

KLASIFIKASI TINGKAT KEMATANGAN BUAH MANGGA BERBASIS CITRA DIGITAL MENGUNAKAN YOLOV8

Diterima Redaksi: 11 November 2025; Revisi Akhir: 26 Mei 2026; Diterbitkan Online: 5 Juni 2026

**Sopyan¹⁾, Fransiscus Andre Suwarno²⁾, Rasya Abel Putra Gumulija³⁾, Sumanto⁴⁾, Ghofar
Taufiq⁵⁾, Jefina Tri Kumalasari⁶⁾**

^{1, 2,3,4,5,6)} Program Studi Teknik Informatika, Fakultas Informatika, Universitas Bina Sarana Informatika Jl. Raya Jatiwaringin -
No.18, Jaticempaka, Kec. Pd.Gede, Kota Bekasi, Jawa Barat

e-mail: sopyanpian2807@gmail.com ¹⁾, frans300904@gmail.com ²⁾, abelputrag@gmail.com ³⁾, sumanto@bsi.ac.id ⁴⁾,
ghofar.gft@gmail.com ⁵⁾, jefina.jt@bsi.ac.id ⁶⁾

Abstrak: Penilaian konvensional terhadap tingkat kematangan buah mangga umumnya didasarkan pada observasi visual. Pendekatan manual ini memiliki keterbatasan karena sangat bergantung pada pengalaman individu serta faktor lingkungan, menjadikannya rentan terhadap inefisiensi dan ketidakakuratan pada operasi skala besar. Untuk mengatasi hal ini, kami mengusulkan solusi otomatis berbasis deep learning melalui implementasi YOLOv8 (You Only Look Once versi 8) untuk klasifikasi kematangan buah mangga. Kami menggunakan dataset yang mencakup 2.328 citra dari Roboflow Universe, yang dikelompokkan menjadi tiga status: mentah, terlalu matang, dan matang. Model dilatih selama 50 epoch dengan resolusi 640 X 640 piksel. Hasil evaluasi menggunakan metrik Precision, Recall, mAP, dan Confusion Matrix menunjukkan kinerja yang superior. Model mencapai mAP50 sebesar 0,92139, mAP50–95 sebesar 0,83656, dan akurasi total 92,13%. Temuan ini mengindikasikan bahwa YOLOv8 merupakan metode deteksi dan klasifikasi yang stabil, cepat, dan efektif untuk pengenalan kematangan buah, sangat mendukung implementasi Smart Farming 4.0.

Kata Kunci— YOLOv8, Citra Digital, Kematangan Buah, Deep Learning, Klasifikasi

Abstract: Conventional assessment of mango ripeness is typically conducted through subjective visual observation, making the process highly dependent on individual expertise and environmental variables. This manual approach often results in inconsistent outcomes and proves inefficient when applied to large-scale operations. To address this limitation, this research introduces an automated solution leveraging the YOLOv8 (You Only Look Once version 8) deep learning algorithm for classifying mango ripeness using digital images. The study utilizes a dataset of 2,328 images sourced from the Roboflow Universe, which are organized into three distinct maturity levels: unripe, overripe, and ripe. The YOLOv8 model underwent training for 50 epochs with an input size of 640 X 640 pixels, and its performance was rigorously evaluated using Precision, Recall, mAP, and the Confusion Matrix. The model successfully achieved an mAP50 of 0.84497, an mAP50–95 of 0.86308, and a classification accuracy of 92.13%. These findings confirm the superior performance of YOLOv8 in providing a fast, stable, and highly accurate method for ripeness detection, thereby facilitating automation in agriculture and advancing the goals of Smart Farming 4.0.

Keywords— YOLOv8, Digital Image, Fruit Ripeness, Deep Learning, Classification

Penulis Korespondensi:

Sopyan,
Program Studi Informatika,
Universitas Bina Sarana Informatika,
Email: sopyanpian2807@gmail.com
Orchid ID: <http://orcid.org/0009-0000-0864-8475>

I. PENDAHULUAN

Isu utama dalam rantai pasok komoditas mangga di Indonesia adalah ketidaktepatan dalam penilaian tingkat kematangan buah [1]. Proses penentuan kematangan secara tradisional masih mengandalkan inspeksi visual terhadap karakteristik fisik seperti warna, tekstur, dan aroma, yang sifatnya inheren subjektif. Hal ini berkaitan erat dengan panduan budidaya dan penanganan mangga di Indonesia [2]. Hasil pengamatan sering menjadi tidak konsisten karena dipengaruhi oleh berbagai faktor, termasuk kondisi pencahayaan, perbedaan varietas, dan pengalaman individu pekerja. Akibatnya, hal ini berdampak langsung pada penurunan mutu, kesalahan jadwal panen, dan potensi hilangnya nilai jual mangga.

Menyambut era Industri 4.0, perkembangan teknologi digital telah membawa solusi modern terhadap tantangan di sektor pertanian. Perkembangan menuju pertanian presisi dan smart farming ini juga didukung oleh potensi besar generasi milenial dalam mengadopsi dan menerapkan inovasi digital [3]. Penerapan Artificial Intelligence (AI) dan Computer Vision menjadi kunci utama dalam inovasi ini. Konsep Smart Farming mempromosikan integrasi sistem berbasis AI yang memungkinkan petani mengambil keputusan yang cepat, tepat, dan efisien melalui analisis data, baik visual maupun sensorik. Dalam konteks pengolahan citra, AI dapat mengenali pola dan karakteristik objek secara otomatis dengan akurasi tinggi, menjadikannya sangat potensial untuk klasifikasi kematangan buah mangga.

Di antara berbagai pendekatan object detection, algoritma YOLO (*You Only Look Once*) menjadi pilihan populer karena efisiensinya. YOLO memungkinkan sistem melakukan deteksi dan klasifikasi objek secara real-time dalam satu langkah pemrosesan tanpa memerlukan tahap segmentasi terpisah. Keunggulan ini, ditambah dengan kecepatan dan efisiensinya dalam mengenali objek pada citra digital, menjadikan YOLO sangat relevan untuk mendeteksi kematangan buah yang ditandai oleh variasi warna kulit mangga.

YOLOv8, sebagai versi terbaru, menawarkan peningkatan signifikan melalui arsitektur anchor-free. Arsitektur ini tidak hanya meningkatkan efisiensi prediksi tetapi juga meningkatkan akurasi melalui mekanisme feature extraction yang lebih mendalam dan ringan secara komputasi. Selain itu, YOLOv8 mendukung transfer learning dan optimasi parameter yang lebih fleksibel, memungkinkannya beradaptasi lebih baik terhadap dataset citra beragam seperti buah mangga.

Penelitian ini bertujuan untuk menciptakan sistem klasifikasi berbasis citra digital untuk kematangan mangga menggunakan algoritma YOLOv8, berdasarkan potensi yang telah disebutkan sebelumnya. Diharapkan sistem ini dapat meningkatkan efisiensi operasional, mengurangi subjektivitas dalam proses seleksi, serta berkontribusi pada implementasi pertanian cerdas (smart agriculture) di Indonesia.

Penggunaan YOLOv8 dipilih karena arsitekturnya yang fleksibel, masih tergolong baru sehingga minim bug, serta proses perbaikan (debugging) yang lebih mudah dilakukan. Kendala pada penelitian sebelumnya yang mengklasifikasikan kematangan mangga terletak pada keterbatasan akurasi akibat variasi pencahayaan dan kompleksitas latar belakang objek. Implementasi YOLOv8 dalam penelitian ini diharapkan mampu mengatasi kendala tersebut, sekaligus meningkatkan efisiensi operasional dan mengurangi subjektivitas dalam proses seleksi.

II. TINJAUAN PUSTAKA

A. Artificial Intelligence dan Deep Learning

Kemajuan pesat dalam AI dan pengolahan citra digital telah memungkinkan pengembangan sistem kategorisasi buah otomatis. Metodologi Deep Learning, khususnya Convolutional Neural Networks (CNN), telah menunjukkan manfaat yang cukup besar dalam hal efisiensi dan akurasi, melampaui metode konvensional. Keunggulan CNN ini dibuktikan, misalnya, dalam studi [4] yang berhasil mencapai tingkat akurasi tinggi saat mengklasifikasi kematangan buah mangga.

B. Penerapan CNN pada Tanaman Mangga

Fokus awal dari penelitian terkait adalah mengatasi isu pada tanaman. [5] melakukan tinjauan literatur mengenai deteksi penyakit mangga dan menyimpulkan bahwa pengenalan gejala penyakit dapat dilakukan sejak dini melalui analisis fitur visual pada daun. Lebih jauh, [6] mendemonstrasikan aplikasi

Deep Learning secara spesifik untuk diagnosis masalah kesehatan pada mangga, di mana model CNN digunakan untuk mengklasifikasi status sehat dan sakit pada daun mangga.

C. *Klasifikasi Kematangan dan Jenis Buah*

Dalam ranah klasifikasi kematangan, [7] mengaplikasikan CNN untuk membedakan tingkat kematangan mangga varietas Garifta Merah, dengan akurasi model multi-layer mencapai 89%. Hasil ini memperkuat bahwa analisis visual berbasis CNN efektif untuk mengenali perubahan warna pada kulit buah. Penelitian lain juga mengeksplorasi penggunaan *machine learning* untuk pengenalan buah. [8] berhasil mencapai akurasi di atas 90% dalam klasifikasi jenis mangga menggunakan backpropagation neural network. Temuan ini didukung oleh [9], yang memanfaatkan CNN untuk mendeteksi jenis mangga berbasis Android.

D. *Object Detection Menggunakan YOLO*

Di bidang object detection, [10] menunjukkan pemanfaatan algoritma You Only Look Once (YOLO) untuk identifikasi objek makanan khas Palembang secara real-time. Kecepatan pemrosesan dan efisiensi yang menjadi keunggulan utama YOLO menjadikannya sangat adaptif pada berbagai tugas citra, termasuk klasifikasi buah, tanpa mengorbankan akurasi. Potensi arsitektur YOLO untuk ini semakin didukung oleh studi [11], yang membuktikan stabilitas serta kecepatan komputasi algoritma ini dalam melakukan lokalisasi objek secara instan, sekaligus kemampuannya dalam mempertahankan akurasi klasifikasi pada pengujian di dalam range sudut kamera tertentu serta kondisi lingkungan yang dinamis.

E. *Smart Farming dan Pertanian Presisi*

Dalam konteks pertanian yang lebih luas, [12] menekankan Smart Farming 4.0 sebagai strategi penting untuk memodernisasi sektor pertanian Indonesia. Gagasan ini menempatkan integrasi AI, sensor digital, dan Internet of Things (IoT) sebagai hal penting untuk meningkatkan produktivitas dan efisiensi. Isu pertanian presisi juga dikaji oleh [3], yang mengulas karakteristik dan potensi generasi milenial dalam pengembangan pertanian berbasis teknologi di Indonesia.

F. *Metode Klasifikasi dan Pra-pemrosesan Citra*

Selain itu, mengembangkan sistem klasifikasi kematangan manggis menggunakan metode Naïve Bayes, menekankan kombinasi atribut warna dan tekstur untuk meningkatkan presisi. Temuan ini konsisten dengan penelitian [14] yang menggunakan Support Vector Machine (SVM) untuk memvalidasi bahwa ekstraksi fitur warna dan tekstur menghasilkan keputusan klasifikasi yang lebih objektif pada komoditas pertanian. Terakhir, [15] menganjurkan optimasi kualitas gambar mangga dengan menggunakan Median Filter sebagai teknik pra-pemrosesan., yang terbukti meningkatkan kejelasan gambar dan penting untuk kinerja model deteksi deep learning.

G. *Rangkuman dan Posisi Penelitian*

Sebagai rangkuman, studi-studi object detection dari [10] dan [11] konsisten menunjukkan bahwa arsitektur keluarga YOLO menawarkan keseimbangan superior antara akurasi dan kecepatan inferensi real-time, melebihi arsitektur dua tahap seperti R-CNN. Oleh karena itu, penelitian ini bertujuan menggabungkan keunggulan feature extraction CNN dengan efisiensi deteksi YOLOv8 untuk mengembangkan sistem klasifikasi kematangan mangga yang berkinerja unggul dalam presisi dan kecepatan implementasi untuk smart agriculture di Indonesia.


III. METODE PENELITIAN

A. *Metode Penelitian*

Tahapan penelitian terdiri atas lima langkah utama: pengumpulan data, pelabelan data, pembagian data, pelatihan YOLOv8, evaluasi model, dan analisis hasil akhir. Diagram alir di atas mengilustrasikan urutan tahapan yang sistematis dalam penelitian ini, dari awal hingga kesimpulan.

Diagram alir pada Gambar 1 mengilustrasikan urutan tahapan yang sistematis dalam penelitian ini, dari awal hingga kesimpulan. Proses diawali dengan Pengumpulan Data citra buah mangga, diikuti oleh Pelabelan Data (annotation) yang memisahkan objek mangga ke dalam kelas kematangan yang telah ditentukan. Selanjutnya, data dibagi menjadi set pelatihan, validasi, dan pengujian (Pembagian Data). Inti dari metodologi terletak pada tahap Pelatihan Model YOLOv8 untuk mendeteksi dan mengklasifikasikan

buah mangga. Kinerja model kemudian diukur melalui Evaluasi Model menggunakan metrik mAP dan Confusion Matrix, dan diakhiri dengan Analisis & Hasil Akhir untuk mendapatkan kesimpulan mengenai performa klasifikasi tingkat kematangan.



Gambar 1 Diagram Alir Metode Penelitian

B. Dataset

Dataset diambil dari Roboflow Universe, berjumlah 2.328 citra, dengan tiga kelas kematangan: mentah, terlalu matang, dan matang.



Gambar 2 Mangga Mentah

Sumber: Roboflow Universe – Dataset “Mango Fruit Ripeness”
(<https://universe.roboflow.com/school-vakkx/mango-fruit-ripeness>)



Gambar 3 Mangga Terlalu Matang

Sumber: Roboflow Universe – Dataset “Mango Fruit Ripeness”
(<https://universe.roboflow.com/school-vakkx/mango-fruit-ripeness>)




Gambar 4 Mangga Matang
Sumber: Roboflow Universe – Dataset “Mango Fruit Ripeness”
(<https://universe.roboflow.com/school-vakxx/mango-fruit-ripeness>)

Proses pelabelan dataset telah disediakan secara otomatis melalui platform Roboflow ke dalam 3 kelas objek, yaitu: mangga mentah, mangga matang, dan mangga terlalu matang. Pada penelitian ini tidak dilakukan proses augmentasi data karena jumlah dataset asli yang tersedia sudah cukup besar dan mencakup variasi pencahayaan, posisi, serta latar belakang yang beragam. Pendekatan ini dipilih agar model YOLOv8 dapat dilatih langsung menggunakan data asli tanpa modifikasi, guna menilai performa dasar (baseline) dari model terhadap citra buah mangga di setiap kelasnya.

C. Pelatihan Model

Pelatihan menggunakan YOLOv8 karena efisien dan ringan. Parameter pelatihan meliputi batch size 16, learning rate 0.001, epoch 50, serta ukuran gambar 640×640 piksel.



Gambar 5 Arsitektur model YOLOv8

D. Evaluasi Model

Penilaian model dilakukan menggunakan banyak ukuran penting untuk menilai kinerja klasifikasi, yaitu: Presisi, Recall, mAP50, mAP50–95, dan Confusion Matrix. Ukuran-ukuran ini dipilih karena memberikan penilaian menyeluruh terhadap efektivitas deteksi objek, termasuk presisi dan kelengkapan hasil kategorisasi.

Precision menunjukkan akurasi model dalam mendeteksi item yang benar-benar termasuk dalam kelas tertentu, sedangkan Recall menggambarkan seberapa banyak objek yang benar berhasil terdeteksi oleh sistem. Nilai keduanya sangat penting dalam menilai keseimbangan antara kesalahan deteksi positif dan negatif.

Secara bersamaan, mAP50 dan mAP50–95 (mean Average Precision) digunakan untuk menilai kinerja model di berbagai ambang batas Intersection over Union (IoU). Nilai mAP50 merepresentasikan performa model pada ambang IoU 50%, sedangkan mAP50–95 memberikan rata-rata hasil pada rentang IoU 50–95% untuk menilai konsistensi model terhadap variasi posisi dan bentuk objek.

Selain itu, *Confusion Matrix* digunakan untuk memvisualisasikan hasil klasifikasi tiap kelas (mentah, terlalu matang, dan matang). Matriks ini menggambarkan alokasi kesalahan prediksi di antara kelas-kelas. Nilai diagonal menunjukkan jumlah prediksi yang akurat, sedangkan elemen di luar diagonal menunjukkan kesalahan klasifikasi.

Untuk melengkapi analisis, hasil evaluasi juga dilihat dari grafik loss dan akurasi per epoch. Pengurangan progresif pada nilai kerugian hingga stabilisasi menandakan bahwa model telah mencapai konvergensi optimal tanpa overfitting. Pengamatan dilakukan pula terhadap waktu inferensi (inference time) per citra, yang menunjukkan efisiensi model dalam melakukan deteksi real-time.


IV. HASIL DAN PEMBAHASAN

A. Konfigurasi dan Proses Pelatihan Model YOLOv8

Pelatihan model YOLOv8 dilakukan menggunakan *dataset* yang terdiri dari 2.328 citra, yang dibagi menjadi tiga kategori kematangan: mentah, terlalu matang, dan matang. Proses pelatihan dijalankan selama 50 epoch, diatur dengan *learning rate* 0,001, *batch size* 16, dan resolusi citra 640 X 640 piksel. Setiap citra telah melalui pelabelan dalam format YOLO agar sistem dapat mendeteksi area buah dengan tingkat presisi yang optimal.

B. Analisis Konvergensi Loss dan Akurasi Model

Hasil pelatihan model menunjukkan konvergensi yang sangat stabil sejak *epoch* ke-20. Indikasi stabilitas terlihat dari *training loss* yang mengalami penurunan drastis dan mendekati nilai minimum kurang dari 0,1 pada akhir periode pelatihan. Nilai metrik evaluasi yang dicapai adalah mAP50 sebesar 0,92139 dan mAP 50-95 sebesar 0,83656. Angka-angka ini menunjukkan bahwa model memiliki kemampuan *object detection* yang tinggi, mampu mengenali buah mangga dengan presisi di berbagai kondisi visual dan ambang *threshold* IoU (0,5 hingga 0,95). Selain itu, nilai IoU (*Intersection over Union*) sebesar 0,83656 yang tercatat menunjukkan bahwa area *bounding box* hasil prediksi model sangat akurat dan mendekati area sebenarnya pada citra uji.




Gambar 6 Grafik Akurasi dan Loss

Grafik pada Gambar 6 mengilustrasikan penurunan yang stabil dalam training loss dari epoch pertama hingga terakhir, menandakan proses pelatihan yang stabil tanpa indikasi overfitting. Pengurangan loss box, loss klasifikasi, dan loss fokus distribusi menunjukkan bahwa model secara progresif meningkatkan kemampuannya untuk mengidentifikasi mangga dengan akurasi yang lebih baik di setiap iterasi.

C. Evaluasi Kinerja Model pada Data Validasi

Hasil pengujian model terhadap data validasi memperlihatkan bahwa YOLOv8 mampu melakukan deteksi dan klasifikasi tingkat kematangan buah mangga secara real-time dengan kecepatan 45–50 citra per detik pada GPU RTX 3060. Hal ini menunjukkan efisiensi tinggi dari model, menjadikannya sangat potensial untuk diterapkan di industri penyortiran buah otomatis.

Berdasarkan visualisasi pada Confusion Matriks (Gambar 7), model memperlihatkan kemampuan yang unggul dalam membedakan ketiga kelas kematangan buah (mentah, terlalu matang, matang). Di sisi efisiensi, pengujian real-time menunjukkan bahwa YOLOv8 mampu melakukan deteksi dan klasifikasi dengan kecepatan sekitar 45–50 frame per detik (FPS) pada GPU kelas menengah, membuktikan efisiensi komputasi model, menjadikannya solusi ideal untuk integrasi pada sistem penyortiran otomatis.



Gambar 7 Confusion Matriks

Tabel 1. Hasil Confusion Matriks

Tabel Kelas	TP	TN	FP	FN
Kelas Over Ripe	800	4935	445(1+444)	74(10+64)
Kelas Ripe	1908	3223	626(10+616)	113(1+112)
Kelas Unripe	1739	2955	404	156(156+0)

D. Perbandingan dengan Penelitian Terdahulu

Model YOLOv8 diimplementasikan dalam penelitian ini menunjukkan peningkatan kinerja yang substansial dibandingkan dengan beberapa studi terdahulu. [7] Berbasis arsitektur CNN konvensional mencatatkan akurasi 89%, namun memiliki keterbatasan pada waktu inferensi relatif lama akibat beban komputasi layer yang sekuensial. sementara itu, pendekatan berbasis *machine learning* tradisional. [13] seperti Naive Bayes dengan akurasi 87%, tetapi sangat bergantung pada ekstraksi fitur manual (*handcrafted features*) yang kurang adaptif terhadap variasi objek di lapangan. Di sisi lain, [15] hanya berfokus pada tahap pemrosesan citra menggunakan *median filter* tanpa melakukan klasifikasi objek secara langsung.

Perbandingan secara tabel tidak representatif untuk disajikan karena adanya perbedaan mendasar pada metrik evaluasi, di mana studi terdahulu hanya berfokus pada akurasi klasifikasi citra tunggal (*image classification*), sedangkan penelitian ini menggunakan metrik *object detection* (seperti mAP) yang melibatkan lokalisasi koordinat objek secara *real-time*. Hasil YOLOv8 pada penelitian ini terbukti lebih unggul karena arsitekturnya mampu mengekstrak fitur spasial kompleks dan degradasi warna kematangan buah secara simultan melalui *convolutional backbone* (C2f) serta mekanisme *decoupled head* yang memisahkan tugas klasifikasi dan regresi *bounding box* secara lebih efisien.

E. Pembahasan dan Implikasi terhadap Aplikasi Pertanian Presisi

Temuan validasi menunjukkan bahwa model tidak mengalami overfitting, karena *validation loss* sebanding dengan *training loss*. Hal ini menunjukkan bahwa model tersebut memiliki fleksibilitas yang kuat terhadap data baru, sehingga cocok untuk digunakan dalam kondisi lapangan yang ditandai dengan lingkungan dan pencahayaan yang beragam. Secara teknis, pendekatan YOLOv8 memberikan keunggulan signifikan dibandingkan metode konvensional berbasis CNN. Hal ini penting untuk aplikasi pertanian presisi (*precision agriculture*), di mana sistem perlu bekerja secara waktu nyata untuk mengklasifikasikan ribuan buah dalam satu kali proses.

Selain itu, penelitian ini juga menunjukkan bahwa jumlah data yang cukup besar (lebih dari dua ribu citra) berperan penting dalam meningkatkan akurasi model. Dengan demikian, kombinasi dataset yang representatif dan algoritma YOLOv8 yang kuat menghasilkan performa optimal dalam mendeteksi tingkat kematangan buah mangga.

Hasil penelitian ini sejalan dengan [12] yang menekankan pentingnya AI untuk meningkatkan efisiensi sektor pertanian, serta [10] yang menunjukkan efektivitas YOLO dalam mendeteksi objek dengan tingkat akurasi tinggi. Penggunaan YOLOv8 dalam kategorisasi kematangan buah meningkatkan efisiensi operasional dan memiliki prospek yang substansial untuk adopsi pertanian modern yang digerakkan oleh otomatisasi.

F. Hasil

Hasil pengujian menunjukkan bahwa model YOLOv8 mencapai keseimbangan yang efektif antara kecepatan dan akurasi, menunjukkan tingkat inferensi rata-rata sekitar 45-50 frame per detik (FPS) pada GPU kelas menengah. Nilai mAP50 sebesar 0,92139 dan mAP50-95 sebesar 0,83656 menunjukkan bahwa model dapat secara akurat mengidentifikasi objek dalam berbagai kondisi pencahayaan dan orientasi buah. Pelatihan total memakan waktu sekitar 40 menit menggunakan VS Code. Optimizer yang digunakan adalah Adam dengan fitur early stopping otomatis yang aktif jika tidak ada penurunan loss signifikan dalam beberapa epoch.

V. KESIMPULAN DAN SARAN

Studi ini telah berhasil mengembangkan dan menjalankan sistem klasifikasi berbasis citra digital untuk kematangan mangga menggunakan algoritma YOLOv8. Kinerja sistem menunjukkan efektivitas yang tinggi, di buktikan dengan akurasi yang tinggi, di buktikan dengan akurasi 92,13%, mAP50 sebesar 0,92139 dan mAP50-95 sebesar 0,83656, dan Intersection over Union (IOU) 0,83656. Performa ini menegaskan bahwa pendekatan object detection YOLOv8 lebih unggul dan efisien dibandingkan metode klasifikasi konvensional, berkat arsitektur anchor-free yang fleksibel dan kuat dalam menangani variasi citra mangga. Dengan kecepatan deteksi real-time mencapai 45-50 citra per detik, model ini sangat potensial untuk diintegrasikan ke dalam sistem penyortiran otomatis, sehingga meningkatkan kualitas dan efisiensi proses pascapanen di sektor pertanian. Temuan studi ini menunjukkan bahwa penggunaan pembelajaran mendalam melalui metodologi deteksi objek seperti YOLOv8 dapat secara efektif meningkatkan kualitas dan efisiensi aktivitas pasca panen. Berdasarkan kesimpulan tersebut, beberapa saran yang dapat diajukan adalah sebagai berikut:

1. Perluasan Dataset

Disarankan untuk memperluas dataset dengan menambahkan citra dari beragam varietas mangga, kondisi cahaya ekstrem, dan latar belakang yang bervariasi. Hal ini bertujuan agar model memiliki daya tahan (robustness) yang lebih tinggi terhadap kondisi operasional nyata.

2. Integrasi Multi Sensor

Pengembangan sistem dapat dilanjutkan dengan mengintegrasikan data citra visual dengan input sensor non-visual (misalnya, sensor aroma atau suhu) guna meningkatkan akurasi dalam penentuan kematangan.

3. Implementasi pada Edge Computing

Dianjurkan untuk menguji kinerja dan optimasi model pada perangkat edge computing (seperti Jetson Nano atau Raspberry Pi), memungkinkan sistem dapat bekerja secara mandiri tanpa memerlukan server sentral.

4. Pengembangan Antarmuka

Disarankan untuk mengembangkan antarmuka pengguna (berbasis web atau aplikasi mobile) yang intuitif, sehingga sistem dapat dimanfaatkan secara langsung oleh pihak-pihak terkait dalam sektor hortikultura.

5. Aplikasi Lintas Komoditas

Arsitektur yang dikembangkan dalam penelitian ini dapat diadaptasi dan diuji penerapannya pada klasifikasi kematangan komoditas buah-buahan lain (seperti pepaya, pisang, atau tomat).

Dengan saran-saran tersebut, penelitian ini diharapkan menjadi pijakan untuk pengembangan sistem smart agriculture berbasis kecerdasan buatan yang berkelanjutan dan dapat diterapkan secara luas di sektor hortikultura Indonesia.

DAFTAR RUJUKAN

- [1] [Kementan] Kementerian Pertanian, *Statistik Pertanian Tahun 2021*. 2022.
- [2] S. B. Indrajati, L. D. Saputra, and D. Rosita, “Lapang Budidaya Mangga,” *Direktorat Buah dan Florikultura, Direktorat Jenderal Hortik.*, pp. 1–60, 2021, [Online]. Available: <http://repository.pertanian.go.id/handle/123456789/12473>
- [3] J. Sondakh, J. H. W. Rembang, and N. Syahyuti, “Karakteristik, Potensi Generasi Milenial Dan Perspektif Pengembangan Pertanian Presisi Di Indonesia,” *Forum Penelit. Agro Ekon.*, vol. 38, no. 2, p. 155, 2021, doi: 10.21082/fae.v38n2.2020.155-166.
- [4] E. Indonesia, C. On, and C. Technology, “[EIconCIT 2021 Front cover],” pp. c1–c1, 2021, doi: 10.1109/eiconcit50028.2021.9431929.
- [5] S. Solikin, “Deteksi Penyakit Pada Tanaman Mangga Dengan Citra Digital : Tinjauan Literatur Sistematis (SLR),” *Bina Insa. Ict J.*, vol. 7, no. 1, p. 63, 2020, doi: 10.51211/biict.v7i1.1336.
- [6] T. Ayu, V. Dwi, and A. E. Minarno, “Pendiagnosa Daun Mangga Dengan Model Convolutional Neural Network,” *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 6, no. 2, p. 230, 2021, doi: 10.24114/cess.v6i2.22857.
- [7] A. Muslih, M. F. Ahadi, and M. I. Rasyid, “Kematangan Pada Buah Mangga HSI,” vol. 5, no. 2, pp. 117–121, 2021, doi: 10.30871/jaic.v5i2.3241.
- [8] C. Rozikin, A. Susilo Yuda Irawan, and U. Singaperbangsa Karawang, “Klasifikasi Jenis Buah Mangga,” *J. Ilm. Elektrotek.*, vol. 20, no. 1, pp. 1–12, 2020, doi: 10.30591/jpit.v5i1.1718.
- [9] L. Fadhillah and W. Hadikurniawati, “Deteksi Jenis Buah Mangga Menggunakan Metode CNN (Convolutional Neural Network) Berbasis Android Secara Real-Time,” *INTECOMS J. Inf. Technol. Comput. Sci.*, vol. 7, no. 4, pp. 1366–1372, 2024, doi: 10.31539/intecom.v7i4.10029.
- [10] L. Rahma, H. Syaputra, A. H. Mirza, and S. D. Purnamasari, “Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Only Look Once),” *J. Nas. Ilmu Komput.*, vol. 2, no. 3, pp. 213–232, 2021, doi: 10.47747/jurnalnik.v2i3.534.
- [11] K. Khairunnas, E. M. Yuniarno, and A. Zaini, “Pembuatan Modul Deteksi Objek Manusia Menggunakan Metode YOLO untuk Mobile Robot,” *J. Tek. ITS*, vol. 10, no. 1, 2021, doi: 10.12962/j23373539.v10i1.61622.
- [12] R. R. Rachmawati, “MAJU , MANDIRI , DAN MODERN Smart Farming 4 . 0 to Build Advanced , Independent , and Modern Indonesian Agriculture,” *Forum Penelit. Agro Ekon.*, vol. 38, no. 2, pp. 137–154, 2020.
- [13] D. Vernanda, N. N. Purnawan, and T. H. Apandi, “Analisis Data Untuk Klasifikasi Tingkat,” vol. 4, no. September, pp. 8–17, 2022, doi: 10.31962/jiitr.vvii.67.
- [14] R. A. Suharman and H. Hartono, “Klasifikasi Kematangan Manggis Berdasarkan Fitur Warna dan Tekstur Menggunakan Algoritma Naive Bayes,” *PYTHAGORAS J. Pendidik. Mat.*, vol. 17, no. 2, pp. 377–388, 2022, doi: 10.21831/pythagoras.v17i2.53625.
- [15] Y. Betriana Roza, D. Agus Salim, and A. R. Ramadhanu, “Optimasi Kualitas dan Kematangan Mangga Melalui Pemrosesan Citra Menggunakan Median Filter,” *J. Educ. Res.*, vol. 5, no. 4, pp. 5589–5598, 2024, doi: 10.37985/jer.v5i4.1863.