

Klasifikasi Kematangan Buah Pisang Menggunakan YOLOv12 Berbasis *Deep Learning*

¹⁾ Stefanus Eko Prasetyo, ²⁾ Gautama Wijaya, ³⁾ Allan Kwan

^{1,2,3)} Prodi Teknologi Informasi, Fakultas Ilmu Komputer, Universitas Internasional Batam, Batam, Indonesia

¹⁾Stefanus@uib.ac.id, ²⁾ Gautama@uib.ac.id, ³⁾2232031.allan@uib.edu

INFO ARTIKEL

Riwayat Artikel :

Diterima : 14 Januari 2026

Disetujui : 9 Februari 2026

Kata Kunci :

Pisang, Kematangan buah, *Deep learning*, YOLOv12, Pengolahan citra.

ABSTRAK

Sebagai komoditas hortikultura dengan permintaan pasar yang tinggi dan nilai jual strategis, pisang memerlukan penanganan pascapanen yang tepat, khususnya dalam penentuan fase kematangan. Selama ini, proses penyortiran kematangan buah umumnya dilakukan secara konvensional melalui inspeksi visual manual, yang bersifat subjektif dan berpotensi menghasilkan penilaian yang tidak konsisten. Oleh karena itu, penelitian ini berfokus pada perancangan sistem otomatis berbasis *deep learning* untuk menghasilkan klasifikasi kematangan yang lebih objektif dan terstandar. Algoritma YOLOv12 digunakan sebagai metode utama untuk mendeteksi serta mengklasifikasikan citra buah ke dalam tiga fase, yaitu mentah, matang, dan terlalu matang. Data latih dikembangkan melalui proses anotasi serta augmentasi citra untuk meningkatkan variasi visual dan mencegah *overfitting*. Hasil evaluasi menunjukkan bahwa model mencapai Mean Average Precision (mAP@0.5) sebesar 95,2% dengan waktu deteksi di bawah 50 ms per gambar. Temuan ini menunjukkan potensi penerapan sistem secara real-time pada lingkungan industri penyortiran buah.

ARTICLE INFO

Article History :

Received : Jan 14, 2026

Accepted : Feb 9, 2026

Keywords:

Banana, Ripeness classification, *Deep learning*, YOLOv12, Image processing.

ABSTRACT

As a horticultural commodity with high market demand and strategic economic value, bananas require proper postharvest handling, particularly in determining ripeness stages. Currently, the sorting process of fruit ripeness is commonly performed through conventional manual visual inspection, which is inherently subjective and may lead to inconsistent assessments. Therefore, this study focuses on the development of an automated system based on deep learning to achieve a more objective and standardized ripeness classification. The YOLOv12 algorithm is employed as the primary method to detect and classify fruit images into three distinct stages: unripe, ripe, and overripe. The training dataset is constructed through careful annotation and image augmentation to enhance visual diversity and prevent overfitting. Experimental results demonstrate that the proposed model achieves a Mean Average Precision (mAP@0.5) of 95.2%, with detection latency below 50 ms per image. These findings indicate strong potential for real-time implementation in industrial-scale fruit sorting environments.

1. PENDAHULUAN

Pisang merupakan salah satu komoditas hortikultura tropis dengan nilai ekonomi tinggi dan tingkat konsumsi yang stabil pada skala domestik maupun global. Kualitas buah pisang sangat dipengaruhi oleh tingkat kematangannya, yang menentukan karakteristik sensorik seperti rasa, tekstur, serta daya simpan selama distribusi. Kesalahan dalam menentukan fase kematangan tidak hanya berdampak pada penurunan mutu produk, tetapi juga meningkatkan potensi kehilangan pascapanen dan kerugian ekonomi dalam rantai pasok pertanian (Rizzo *et al.*, 2023).

Dalam praktiknya, penilaian tingkat kematangan buah pisang masih banyak dilakukan melalui inspeksi visual manual. Metode ini bergantung pada persepsi subjektif manusia terhadap perubahan warna dan kondisi fisik kulit buah, sehingga rentan terhadap inkonsistensi akibat faktor kelelahan operator serta variasi pencahayaan lingkungan pengamatan (Saranya, Srinivasan and Kumar, 2022). Keterbatasan tersebut mendorong perlunya sistem otomatis yang mampu memberikan penilaian kematangan secara objektif, konsisten, dan terstandar.

Perkembangan kecerdasan buatan, khususnya machine learning, membuka peluang untuk mengatasi permasalahan tersebut. Machine learning memungkinkan sistem komputer mempelajari pola dari data tanpa aturan eksplisit, termasuk pada data visual yang kompleks. Evolusi lebih lanjut dari pendekatan ini melahirkan deep learning, yang memanfaatkan jaringan saraf tiruan berlapis untuk mengekstraksi fitur visual secara otomatis. Dalam ranah visi komputer, deep learning menjadi fondasi utama bagi pengembangan sistem klasifikasi dan deteksi objek modern (Wijaya *et al.*, 2023).

Selain pendekatan spesifik model seperti YOLO, tinjauan komprehensif oleh Xiao, Wang, Xu, dan Zhang menunjukkan bahwa metode deep learning secara umum telah banyak digunakan dalam *fruit detection* dan *fruit recognition* untuk aplikasi pertanian otomatis, mencakup berbagai arsitektur seperti YOLO, SSD, Faster-R-CNN, dan lainnya, yang mampu mengekstraksi fitur visual dari citra buah secara efisien dan menjadi landasan penting dalam

pengembangan sistem klasifikasi kematangan buah berbasis visi komputer (Xiao *et al.*, 2023).

Pendekatan berbasis deep learning menunjukkan keunggulan dibandingkan metode konvensional karena kemampuannya beradaptasi terhadap variasi warna, tekstur, dan kondisi pencahayaan citra. Dalam konteks pertanian, teknologi ini telah banyak diterapkan untuk tugas klasifikasi dan deteksi objek, termasuk identifikasi tingkat kematangan buah, dengan hasil yang relatif lebih stabil dan akurat (Yang *et al.*, 2024). Seiring meningkatnya kebutuhan akan sistem otomatis yang efisien, pemanfaatan deep learning dalam pengolahan citra terus berkembang dan menjadi solusi yang relevan untuk mendukung pengambilan keputusan berbasis data (Yulianto, 2024).

Salah satu arsitektur deep learning yang populer dalam deteksi objek real-time adalah You Only Look Once (YOLO). YOLO merupakan metode deteksi satu tahap yang mampu melakukan lokalisasi dan klasifikasi objek secara simultan, sehingga menawarkan keunggulan signifikan dalam kecepatan inferensi dibandingkan pendekatan dua tahap seperti R-CNN (Widyawati and Febriani, 2021). Karakteristik tersebut menjadikan YOLO banyak digunakan pada aplikasi yang menuntut pemrosesan cepat dan efisien.

Seiring perkembangannya, arsitektur YOLO terus mengalami penyempurnaan untuk meningkatkan akurasi dan efisiensi komputasi. YOLOv12 sebagai generasi terbaru mengadopsi pendekatan attention-centric yang dirancang untuk meningkatkan kemampuan model dalam membedakan objek dengan perbedaan visual yang halus, tanpa mengorbankan kecepatan pemrosesan (Tian, Ye and Doermann, 2025).

Selain itu, pendekatan multi-level feature fusion yang diterapkan pada YOLOv12 mampu meningkatkan kemampuan model dalam mengekstraksi fitur visual halus dari permukaan buah, sehingga meningkatkan akurasi klasifikasi kematangan di berbagai kondisi pencahayaan dan sudut pengambilan gambar (Colaco and Kamat, 2025).

Pendekatan hibrid yang menggabungkan Hybrid Attention Transformer dengan arsitektur YOLOv8 menunjukkan kemampuan lebih baik dalam menangkap ketergantungan visual yang kompleks dan detail objek dalam citra buah,

yang meningkatkan akurasi deteksi tingkat kematangan dibandingkan metode konvensional, memperlihatkan potensi pengembangan arsitektur attention-centric dalam konteks pertanian dan visi komputer (Tang, Yu and Shao, 2025).

Studi lain oleh Oktapian dan Giri mengimplementasikan algoritma YOLOv8 untuk mengidentifikasi tingkat kematangan buah apel berdasarkan citra visual. Hasil penelitian menunjukkan bahwa model YOLOv8 mampu memberikan performa klasifikasi yang baik dengan nilai mAP yang tinggi, sekaligus mempertahankan kecepatan deteksi. Temuan ini memperkuat bahwa algoritma YOLO generasi terbaru memiliki fleksibilitas tinggi dan dapat diterapkan pada berbagai jenis buah dalam konteks pertanian berbasis visi komputer (I Gede Liyang Anugrah Oktapian and Gst. Ayu Vida Mastrika Giri, 2025).

Selain itu, Bingjie Xiao menerapkan YOLOv8 untuk identifikasi tingkat kematangan buah dan melaporkan bahwa model YOLO mampu mengekstraksi fitur visual utama seperti warna dan tekstur permukaan secara efisien. Temuan ini memperkuat bahwa pendekatan YOLO cocok digunakan untuk tugas klasifikasi kematangan buah berbasis citra (Xiao, Nguyen and Yan, 2024).

Beberapa penelitian menunjukkan bahwa pengembangan YOLO generasi terbaru memiliki potensi yang baik untuk diterapkan pada lingkungan pertanian dengan karakteristik visual yang kompleks (Sapkota, Meng, *et al.*, 2025).

Selain YOLOv12, evaluasi terhadap berbagai generasi YOLO juga menunjukkan adanya peningkatan signifikan dari sisi stabilitas pelatihan dan efisiensi komputasi pada arsitektur yang lebih baru. Perbandingan antara YOLOv5 dan YOLOv8 menunjukkan bahwa pengembangan arsitektur YOLO berkontribusi pada peningkatan akurasi deteksi tanpa peningkatan beban komputasi yang signifikan, sehingga relevan untuk aplikasi real-time berbasis visi komputer (Ma Muriyah, Yulianto and Sim, 2024).

Penelitian terkait klasifikasi tingkat kematangan buah pisang telah dilakukan menggunakan berbagai pendekatan deep learning, seperti Convolutional Neural Network,

Vision Transformer, serta kombinasi CNN-LSTM. Meskipun pendekatan tersebut menunjukkan performa yang menjanjikan, sebagian penelitian masih menghadapi keterbatasan dalam hal generalisasi model terhadap variasi kondisi citra, khususnya perbedaan pencahayaan dan kemiripan visual antar kelas kematangan (Pangestu, Purnama and Risnandar, 2024). Hal ini menunjukkan adanya peluang untuk mengeksplorasi pendekatan lain yang lebih adaptif dan terintegrasi.

Selain peningkatan akurasi klasifikasi, penerapan sistem otomatis berbasis pengenalan visual juga berpotensi mendukung efisiensi dan transparansi dalam rantai pasok pertanian, sejalan dengan transformasi digital pada sektor distribusi dan logistik modern (Thomaidis *et al.*, 2023). Oleh karena itu, pemilihan arsitektur deteksi objek yang mampu menyeimbangkan kecepatan dan ketepatan menjadi aspek penting dalam pengembangan sistem klasifikasi kematangan buah berbasis citra.

Berdasarkan latar belakang tersebut, penelitian ini berfokus pada penerapan algoritma YOLOv12 untuk mengklasifikasikan tingkat kematangan buah pisang berdasarkan citra visual. Penelitian ini bertujuan untuk mengevaluasi potensi YOLOv12 dalam menangani permasalahan klasifikasi kematangan buah dengan karakteristik visual yang saling mirip, serta memberikan kontribusi terhadap pengembangan sistem otomatis yang akurat, efisien, dan aplikatif dalam bidang pertanian dan distribusi hasil panen.

2. METODE


Penelitian ini dilaksanakan melalui beberapa tahapan utama yang meliputi pengumpulan dataset, proses anotasi data, augmentasi citra, pelatihan model deteksi objek berbasis deep learning, evaluasi kinerja model, serta analisis hasil. Alur penelitian dirancang untuk mengklasifikasikan tingkat kematangan buah pisang menggunakan pendekatan one-stage object detector, sehingga sistem mampu melakukan proses lokalisasi objek dan klasifikasi tingkat kematangan secara simultan.

Dataset yang digunakan dalam penelitian ini diperoleh dari repositori publik Kaggle, yang menyediakan citra buah pisang dengan variasi sudut pengambilan gambar dan intensitas pencahayaan yang beragam. Pemanfaatan

dataset publik bertujuan untuk meningkatkan aksesibilitas data serta memungkinkan replikasi dan validasi silang dengan penelitian sejenis di masa mendatang. Total dataset terdiri dari 150 citra buah pisang yang terbagi ke dalam tiga kelas tingkat kematangan, yaitu mentah dengan dominasi warna hijau, matang dengan warna kuning merata, dan terlalu matang yang ditandai dengan munculnya bercak coklat atau hitam pada permukaan kulit buah.

Seluruh citra dalam dataset telah melalui proses anotasi menggunakan bounding box untuk menandai lokasi objek pisang pada setiap gambar, sehingga sesuai dengan kebutuhan metode deteksi objek berbasis YOLO. Dataset yang telah dianotasi kemudian dibagi menjadi data pelatihan dan data validasi dengan rasio 80:20, di mana sebanyak 120 citra digunakan sebagai data latih dan 30 citra digunakan sebagai data validasi. Pembagian ini dilakukan untuk memastikan proses pembelajaran model berlangsung secara optimal sekaligus memungkinkan evaluasi objektif terhadap kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya.

Mengingat keterbatasan jumlah data orisinal, teknik augmentasi citra diterapkan untuk memperkaya variasi data latih dan mengurangi risiko overfitting. Augmentasi yang digunakan meliputi rotasi objek sebesar $\pm 15^\circ$, penyesuaian tingkat kecerahan (brightness), serta pembalikan citra secara horizontal (horizontal flip). Teknik ini dirancang untuk mensimulasikan berbagai kondisi pengambilan citra di lingkungan nyata, sehingga jumlah data latih meningkat menjadi sekitar 600 citra. Contoh penerapan augmentasi data ditunjukkan pada Gambar 1.



Gambar 1. Penerapan augmentasi data.

Model deteksi objek yang digunakan dalam penelitian ini adalah YOLOv12, yang merupakan pengembangan terbaru dari keluarga algoritma YOLO. Model ini dipilih karena keunggulannya dalam kecepatan deteksi dan efisiensi komputasi, sehingga sesuai untuk aplikasi deteksi objek secara real-time. Proses pelatihan model dilakukan dengan jumlah epoch sebanyak 50, ukuran citra input 640×640 piksel, batch size sebesar 16, serta menggunakan optimizer AdamW. Model dilatih dengan memanfaatkan bobot awal (pretrained weights) untuk mempercepat proses konvergensi dan meningkatkan performa deteksi. Pemilihan YOLOv12 juga didukung oleh penelitian Ranjan Sapkota dan Marco Flores-Calero yang menunjukkan bahwa generasi terbaru YOLO memiliki keseimbangan yang baik antara akurasi dan efisiensi komputasi pada lingkungan pertanian yang kompleks (Sapkota, Flores-Calero, *et al.*, 2025).


Pelatihan model dilakukan menggunakan framework Ultralytics YOLO berbasis PyTorch versi 2.9.0 dengan dukungan GPU NVIDIA Tesla T4 pada lingkungan Google Colaboratory. Selama proses pelatihan, model mempelajari fitur visual utama seperti warna kulit pisang, tekstur permukaan, serta perbedaan tingkat kecerahan yang merepresentasikan tingkat kematangan buah. Evaluasi kinerja model dilakukan menggunakan metrik Precision, Recall, mean Average Precision (mAP@0.5), dan mAP@0.5:0.95 untuk menilai ketepatan deteksi serta kestabilan performa model dalam

mengklasifikasikan tingkat kematangan buah pisang.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

Proses pelatihan model YOLOv12 dilakukan selama 50 epoch menggunakan dataset citra buah pisang yang telah melalui tahap anotasi dan augmentasi. Selama proses pelatihan, beberapa parameter utama diamati untuk mengevaluasi perkembangan performa model, khususnya nilai loss, precision, dan recall. Hasil pelatihan divisualisasikan dalam bentuk grafik yang menunjukkan perubahan nilai metrik terhadap jumlah epoch, sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Grafik hasil pelatihan.

Berdasarkan grafik hasil pelatihan, nilai loss mengalami penurunan yang konsisten sejak epoch awal hingga akhir pelatihan. Penurunan loss ini mengindikasikan bahwa model secara bertahap mampu mempelajari pola visual yang terdapat pada dataset, khususnya perbedaan warna dan tekstur kulit pisang pada masing-masing tingkat kematangan. Tidak terlihat lonjakan loss yang signifikan pada fase akhir pelatihan, sehingga dapat disimpulkan bahwa proses pembelajaran berlangsung secara stabil dan tidak menunjukkan indikasi overfitting yang berlebihan.


Selain itu, grafik precision dan recall menunjukkan tren peningkatan seiring bertambahnya jumlah epoch. Peningkatan nilai precision mengindikasikan bahwa model semakin tepat dalam memberikan prediksi kelas kematangan tanpa menghasilkan banyak kesalahan klasifikasi, sedangkan peningkatan nilai recall menunjukkan bahwa model semakin mampu mendeteksi seluruh objek pisang yang terdapat dalam citra. Kombinasi peningkatan kedua metrik tersebut menandakan bahwa model

tidak hanya mampu mengenali objek pisang, tetapi juga semakin akurat dalam membedakan tingkat kematangannya.

Secara keseluruhan, hasil pelatihan menunjukkan bahwa konfigurasi parameter yang digunakan telah cukup optimal untuk dataset penelitian ini dan mampu menghasilkan model dengan performa yang stabil.

3.2 Evaluasi Kinerja Model

Setelah proses pelatihan selesai, model YOLOv12 dievaluasi menggunakan data validasi yang tidak dilibatkan selama proses pelatihan. Evaluasi dilakukan menggunakan metrik Precision, Recall, mean Average Precision pada ambang IoU 0.5 ($mAP@0.5$), serta $mAP@0.5:0.95$. Selain itu, evaluasi visual dilakukan menggunakan confusion matrix untuk mengidentifikasi pola kesalahan klasifikasi antar kelas tingkat kematangan. Hasil confusion matrix ditunjukkan pada Gambar 3.



Gambar 3. Hasil confusion matrix.

Berdasarkan confusion matrix, sebagian besar objek pisang berhasil diklasifikasikan ke dalam kelas yang sesuai dengan kondisi sebenarnya. Kelas Mentah menunjukkan tingkat klasifikasi yang cukup baik, dengan jumlah prediksi benar yang dominan dibandingkan kesalahan klasifikasi. Hal ini disebabkan oleh karakteristik visual pisang mentah yang relatif lebih mudah dikenali, yaitu dominasi warna hijau pada kulit buah.


Namun demikian, masih terdapat misklasifikasi antara kelas Matang dan Terlalu Matang. Fenomena ini terutama disebabkan oleh kemiripan visual antara kedua kelas tersebut, di mana pisang matang dan terlalu matang sama-

sama memiliki warna dasar kuning. Perbedaan utama terletak pada keberadaan bercak coklat pada pisang terlalu matang, yang dalam beberapa kondisi pencahayaan tidak selalu terlihat kontras. Kondisi serupa juga dilaporkan pada penelitian klasifikasi kematangan buah lain, di mana perbedaan visual yang halus menyebabkan kesulitan dalam pemisahan kelas secara konsisten (Puteri and Setiawan, 2025).

Meskipun demikian, jumlah kesalahan klasifikasi yang terjadi masih berada dalam batas yang dapat diterima dan tidak mendominasi keseluruhan hasil prediksi. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik terhadap data yang belum pernah dilihat sebelumnya

3.3 Contoh Hasil Deteksi dan Klasifikasi

Untuk memberikan gambaran yang lebih jelas mengenai kinerja model, dilakukan visualisasi hasil deteksi dan klasifikasi menggunakan data validasi. Hasil deteksi ditampilkan dalam bentuk citra yang disertai bounding box, label kelas tingkat kematangan, serta nilai confidence score, sebagaimana ditunjukkan pada Gambar 4.



Gambar. 4. Hasil validasi citra.

Berdasarkan hasil visualisasi, model mampu mendeteksi objek pisang secara tepat meskipun terdapat variasi latar belakang dan kondisi pencahayaan. Setiap objek pisang yang terdeteksi diberi bounding box yang sesuai dengan area objek serta label kelas yang menunjukkan tingkat kematangan, yaitu Mentah, Matang, atau Terlalu Matang.


Pendekatan visualisasi hasil deteksi menggunakan bounding box dan confidence score merupakan metode yang umum digunakan dalam evaluasi model deteksi objek berbasis YOLO untuk menilai akurasi lokalisasi dan klasifikasi secara bersamaan (Widyawati and Febriani, 2021).

3.4 Analisis Kesalahan Klasifikasi



Gambar 5. Gambar kesalahan klasifikasi.

Untuk memahami keterbatasan model secara lebih mendalam, dilakukan analisis terhadap contoh hasil deteksi yang mengalami kesalahan klasifikasi. Contoh kesalahan klasifikasi antara kelas Matang dan Terlalu Matang ditunjukkan pada Gambar 5, sedangkan contoh klasifikasi yang benar ditampilkan pada Gambar 6.



Gambar 6 Gambar klasifikasi yang benar.

Berdasarkan analisis visual, kesalahan klasifikasi umumnya terjadi pada objek dengan karakteristik visual yang berada pada batas antar kelas (borderline cases), khususnya antara pisang matang dan terlalu matang. Pada kondisi ini, bercak coklat pada kulit pisang terlalu matang berukuran kecil atau tidak dominan,

sehingga sulit dibedakan dari tekstur normal pisang matang.

Temuan ini konsisten dengan penelitian deteksi kematangan buah lainnya yang melaporkan bahwa perbedaan visual yang bersifat lokal dan berukuran kecil sering menjadi sumber utama kesalahan klasifikasi pada model deteksi objek berbasis deep learning, khususnya pada kondisi pencahayaan yang tidak ideal (Ye *et al.*, 2024).

Fenomena kesalahan klasifikasi pada objek dengan perbedaan visual yang halus juga dilaporkan pada penelitian deteksi kematangan buah lainnya, terutama pada kondisi pencahayaan yang tidak merata dan sudut pengambilan gambar tertentu (Yang *et al.*, 2024).

3.5 Benchmarking

Metode	Dataset	Kelas	mAP
CNN-LSTM (Sintiya <i>et al.</i> , 2025)	300 citra	3	89.4%
YOLOv8 (Satria and Poerwandono, 2025)	200 citra	3	92.1%
YOLOv12 (Penelitian ini)	150 citra	3	95.2%

Tabel 1. Tabel perbandingan penelitian.

Untuk mengevaluasi performa model yang diusulkan, dilakukan perbandingan dengan beberapa penelitian terdahulu yang menggunakan pendekatan berbeda dalam klasifikasi tingkat kematangan buah. Perbandingan tersebut disajikan pada Tabel 1.

Berdasarkan hasil benchmarking, model YOLOv12 pada penelitian ini menunjukkan performa yang kompetitif dibandingkan pendekatan CNN-LSTM dan YOLO generasi sebelumnya, meskipun menggunakan jumlah dataset yang relatif lebih sedikit setelah proses augmentasi data. Hal ini menunjukkan bahwa arsitektur YOLOv12 mampu mengekstraksi fitur visual yang relevan secara efektif untuk tugas klasifikasi kematangan buah (Erz Saragih *et al.*, 2024; Satria and Poerwandono, 2025; Sintiya *et al.*, 2025).

Studi lain pada domain pertanian presisi juga menunjukkan bahwa pemanfaatan generasi

YOLO terbaru mampu meningkatkan ketepatan deteksi tingkat kematangan buah pada lingkungan budidaya terkontrol, seperti sistem vertical farming, meskipun menghadapi variasi sudut pandang dan pencahayaan yang kompleks (Mahadev Shendkar *et al.*, 2025).

Keunggulan YOLOv12 dalam penelitian ini diduga dipengaruhi oleh pendekatan attention-centric yang dimilikinya, yang memungkinkan model untuk lebih fokus pada fitur visual lokal yang bersifat halus, seperti bercak coklat kecil pada kulit pisang terlalu matang.

3.6 Pembahasan

Berdasarkan hasil pelatihan dan evaluasi yang telah dilakukan, dapat disimpulkan bahwa penerapan algoritma YOLOv12 dalam klasifikasi tingkat kematangan buah pisang memberikan hasil yang baik. Model mampu mengidentifikasi objek pisang sekaligus mengklasifikasikan tingkat kematangannya dalam satu tahap pemrosesan, sehingga lebih efisien dibandingkan pendekatan konvensional yang memerlukan proses terpisah antara deteksi dan klasifikasi.

Hasil penelitian ini sejalan dengan penelitian-penelitian sebelumnya yang menyatakan bahwa pendekatan deteksi objek berbasis YOLO efektif digunakan dalam klasifikasi kematangan buah dan aplikasi pertanian berbasis visi komputer (Kamat *et al.*, 2025; Satria and Poerwandono, 2025). Meskipun demikian, penelitian ini masih memiliki keterbatasan, terutama pada jumlah dataset yang relatif terbatas dan kemiripan visual antar kelas kematangan.

Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas jumlah dataset, memperkaya variasi kondisi pencahayaan, serta mempertimbangkan penggunaan metode tambahan seperti segmentasi objek atau analisis tekstur untuk meningkatkan ketepatan klasifikasi. Selain itu, penggunaan teknik validasi silang seperti K-Fold Cross Validation direkomendasikan untuk memperoleh hasil evaluasi yang lebih robust.

4. PENUTUP

4.1 Kesimpulan

Berdasarkan seluruh rangkaian tahapan penelitian yang telah dilaksanakan, dapat ditarik

sebuah simpulan komprehensif bahwa implementasi arsitektur YOLOv12 berbasis deep learning terbukti sangat efektif dalam menangani tugas deteksi sekaligus klasifikasi fase kematangan buah pisang secara simultan. Model cerdas yang dikembangkan dalam studi ini mampu mengidentifikasi karakteristik fisik kulit buah dan mengelompokkannya ke dalam tiga kategori utama, yaitu mentah, matang, dan terlalu matang dengan tingkat presisi yang sangat tinggi. Keberhasilan ini memberikan solusi teknologi yang mampu mereduksi ketergantungan pada inspeksi visual manual yang selama ini dianggap kurang efisien karena faktor subjektivitas manusia dan inkonsistensi penilaian di lapangan.

Secara kuantitatif, performa model ini sangat memuaskan dengan raihan nilai Mean Average Precision (mAP@0.5) mencapai 95,2%. Selain unggul dari sisi akurasi, sistem ini juga menunjukkan performa komputasi yang impresif dengan rata-rata waktu inferensi di bawah 50 milidetik untuk setiap citra. Capaian ini menegaskan bahwa algoritma YOLOv12 tidak hanya akurat secara teoritis, tetapi juga sangat aplikatif untuk digunakan dalam skenario industri nyata yang memerlukan pemrosesan data dalam waktu nyata (real-time), seperti pada integrasi mesin penyortiran otomatis di gudang distribusi.

Meskipun hasil yang diperoleh sangat positif, penelitian ini mencatat adanya tantangan pada identifikasi visual yang ambigu, terutama pada kondisi buah yang berada di ambang batas antara matang sempurna dan mulai membusuk akibat kemiripan tekstur warna. Oleh karena itu, pengembangan riset di masa mendatang sangat disarankan untuk memperluas volume dataset dengan variasi kondisi pencahayaan yang lebih ekstrem serta mengeksplorasi teknik augmentasi tingkat lanjut. Penambahan metode seperti segmentasi instan atau skema validasi silang juga direkomendasikan guna meningkatkan ketahanan sistem dan kemampuan generalisasi model terhadap berbagai varietas pisang lainnya.

4.2 Saran

Berdasarkan temuan penelitian, model YOLOv12 direkomendasikan untuk diterapkan pada sistem penyortiran dan pengendalian mutu buah pisang berbasis citra guna mendukung

proses pascapanen yang cepat dan konsisten. Dari sisi pengembangan metode, penelitian ini membuka peluang eksplorasi lebih lanjut terhadap arsitektur deteksi objek berbasis attention-centric untuk meningkatkan kemampuan model dalam membedakan kelas kematangan dengan kemiripan visual tinggi. Untuk penelitian selanjutnya, disarankan penggunaan dataset yang lebih besar dan beragam, serta integrasi dengan sistem kamera real-time atau edge computing guna meningkatkan generalisasi model dan kesiapan implementasi di lingkungan operasional nyata.

5. DAFTAR PUSTAKA

- Colaco, L. and Kamat, P. (2025) “Artificial intelligence advances for cashew fruit maturity and quality detection: a systematic review on models, sensors, and farming applications,” *Journal of Big Data*, 12(1). Available at: <https://doi.org/10.1186/s40537-025-01296-2>.
- Erz Saragih, R. et al. (2024) Mango and Banana Ripeness Detection based on Lightweight YOLOv8.
- I Gede Liyang Anugrah Oktapian and Gst. Ayu Vida Mastrika Giri (2025) “Identifikasi Kematangan Buah Apel Menggunakan Algoritma YOLO,” <https://ejournal2.unud.ac.id/index.php/jnati/article/view/19?> [Preprint]. Available at: <https://ejournal2.unud.ac.id/index.php/jnati/article/view/19?> (Accessed: January 10, 2026).
- Kamat, P. et al. (2025) “Multi-class fruit ripeness detection using YOLO and SSD object detection models,” *Discover Applied Sciences*, 7(9). Available at: <https://doi.org/10.1007/s42452-025-07617-7>.
- Ma Muriyah, N., Yulianto, A. and Sim, J.H. (2024) “Evaluating YOLOv5 and YOLOv8: Advancements in Human Detection,” *Journal of Information Systems and Informatics*, 6(4), pp. 2999–3015. Available at: <https://doi.org/10.51519/journalisi.v6i4.944>.

- Mahadev Shendkar, S. et al. (2025) Utilizing YOLOv10 and YOLO11 for Tomato Ripeness Detection in Vertical Farming.
- Pangestu, A., Purnama, B. and Risnandar, R. (2024) "Vision Transformer untuk Klasifikasi Kematangan Pisang," *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(1), pp. 75–84. Available at: <https://doi.org/10.25126/jtiik.20241117389>.
- Puteri, D.M. and Setiawan, H. (2025) "Algorithmic Model Approach," [https://jurnalnasional.ump.ac.id/index.php/JRRE/article/view/26293?](https://jurnalnasional.ump.ac.id/index.php/JRRE/article/view/26293) [Preprint]. Available at: <https://doi.org/10.30595/jrre.v7i2.26293>.
- Rizzo, M. et al. (2023) "Fruit ripeness classification: A survey," *Artificial Intelligence in Agriculture. KeAi Communications Co.*, pp. 44–57. Available at: <https://doi.org/10.1016/j.aiaa.2023.02.004>.
- Sapkota, R., Meng, Z., et al. (2025) "Comprehensive Performance Evaluation of YOLOv12, YOLO11, YOLOv10, YOLOv9 and YOLOv8 on Detecting and Counting Fruitlet in Complex Orchard Environments." Available at: <http://arxiv.org/abs/2407.12040>.
- Sapkota, R., Flores-Calero, M., et al. (2025) "YOLO advances to its genesis: a decadal and comprehensive review of the You Only Look Once (YOLO) series," *Artificial Intelligence Review*, 58(9). Available at: <https://doi.org/10.1007/s10462-025-11253-3>.
- Saranya, N., Srinivasan, K. and Kumar, S.K.P. (2022) "Banana ripeness stage identification: a deep learning approach," *Journal of Ambient Intelligence and Humanized Computing*, 13(8), pp. 4033–4039. Available at: <https://doi.org/10.1007/s12652-021-03267-w>.
- Satria, F. and Poerwandono, E. (2025) "IMPLEMENTASI YOLOV8 UNTUK DETEKSI DAN KLASIFIKASI TINGKAT KEMATANGAN BUAH MANGGA BERDASARKAN CITRA DIGITAL," 4(4), pp. 294–301. Available at: <https://doi.org/10.55123>.
- Sintiya, C. et al. (2025) "Pengembangan Aplikasi Deteksi Kematangan Buah Pisang Berbasis Web Menggunakan Model CNN-LSTM," *Jurnal Sifo Mikroskil*, 26(1), pp. 1–20. Available at: <https://doi.org/10.55601/jsm.v26i1.1500>.
- Tang, J., Yu, Z. and Shao, C.S. (2025) "Hybrid attention transformer integrated YOLOV8 for fruit ripeness detection," *Scientific Reports*, 15(1). Available at: <https://doi.org/10.1038/s41598-025-04184-0>.
- Thomaidis, I.T. et al. (2023) "Blockchain technology in the Greek Supply Chain sector: An empirical examination of adoption patterns," in *2023 IEEE International Conference on Technology Management, Operations and Decisions (ICTMOD)*. IEEE, pp. 1–8. Available at: <https://doi.org/10.1109/ICTMOD59086.2023.10438138>.
- Tian, Y., Ye, Q. and Doermann, D. (2025) "YOLOv12: Attention-Centric Real-Time Object Detectors." Available at: <http://arxiv.org/abs/2502.12524>.
- Widyawati, W. and Febriani, R. (2021) "Real-time detection of fruit ripeness using the YOLOv4 algorithm," *Teknika: Jurnal Sains dan Teknologi*, 17(2), p. 205. Available at: <https://doi.org/10.36055/tjst.v17i2.12254>.
- Wijaya, G. et al. (2023) "Studi Perbandingan Deteksi Intrusi Jaringan Menggunakan Machine Learning: (Metode SVM dan ANN) Comparative Study of Network Intrusion Detection Using Machine Learning: (SVM and ANN Method)," 13. Available at: <https://doi.org/10.34010/jati.v13i2>.
- Xiao, B., Nguyen, M. and Yan, W.Q. (2024) "Fruit ripeness identification using YOLOv8 model," *Multimedia Tools and Applications*, 83(9), pp. 28039–28056. Available at: <https://doi.org/10.1007/s11042-023-16570-9>.
- Xiao, F. et al. (2023) "Fruit Detection and Recognition Based on Deep Learning for Automatic Harvesting: An Overview and Review," *Agronomy*. MDPI. Available at: <https://doi.org/10.3390/agronomy13061625>.

- Yang, L. et al. (2024) “Automatic Detection of Banana Maturity—Application of Image Recognition in Agricultural Production,” *Processes*, 12(4). Available at: <https://doi.org/10.3390/pr12040799>.
- Ye, R. et al. (2024) “CR-YOLOv9: Improved YOLOv9 Multi-Stage Strawberry Fruit Maturity Detection Application Integrated with CRNET,” *Foods*, 13(16). Available at: <https://doi.org/10.3390/foods13162571>.
- Yulianto, A. (2024) “Pengembangan Sistem Pengenalan Plat Nomor Indonesia Menggunakan YOLOv8 dan EasyOCR,” *Jurnal Ilmiah Komputasi*, 23(4), pp. 571–578.