, yang merepresentasikan kompromi terbaik antara *precision* dan *recall*; peningkatan ambang di atas nilai tersebut cenderung menurunkan F1 karena berkurangnya *recall* akibat penyaringan prediksi yang semakin ketat. Kurva Precision–Recall 6(b) menegaskan variasi performa antar kelas dengan $mAP@0,5$ keseluruhan sebesar 0,835, di mana kelas belum matang memperoleh nilai tertinggi (0,966) sedangkan kelas setengah matang terendah (0,720), mengindikasikan bahwa kelas transisi memiliki tingkat separabilitas fitur visual yang lebih rendah. Selanjutnya, kurva Precision–Confidence 6(c) memperlihatkan *precision* yang meningkat seiring kenaikan *confidence* dan mencapai 1,00 pada *confidence* $\approx 0,916$ untuk agregat seluruh kelas, namun peningkatan ini berimplikasi pada penurunan cakupan deteksi (*recall*), sehingga penetapan ambang *confidence* perlu disesuaikan dengan kebutuhan sistem pada tahap implementasi.

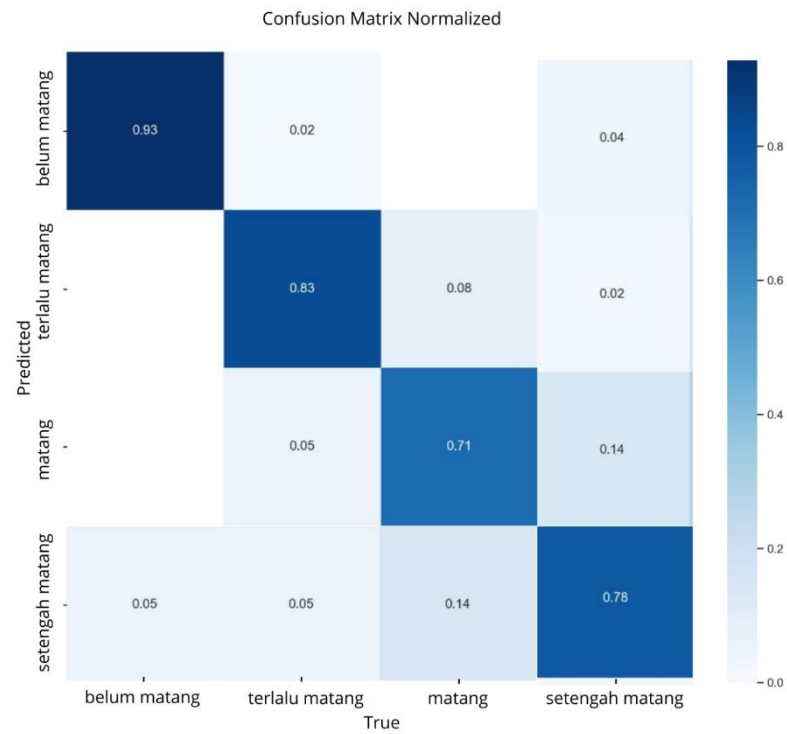
Gambar 7(a) dan 7(b) menampilkan contoh hasil deteksi–klasifikasi tingkat kematangan pisang menggunakan YOLOv11 pada beragam kondisi pengujian. Pada kedua subgambar terlihat bahwa model mampu melakukan lokalisasi objek secara tepat melalui *bounding box* sekaligus memberikan label kelas (belum matang, setengah matang, matang, dan terlalu matang) pada berbagai variasi latar belakang, sudut pengambilan, serta intensitas pencahayaan. Secara kualitatif, prediksi pada kelas ekstrem seperti belum matang dan terlalu matang tampak lebih konsisten, sedangkan pada kelas transisi (setengah matang dan matang) masih ditemukan beberapa kasus yang berpotensi saling tertukar akibat kemiripan karakteristik visual. Visualisasi ini disajikan sebagai bukti kinerja model pada contoh nyata dan sebagai pendukung analisis kuantitatif ($mAP/precision/recall$ serta *confusion matrix*) dalam bagian hasil dan pembahasan.

Untuk memudahkan penggunaan, Gambar 8 menampilkan tampilan *dashboard* web “Tes Kematangan Pisang” sebagai antarmuka implementasi sistem deteksi dan klasifikasi. Pada *dashboard*, hasil pengujian yang telah dilakukan ditampilkan dalam bentuk tabel “Hasil Tes Kematangan” yang memuat pratinjau gambar, nama/tanggal pengujian, catatan, serta stage (kelas kematangan) beserta nilai keyakinan (*confidence*). Selain itu, *dashboard* menyediakan fitur Tambah Hasil untuk menambahkan data uji baru dan menu Aksi (misalnya *view only*) untuk melihat detail hasil deteksi pada setiap entri. Tampilan ini menunjukkan bahwa keluaran model tidak hanya berupa label, tetapi juga terdokumentasi secara terstruktur sehingga memudahkan pemantauan dan penelusuran riwayat hasil klasifikasi.

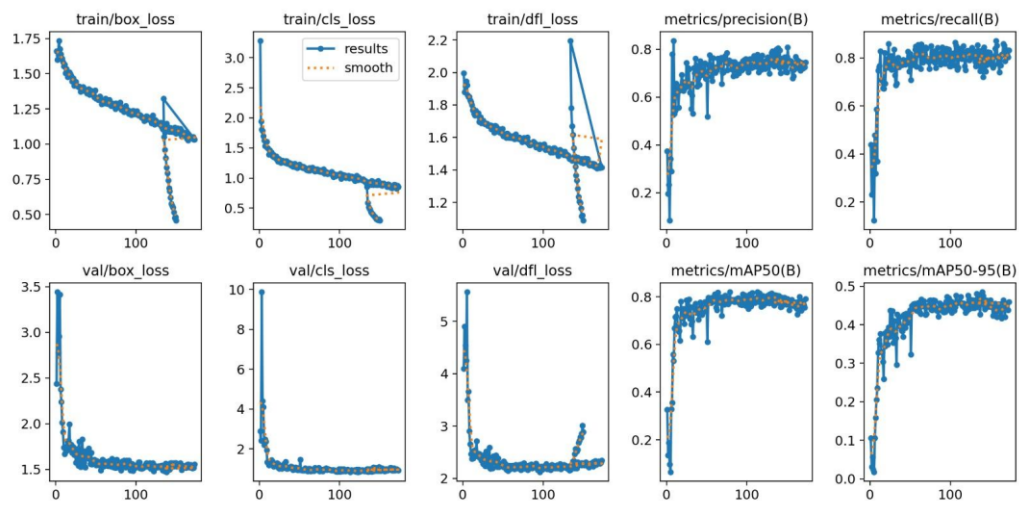
Hasil evaluasi kuantitatif dan visualisasi menunjukkan bahwa sumber kesalahan utama model berada pada kelas transisi, terutama pertukaran prediksi antara setengah matang dan matang, yang mengindikasikan tumpang tindih karakteristik visual pada tingkat kematangan berdekatan. Perubahan warna hijau–kuning, kemunculan bercak, dan variasi tekstur terjadi secara gradual sehingga batas antar kelas tidak selalu tegas, dan kasus *borderline* berpotensi memicu salah klasifikasi. Selain itu, akurasi prediksi dipengaruhi kualitas citra, meliputi pencahayaan tidak merata/ketidakkuratan *white balance*, blur atau ketidakkfokus, oklusi/pemotongan objek, serta latar belakang dengan spektrum warna serupa yang menurunkan kontras dan mengganggu ekstraksi fitur pada area objek. Temuan ini menegaskan keterbatasan penelitian, yaitu ketergantungan performa pada keragaman dataset dan konsistensi akuisisi citra, sehingga generalisasi berisiko menurun pada lingkungan lapangan yang lebih heterogen (*domain shift*). Dalam penerapan operasional, disarankan menggunakan ambang *confidence* yang telah dioptimalkan (misalnya pada titik maksimum F1) serta menyediakan mekanisme verifikasi untuk prediksi berkeyakinan rendah, khususnya pada kelas transisi. Ke depan, peningkatan dapat dilakukan melalui pengayaan data pada kondisi ekstrem dan *borderline*, penguatan augmentasi fotometrik, serta evaluasi pembandingan dan studi ablation untuk mengukur kontribusi konfigurasi pelatihan terhadap kinerja model. Dengan demikian, model YOLOv11 menunjukkan kinerja yang stabil, namun tantangan utama masih berada pada pemisahan kelas transisi serta ketahanan terhadap variasi kualitas citra.

Tabel 4. Hasil Evaluasi Kinerja YOLOv11 pada Klasifikasi Kematangan Pisang


No	Tingkat Kematangan (%)	Precision (%)	Recall (%)	F1-Score (%)	mAP50(%)
1	Belum matang	93.4	93.8	0.94	96.6
2	Setengah Matang	58.2	92	0.57	72
3	Matang	69.7	79.9	0.72	82.6
4	Terlalu matang	80.2	82.8	0.84	82.6




Gambar 4. Confusion Matrix



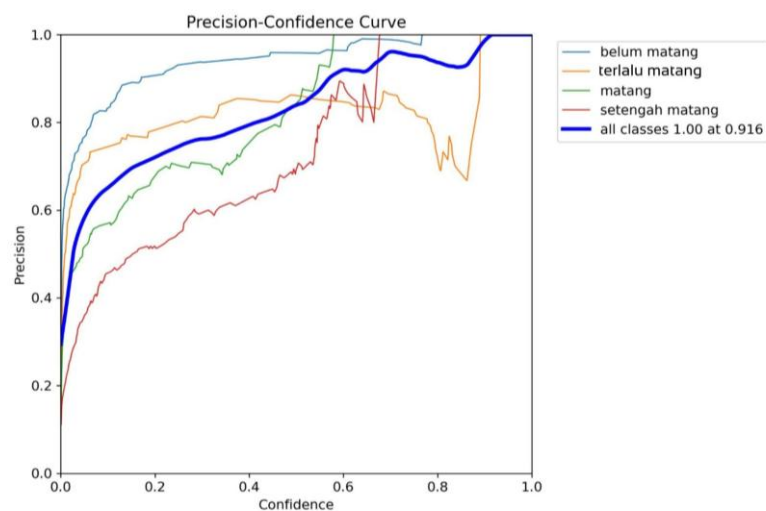
Gambar 5. Training and Validation Metrics



(a)

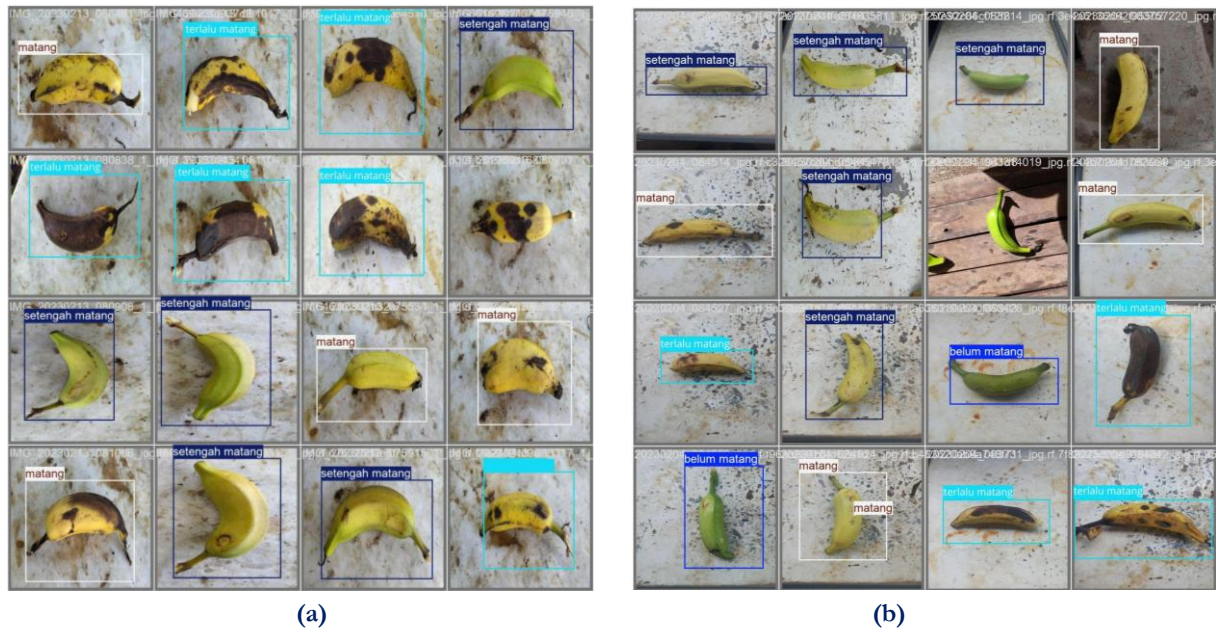


(b)

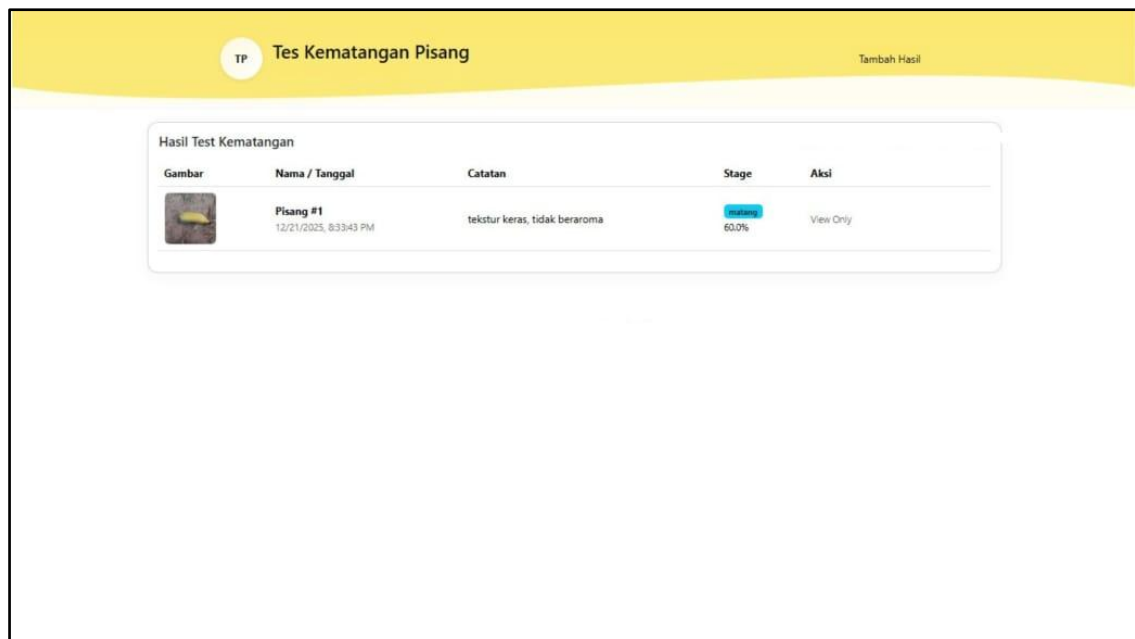


(c)

Gambar 6. (a) Precision-confidence curve, (b) F1-Confidence curve, (c) Recall-confidence curve



Gambar 7. (a) Hasil deteksi tingkat kematangan yang benar, (b) Hasil deteksi tingkat kematangan yang salah



Gambar 8. Hasil Deteksi Buah Pisang Pada Dashboard Web

5. KESIMPULAN

Berdasarkan hasil penelitian dan pengembangan sistem klasifikasi tingkat kematangan buah pisang menggunakan algoritma YOLOv11, dapat disimpulkan beberapa hal sebagai berikut:

1. Algoritma YOLOv11 terbukti efektif dalam mengklasifikasikan tingkat kematangan pisang ke dalam empat kategori. Kelas ekstrem (belum matang dan kematangan) menunjukkan performa terbaik, sedangkan kelas transisi (setengah matang dan matang) cenderung

kurang stabil akibat kemiripan karakteristik visual.

2. Model mencapai nilai mAP@0.5 sebesar 0,835, dengan precision dan recall tertinggi pada kelas belum matang (0,934 dan 0,938). Nilai F1-score optimal diperoleh pada confidence 0,28. Performa model menurun pada kelas transisi ketika threshold meningkat, menunjukkan sensitivitas terhadap perubahan confidence.
3. Implementasi antarmuka sistem menggunakan aplikasi yang memberikan kemudahan bagi pengguna dalam mengakses fungsi klasifikasi tanpa memerlukan keahlian teknis yang mendalam. Sistem mampu menampilkan hasil deteksi secara real-time, termasuk visualisasi bounding box, label kelas, dan confidence score, dengan waktu inferensi rata-rata sebesar 63,8 milidetik per citra.

Evaluasi visual menunjukkan bahwa sistem bekerja secara optimal dalam kondisi pencahayaan yang baik dan

objek terlihat secara utuh. Namun demikian, performa sistem menurun pada citra buram, objek yang hanya sebagian terlihat, atau latar belakang yang menyerupai objek utama, sehingga masih terdapat keterbatasan dalam hal generalisasi model terhadap variasi kondisi lingkungan.

Kontribusi utama penelitian ini terletak pada pemanfaatan YOLOv11 untuk klasifikasi kematangan pisang, yang menawarkan peningkatan arsitektur berupa C3k2 dan mekanisme parallel spatial attention. Namun, keterbatasan dalam penelitian terletak pada variasi kondisi citra, di mana performa model cenderung menurun pada pencahayaan tidak merata dan latar belakang yang menyerupai warna pisang. Selain itu, kelas transisi seperti setengah matang dan matang masih sulit dibedakan akibat kemiripan karakteristik visual.

Untuk penelitian selanjutnya, disarankan melakukan penambahan dan perluasan variasi dataset, khususnya pada kelas transisi, serta penerapan teknik augmentasi pencahayaan, dan penyesuaian latar belakang.

DAFTAR PUSTAKA

- [1] F. R. Ramadhan, "Sistem Pendeteksi Kematangan Pisang Menggunakan YOLOv5 Berbasis Internet of Things (IoT)," *INTECOMS: Journal of Information Technology and Computer Science*, vol. 8, no. 2, 2025, doi: 10.31539/intecom.s.v8i2.13637
- [2] R. A. H. Majdudin, "Pineapple Ripeness Detection Using YOLO v8 Algorithm," *PIJAR: Publication of the International Journal of Academic Research*, vol. 1, no. 1, pp. 50-54, 2025, doi: 10.63222/pijar.v1i1.7
- [3] J. Liu, J. Guo, and S. Zhang, "YOLOv11-HRS: An improved model for strawberry ripeness detection," *Journal of Agricultural Informatics*, vol. 15, no. 2, pp. 10-21, 2024, doi: 10.3390/agronomy15051026.
- [4] N. Banduka, K. Tomić, J. Živadinović, and M. Mladineo, "Automated dual-side leather defect detection and classification using YOLOv11: A case study in the finished leather industry," *Processes*, vol. 12, no. 12, p. 2892, 2024, DOI: 10.3390/pr12122892.
- [5] M. M. Huda, K. A. Prasetyo, M. A. R. Vieri, R. Wulanningrum, and M. A. D. W. Dara, "Identifikasi mangga berdasarkan tingkat kematangan menggunakan YOLOv11," in *Prosiding Seminar Nasional Teknologi dan Sains*, vol. 4, Universitas Nusantara PGRI Kediri, Kediri, Indonesia, Jan. 2025, e-ISSN: 2828-299X.
- [6] M. F. Ajizi, D. Syauqy, and M. H. H. Ichsan, "Klasifikasi kematangan buah pisang berbasis sensor warna dan sensor load cell menggunakan metode Naive Bayes," *JESSI*, vol. 12, no. 2, pp. A89-A94, 2023.
- [7] A. Wahid, "Klasifikasi tingkat kematangan buah pisang dalam ruang warna RGB menggunakan jaringan syaraf tiruan (JST)," *Jurnal Teknik Komputer*, vol. 9, no. 1, pp. 15-21, 2023, doi: 10.26858/jessi.v2i1.20327.
- [8] J. D. Irawan, "Optimasi model klasifikasi tingkat kematangan buah pisang menggunakan fine-tuning MobileNetV2," *Jurnal Ilmiah Teknologi dan Komputer*, vol. 8, no. 2, pp. 55-63, 2023.
- [9] G. F. Nama, "Pemantauan musang pandan menggunakan metode computer vision dengan model YOLOv11," *Jurnal Teknologi Informasi dan Komputer*, vol. 10, no. 1, pp. 22-29, 2024.
- [10] M. P. Sirappa, "Potensi pengembangan tanaman pisang: Tinjauan syarat tumbuh dan teknik budidaya pisang dengan metode BIT," *Jurnal Hortikultura Tropis*, vol. 6, no. 3, pp. 120-128, 2022.
- [11] S. Hartati, D. Pamungkas, and R. Farhan, "Rancang bangun alat ukur kematangan buah pisang berdasarkan warna dan berat menggunakan mikrokontroler ESP32," in *Prosiding Seminar Nasional Sistem Informasi dan Teknologi Informasi (SENSASI 2024)*, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia, Mar. 2024, ISSN: 2964-9871.
- [12] G. Ramadhani, R. C. Pratama, W. R. Yahya, and R. Wulanningrum, "Rancang bangun sistem deteksi buah jeruk menggunakan YOLOv8," in *Prosiding Seminar Nasional Teknologi dan Sains*, vol. 4, Universitas Nusantara PGRI Kediri, Kediri, Indonesia, Jan. 2025, e-ISSN: 2828-299X.
- [13] P. Li, J. Zheng, P. Li, H. Long, M. Li, and L. Gao, "Tomato maturity detection and counting model based on MHSA-YOLOv8," *Sensors*, 23(15):6701, 2023. DOI: 10.3390/s23156701.
- [14] M. Mao and M. Hong, "YOLO object detection for real-time fabric defect inspection in the textile industry: A review of YOLOv1 to YOLOv11," *Sensors*, 25(7):2270, 2025. DOI: 10.3390/s25072270.



- [15] Y. Liao, L. Li, H. Xiao, F. Xu, B. Shan, and H. Yin, "YOLO-MECD: Citrus detection algorithm based on YOLOv11," *Agronomy*, vol. 15, no. 3, p. 687, 2025, doi: 10.3390/agronomy15030687.
- [16] R. Khanam and M. Hussain, "YOLOv11: An overview of the key architectural enhancements," *arXiv preprint*, Oct. 2024, doi: 10.48550/arXiv.2410.17725.
- [17] M. A. R. Alif, "YOLOv11 for vehicle detection: Advancements, performance, and applications in intelligent transportation systems," *arXiv preprint*, 2024, doi: 10.48550/arXiv.2410.22898.
- [18] D. Pamungkas, "Diagnosa penyakit tanaman menggunakan YOLOv11: Studi kasus deteksi bercak coklat dan daun blast," *Jurnal Teknik Informatika dan Sains Komputer*, vol. 12, no. 1, pp. 33–40, 2024.

