



IMPLEMENTASI YOLOV8 UNTUK KLASIFIKASI TINGKAT KEMATANGAN BUAH MANGGIS BERBASIS CITRA DIGITAL

IMPLEMENTATION OF YOLOV8 FOR DIGITAL IMAGE-BASED CLASSIFICATION OF MANGOSTEEN FRUIT RIPENESS STAGES

Mi'raj Fuadi^{1*}, Yuhendra AP¹, M. Azhar Mustafid¹, Ince Siti Wardatullatifah S¹,
Wiwin Apriyanditra¹

¹Program Studi Teknik Pertanian, Fakultas Teknologi Pangan dan Agroindustri, Universitas Mataram

*Co-author: mirajfuadi@unram.ac.id

Article History:

Received : 14-06-2026
Revised : 25-06-2026
Accepted : 27-06-2026
Online : 28-06-2026

Keywords:

Digital image;
Mangosteen;
Object detection;
Ripeness stages;
YOLOv8;

Kata Kunci:

Citra digital;
Deteksi objek;
Manggis;
Tingkat kematangan;
YOLOv8;



Abstract: Manual determination of mangosteen (*Garcinia mangostana*) ripeness still relies on human visual observation, which may lead to subjective and inconsistent assessments. This study aimed to develop a YOLOv8-based model for detecting mangosteen ripeness stages. The research adopted the Cross Industry Standard Process for Data Mining (CRISP-DM) framework, which includes business understanding, data understanding, data preparation, modeling, evaluation, and deployment stages. The dataset consisted of 600 mangosteen images classified into six ripeness stages, namely Stage 1 to Stage 6, with 100 images in each class. Image annotation was performed using bounding boxes, and the dataset was divided into training, validation, and testing subsets using a 70:20:10 ratio. Five YOLOv8 variants, namely YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, and YOLOv8xl, were trained and compared based on precision, recall, mAP50, and mAP50-95. The results showed that YOLOv8m achieved the best performance, with a precision of 0.772, recall of 0.941, mAP50 of 0.933, and mAP50-95 of 0.919. YOLOv8m was selected as the best model because it obtained the highest mAP and recall values, indicating its ability to detect mangosteen ripeness stages more effectively. These findings demonstrate that YOLOv8 has the potential to be used as a supporting system for automatic mangosteen sorting based on ripeness stage.

Abstrak: Penentuan tingkat kematangan buah manggis (*Garcinia mangostana*) secara manual masih bergantung pada pengamatan visual manusia sehingga berpotensi menghasilkan penilaian yang subjektif dan tidak konsisten. Penelitian ini bertujuan untuk mengembangkan model deteksi tingkat kematangan buah manggis berbasis YOLOv8. Penelitian menggunakan pendekatan *Cross Industry Standard Process for Data Mining* (CRISP-DM), yang meliputi tahapan *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Dataset yang digunakan terdiri atas 600 citra buah manggis yang terbagi ke dalam enam kelas kematangan, yaitu Stage 1 hingga Stage 6, dengan masing-masing kelas terdiri atas 100 citra. Proses anotasi dilakukan menggunakan *bounding box*, kemudian dataset dibagi menjadi data latih, validasi, dan uji dengan rasio 70:20:10. Lima varian YOLOv8, yaitu YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, dan YOLOv8xl, dilatih dan dibandingkan berdasarkan nilai *precision*, *recall*, *mAP50*, dan *mAP50-95*. Hasil penelitian menunjukkan bahwa YOLOv8m memberikan performa terbaik dengan *precision* 0,772, *recall* 0,941, *mAP50* 0,933, dan *mAP50-95* 0,919. Model YOLOv8m dipilih sebagai model terbaik karena memiliki nilai *mAP* dan *recall* tertinggi, sehingga mampu mendeteksi tingkat kematangan buah manggis secara lebih optimal. Hasil ini menunjukkan bahwa YOLOv8 berpotensi digunakan sebagai sistem pendukung sortasi otomatis buah manggis.



A. LATAR BELAKANG

Buah manggis (*Garcinia mangostana* L.) merupakan komoditas hortikultura tropis yang memiliki nilai ekonomi tinggi di pasar domestik maupun internasional. Kualitas buah manggis sangat ditentukan oleh tingkat kematangannya, yang secara visual ditandai oleh perubahan warna kulit dari hijau kekuningan hingga ungu tua. Perubahan ini tidak hanya memengaruhi penampilan, tetapi juga berkaitan erat dengan rasa, tekstur, dan kandungan nutrisi buah (Kader & Yahia, 2011).

Pada praktik konvensional, identifikasi kematangan buah manggis umumnya dilakukan secara visual oleh tenaga manusia. Metode ini cenderung bersifat subjektif dan bergantung pada pengalaman pengamat, sehingga berpotensi menimbulkan inkonsistensi hasil penilaian (Jayashri Patil, 2021). Selain itu, faktor eksternal seperti kondisi pencahayaan dan kelelahan operator dapat memengaruhi akurasi pengamatan. Keterbatasan ini menjadi tantangan tersendiri, terutama dalam skala industri yang membutuhkan proses sortasi cepat, konsisten, dan akurat.

Seiring dengan perkembangan teknologi, pendekatan berbasis *computer vision* dan *deep learning* telah banyak dimanfaatkan untuk meningkatkan akurasi dalam analisis citra pertanian. Salah satu metode yang banyak digunakan adalah algoritma deteksi objek berbasis *You Only Look Once* (YOLO), yang mampu melakukan deteksi secara *real-time* dengan tingkat akurasi yang tinggi (Kamilaris & Prenafeta-Boldú, 2018). Perkembangan algoritma YOLO hingga versi terbaru seperti YOLOv8 menunjukkan peningkatan performa dalam hal kecepatan dan efisiensi komputasi. Model ini dirancang untuk meningkatkan kemampuan deteksi pada objek kecil serta kondisi citra yang kompleks (Huang et al., 2024).

Beberapa penelitian sebelumnya telah menunjukkan bahwa penerapan metode *deep learning* dalam klasifikasi kematangan buah mampu memberikan hasil yang lebih objektif dan konsisten dibandingkan metode manual (Heaton, 2017). Model yang dilatih menggunakan dataset citra dengan variasi tingkat kematangan dapat mengenali pola visual secara otomatis, sehingga dapat digunakan sebagai sistem pendukung dalam proses grading buah. Namun demikian, masih terdapat peluang untuk meningkatkan performa model, khususnya dalam hal akurasi deteksi pada kondisi lingkungan yang bervariasi dan dataset yang terbatas. Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan sistem deteksi kematangan buah manggis menggunakan pendekatan YOLOv8. Sistem yang diusulkan diharapkan mampu mengklasifikasikan tingkat kematangan secara cepat dan akurat, serta dapat diimplementasikan dalam proses sortasi otomatis guna meningkatkan efisiensi dan konsistensi penilaian kualitas manggis.

B. METODE PENELITIAN

Penelitian ini menggunakan pendekatan *Cross Industry Standard Process for Data Mining* (CRISP-DM) sebagai kerangka kerja dalam pengembangan sistem deteksi kematangan buah manggis. CRISP-DM merupakan metodologi yang umum digunakan dalam proyek *data mining* dan *machine learning* karena menyediakan tahapan sistematis yang terstruktur, mulai dari pemahaman masalah hingga evaluasi model. Pendekatan ini dipilih karena mampu mendukung proses pengolahan data citra dan pengembangan model *deep learning* secara terintegrasi (Kirilenko, 2025).

Pada penelitian ini, tahapan CRISP-DM disesuaikan dengan aktivitas yang benar-benar dilakukan dalam pengembangan model deteksi tingkat kematangan buah manggis. Tahapan tersebut

meliputi *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Setiap tahapan dijelaskan sebagai berikut.

Tahap *Business Understanding* dilakukan dengan menetapkan tujuan utama penelitian, yaitu mengembangkan model deteksi tingkat kematangan buah manggis berdasarkan citra digital. Permasalahan yang dikaji dalam penelitian ini adalah bagaimana model dapat mengenali dan membedakan tingkat kematangan buah manggis berdasarkan karakteristik visual, terutama perubahan warna kulit buah pada setiap stage kematangan.


Tahap *Data Understanding* dilakukan dengan memahami karakteristik dataset citra buah manggis yang digunakan dalam penelitian. Dataset terdiri atas 600 citra buah manggis yang terbagi ke dalam enam kelas tingkat kematangan, yaitu *Stage 1*, *Stage 2*, *Stage 3*, *Stage 4*, *Stage 5*, dan *Stage 6*. Pada tahap ini juga dilakukan pengamatan terhadap karakteristik visual setiap kelas, seperti perbedaan warna kulit buah, variasi bentuk buah, ukuran objek, serta kondisi citra yang dapat memengaruhi proses deteksi.

Tahap *Data Preparation* dilakukan untuk menyiapkan dataset sebelum digunakan dalam proses pelatihan model. Aktivitas pada tahap ini meliputi seleksi citra, pengelompokan citra berdasarkan kelas kematangan, anotasi objek buah manggis menggunakan *bounding box*, pemberian label sesuai kelas kematangan, pemeriksaan hasil anotasi, serta pembagian dataset menjadi data latih, data validasi, dan data uji. Tahap ini penting untuk memastikan bahwa data yang digunakan dalam pelatihan model telah tersusun dengan baik dan sesuai dengan format deteksi objek.

Tahap *Modeling* dilakukan dengan melatih model deteksi objek menggunakan dataset citra manggis yang telah dianotasi. Model dilatih untuk mengenali objek buah manggis dan mengklasifikasikannya ke dalam enam tingkat kematangan. Pada tahap ini dilakukan pengaturan parameter pelatihan, seperti ukuran citra, jumlah *epoch*, *batch size*, serta konfigurasi model yang digunakan. Hasil dari tahap ini adalah model deteksi yang mampu mempelajari pola visual dari masing-masing kelas kematangan buah manggis.

Tahap *Evaluation* dilakukan untuk mengukur performa model dalam mendeteksi dan mengklasifikasikan tingkat kematangan buah manggis. Evaluasi dilakukan menggunakan data validasi dan data uji dengan metrik evaluasi deteksi objek, seperti *precision*, *recall*, *mAP@50* dan *mAP@50-95*. Hasil evaluasi digunakan untuk mengetahui tingkat keberhasilan model dalam mengenali setiap kelas kematangan serta mengidentifikasi kemungkinan kesalahan deteksi.

Tahap *Deployment* dilakukan dengan menggunakan model terbaik hasil pelatihan untuk melakukan prediksi pada citra baru. Tahap ini bertujuan untuk menunjukkan bahwa model yang dikembangkan dapat digunakan sebagai dasar sistem deteksi tingkat kematangan buah manggis secara otomatis. Model hasil penelitian ini diharapkan dapat mendukung proses sortasi dan klasifikasi mutu buah manggis berdasarkan tingkat kematangannya. Model CRISP-DM untuk pengolahan data ditunjukkan oleh **Gambar 1**.



Gambar 1. Model CRISP-DM Untuk Pengolahan Data
Sumber: Chapman et al. (2000)

C. HASIL DAN PEMBAHASAN

Proses pengembangan model dilakukan menggunakan bahasa pemrograman Python dan dijalankan pada platform Google Colab dengan memanfaatkan dukungan GPU untuk mempercepat proses komputasi. Selain itu, penelitian ini mengadopsi pendekatan *Cross Industry Standard Process for Data Mining* (CRISP-DM) sebagai kerangka kerja dalam pengolahan data dan pembangunan model, sehingga setiap tahapan dilakukan secara sistematis dan terarah.

1. Business Understanding

Pada tahap *business understanding*, penelitian ini berfokus pada permasalahan utama dalam penentuan tingkat kematangan buah manggis yang masih dilakukan secara manual dan bersifat subjektif. Pendekatan konvensional memiliki keterbatasan dalam hal konsistensi dan efisiensi, terutama ketika diterapkan pada skala industri. Oleh karena itu, penggunaan model berbasis *deep learning* seperti YOLOv8 menjadi solusi yang relevan karena mampu melakukan deteksi objek secara otomatis dan *real-time*. Hasil penelitian menunjukkan bahwa pendekatan ini dapat mengurangi ketergantungan terhadap pengamatan manusia serta meningkatkan objektivitas dalam proses penilaian kematangan buah (Redmon et al., 2016).

2. Data Understanding

Pada tahap *data understanding*, dilakukan analisis terhadap dataset citra buah manggis yang digunakan dalam penelitian. Dataset terdiri dari beberapa kelas tingkat kematangan dengan karakteristik visual yang berbeda, terutama pada aspek warna kulit buah. Tingkat kematangan manggis terdapat 6 tingkatan yang ditunjukkan oleh **Tabel 1**. Hasil analisis menunjukkan bahwa variasi pencahayaan, sudut pengambilan gambar, dan latar belakang memberikan pengaruh terhadap kualitas data. Selain itu, ditemukan bahwa distribusi data yang tidak seimbang antar kelas dapat memengaruhi performa model dalam proses pelatihan (Kamilaris & Prenafeta-Boldú, 2018). Oleh karena itu, pemahaman terhadap karakteristik dataset menjadi langkah penting dalam meningkatkan akurasi model.


Tabel 1. Tingkat kematangan buah manggis (Palapol et al., 2009)

Tingkat Kematangan	Penampakan
	Kuning kehijauan muda dengan bercak merah muda tersebar sebesar 5–50%
	Kuning kehijauan muda dengan bercak merah muda tersebar sebesar 51–100%
	Berwarna merah muda kemerahan
	Merah hingga merah keunguan
	Ungu tua
	Ungu kehitaman

3. Data Preparation

Penelitian ini menggunakan data primer. Objek penelitian diambil langsung tempat sortasi buah manggis di wilayah Lombok Barat, Nusa Tenggara Barat. Pengambilan citra buah manggis dilakukan menggunakan smartphone Xiaomi Redmi Note 12 Pro 5G. Proses pengambilan gambar dilakukan di dalam mini studio photo box berukuran 32 cm x 32 cm x 32 cm dengan latar belakang cerah/putih untuk meminimalkan gangguan visual pada citra. Pencahayaan dibantu menggunakan lampu LED T5 5 W agar objek memperoleh intensitas cahaya yang lebih merata. Jarak antara kamera dan objek diatur kurang lebih 30 cm. Pengaturan ini dilakukan untuk menghasilkan citra buah manggis yang lebih konsisten dari segi pencahayaan, jarak pengambilan gambar, dan latar belakang, sehingga memudahkan proses anotasi serta pelatihan model deteksi tingkat kematangan.

Pada tahap *Data Preparation*, digunakan 600 citra buah manggis yang terbagi ke dalam enam kelas tingkat kematangan, yaitu *Stage 1* hingga *Stage 6*. Setiap kelas terdiri atas 100 citra, sehingga dataset memiliki distribusi yang seimbang antar kelas. Pada tahap ini, dilakukan proses anotasi citra serta augmentasi data untuk meningkatkan kualitas dataset. Anotasi dilakukan dengan memberikan *bounding box* pada objek buah manggis sesuai dengan tingkat kematangannya. Sementara itu, augmentasi data seperti rotasi, *flipping*, dan perubahan intensitas cahaya digunakan untuk memperkaya variasi data latih. Hasil dari tahap ini menunjukkan bahwa augmentasi data mampu meningkatkan kemampuan model dalam mengenali objek pada berbagai kondisi lingkungan (Shorten & Khoshgoftaar, 2019). Selain itu, proses ini juga membantu mengurangi risiko *overfitting* yang sering terjadi pada dataset dengan jumlah terbatas (Kamilaris & Prenafeta-Boldú, 2018). Proses Anotasi dapat dilihat pada **Gambar 2**.



Gambar 2. Proses Anotasi

Gambar 2 menunjukkan bahwa citra buah manggis yang telah dianotasi kemudian dibagi ke dalam beberapa subset untuk mendukung proses pemodelan. Data tersebut telah dibagi menjadi 70% untuk data latih (420 gambar), 20% untuk validasi (120 gambar), dan 10% untuk pengujian (60 gambar) agar model dapat belajar dan mengukur akurasi dengan efektif. Pembagian dataset ini bertujuan untuk mendukung proses validasi model dan memperoleh estimasi kemampuan generalisasi yang lebih baik terhadap data yang belum pernah digunakan sebelumnya (Xu & Goodacre, 2018).

4. Modeling

Pada tahap ini pembangunan model dilakukan dengan menggunakan *tools* dari Google yaitu Google Collab. Google Colab merupakan platform berbasis cloud yang menyediakan lingkungan pemrograman Python secara interaktif. Platform ini memungkinkan pengguna untuk menjalankan kode tanpa memerlukan spesifikasi perangkat keras yang tinggi karena telah menyediakan akses ke GPU dan TPU. Google Colab juga terintegrasi dengan Google Drive sehingga memudahkan pengelolaan dataset dan hasil eksperimen (Tock, 2019). Penggunaan Python juga memungkinkan integrasi yang fleksibel antara model *deep learning* dengan sistem aplikasi lainnya (McKinney, 2022). Pembangunan model YOLOv8 ini menggunakan hyperparameter yang ditunjukkan pada **Tabel 2**.

Tabel 2. Parameter Pelatihan

Parameter	Nilai
Epoch Maksimum	100
Batch Size	16
Image Size	640x640
Patience	25

Hasil pengujian pada **Tabel 3** menunjukkan bahwa seluruh varian YOLOv8 mampu mendeteksi tingkat kematangan buah manggis dengan performa yang baik. Nilai mAP50 berada pada rentang 0,905–0,933, sedangkan mAP50-95 berada pada rentang 0,876–0,919. Secara umum, peningkatan ukuran model dari YOLOv8n ke YOLOv8m/YOLOv8l meningkatkan performa deteksi. Hal ini terlihat dari peningkatan nilai mAP50 dan mAP50-95, yang menunjukkan bahwa model semakin baik dalam mendeteksi objek dan menentukan posisi *bounding box*. Penggunaan mAP sebagai metrik utama sesuai untuk evaluasi deteksi objek karena metrik ini

mempertimbangkan ketepatan klasifikasi sekaligus kesesuaian lokasi *bounding box* berdasarkan nilai IoU (Padilla et al., 2021).

Tabel 3. Hasil rata-rata presisi (mAP) dari pelatihan model YOLOv8

Yolov8 variants	Stoppage Epoch	Precision	Recall	mAP 50	mAP 50-95
YOLOv8n	57	0,81	0,854	0,905	0,876
YOLOv8s	89	0,901	0,898	0,929	0,914
YOLOv8m	91	0,772	0,941	0,933	0,919
YOLOv8l	100	0,881	0,868	0,932	0,914
YOLOv8x	75	0,852	0,802	0,915	0,892


YOLOv8m memperoleh performa terbaik dengan nilai mAP50 sebesar 0,933 dan mAP50-95 sebesar 0,919. Selain itu, YOLOv8m juga memiliki nilai recall tertinggi, yaitu 0,941, yang menunjukkan bahwa model ini paling baik dalam mendeteksi objek manggis pada citra. Meskipun precision YOLOv8m sebesar 0,772 bukan yang tertinggi, keunggulannya pada mAP dan recall menunjukkan bahwa model ini memiliki kemampuan deteksi yang lebih baik secara keseluruhan. YOLOv8l juga menunjukkan performa yang mendekati YOLOv8m dengan nilai mAP50 sebesar 0,932 dan mAP50-95 sebesar 0,914, tetapi peningkatan ukuran model tidak menghasilkan peningkatan performa yang signifikan dibandingkan YOLOv8m.

Sementara itu, YOLOv8x sebagai varian terbesar justru mengalami penurunan performa dengan mAP50 sebesar 0,915 dan mAP50-95 sebesar 0,892. Hal ini menunjukkan bahwa model yang lebih besar tidak selalu memberikan hasil yang lebih baik, terutama apabila kompleksitas model tidak sebanding dengan karakteristik dan jumlah dataset. Dengan demikian, YOLOv8m dipilih sebagai model terbaik karena memberikan keseimbangan paling baik antara akurasi deteksi, kualitas lokalisasi *bounding box*, dan kemampuan menemukan objek. Temuan ini sejalan dengan prinsip pemilihan model deteksi objek yang mempertimbangkan *trade-off* antara akurasi, kompleksitas model, dan efisiensi komputasi (Huang et al., 2017; Redmon et al., 2016).


5. Evaluation

Tahap *evaluation* bertujuan untuk menilai kinerja model yang telah dibangun dengan menggunakan data uji. Dalam proses ini, metrik seperti mAP, precision, dan recall digunakan untuk mengukur efektivitas model dalam mendeteksi tingkat kematangan buah manggis.

Berdasarkan kurva training loss dan validation loss, model YOLOv8m (**Gambar 3**) dan YOLOv8l (**Gambar 4**) menunjukkan pola pembelajaran yang cukup stabil. Pada YOLOv8m, nilai train/box_loss, train/cls_loss, dan train/df_loss mengalami penurunan secara bertahap hingga akhir pelatihan. Pola yang sama juga terlihat pada YOLOv8l, meskipun penurunan training loss pada YOLOv8l tampak lebih panjang karena pelatihan berlangsung hingga 100 epoch. Penurunan ketiga komponen training loss tersebut menunjukkan bahwa model mampu mempelajari fitur objek, kelas kematangan, dan posisi bounding box secara semakin baik selama proses pelatihan.



Gambar 3. Training plot YOLOv8m




Gambar 4. Training plot YOLOv8l


Pada kurva validation loss, kedua model menunjukkan nilai loss yang tinggi dan berfluktuasi pada epoch awal. Kondisi ini umum terjadi pada tahap awal pelatihan karena model masih menyesuaikan bobot terhadap karakteristik dataset. Setelah beberapa epoch, nilai val/box_loss, val/cls_loss, dan val/dfl_loss menurun tajam dan kemudian cenderung stabil pada nilai yang rendah.

Jika dibandingkan antara kedua model, YOLOv8m menunjukkan kestabilan validasi yang baik dengan peningkatan metrik precision, recall, mAP50, dan mAP50-95 yang terus membaik hingga mendekati akhir pelatihan. Sementara itu, YOLOv8l juga menunjukkan performa validasi yang baik, tetapi peningkatan ukuran model tidak menghasilkan perbedaan performa yang signifikan dibandingkan YOLOv8m. Kurva mAP pada YOLOv8m terlihat meningkat secara konsisten dan mencapai nilai tinggi, sedangkan nilai loss validasi tetap rendah setelah fase awal pelatihan. Hal ini menunjukkan bahwa YOLOv8m memiliki kemampuan generalisasi yang baik, yaitu mampu mengenali pola kematangan buah manggis pada data yang tidak digunakan dalam pelatihan. Penggunaan mAP sebagai metrik utama juga sesuai dengan evaluasi model deteksi objek, karena mAP umum digunakan untuk mengukur kemampuan model dalam menghasilkan prediksi objek yang benar berdasarkan kombinasi precision, recall, dan kesesuaian posisi *bounding*

box terhadap objek sebenarnya (Henderson & Ferrari, 2017).



Gambar 5. *Confusion matrix* model YOLOv8m



Gambar 6. *Confusion matrix* model YOLOv8l

Confusion matrix pada model YOLOv8 menunjukkan perbedaan karakteristik performa antara varian YOLOv8m (**Gambar 5**) dan YOLOv8l (**Gambar 6**) dalam mengklasifikasikan setiap kelas. Pada YOLOv8m, nilai diagonal yang relatif tinggi pada Stage 5 (1,00) dan Stage 6 (0,95) mengindikasikan kemampuan klasifikasi yang sangat baik pada kedua kelas tersebut, sementara kelas lain seperti Stage 1 dan Stage 2 juga menunjukkan performa cukup stabil (sekitar 0,82). Namun, penurunan terlihat pada Stage 3 (0,71), yang mengindikasikan bahwa kelas ini lebih sulit dibedakan oleh model. Selain itu, kesalahan klasifikasi cenderung terjadi pada kelas yang berdekatan, seperti Stage 2 yang sering diprediksi sebagai Stage 3 serta Stage 3 ke Stage 4, yang menunjukkan adanya kemiripan fitur antar kelas. Nilai prediksi terhadap background yang cukup tinggi pada beberapa kelas (misalnya Stage 2 dan Stage 3) juga menunjukkan adanya kesalahan deteksi objek, bukan hanya kesalahan klasifikasi.

Sementara itu, pada YOLOv8l, meskipun terjadi peningkatan performa pada beberapa kelas seperti Stage 1 (0,95) dan tetap optimal pada Stage 5 (1,00), model ini menunjukkan ketidakstabilan pada kelas lainnya. Nilai akurasi Stage 2 menurun (0,73) dan Stage 6 juga lebih rendah dibandingkan YOLOv8m (0,85). Selain itu, kesalahan klasifikasi antar kelas berdekatan cenderung meningkat, terutama pada Stage 3 yang sering diklasifikasikan sebagai Stage 4 dengan proporsi lebih besar dibandingkan model sebelumnya. Prediksi terhadap background juga lebih tinggi, yang mengindikasikan bahwa model yang lebih kompleks cenderung lebih sensitif terhadap variasi data dan berpotensi mengalami *overfitting*. Secara keseluruhan, meskipun YOLOv8l memiliki kapasitas model yang lebih besar, hasil *confusion matrix* menunjukkan bahwa peningkatan kompleksitas tidak selalu diikuti oleh peningkatan performa yang merata.

Stage 3 menjadi kelas yang paling sulit diklasifikasikan karena berada pada fase transisi kematangan buah manggis. Secara biologis, pematangan manggis ditandai oleh perubahan warna kulit dari hijau menuju merah, ungu, hingga ungu kehitaman. Perubahan warna tersebut berkaitan dengan perkembangan pigmen antosianin pada perikarp buah manggis, yang menyebabkan perubahan warna selama proses pematangan dan pascapanen. Palapol et al. (2009) melaporkan bahwa warna kulit manggis berubah dari hijau menjadi ungu kehitaman selama pematangan, dan perubahan tersebut berkaitan dengan komposisi serta kandungan antosianin pada perikarp. Pada fase transisi seperti Stage 3, perubahan warna belum berlangsung seragam pada seluruh permukaan

buah, sehingga masih dapat ditemukan kombinasi warna hijau kekuningan, cokelat, merah muda, hingga merah keunguan dalam satu objek yang sama.

Secara visual, kondisi tersebut menyebabkan karakteristik Stage 3 tumpang tindih dengan Stage 2 dan Stage 4. Citra Stage 3 yang masih memiliki dominasi warna hijau kecokelatan dapat menyerupai Stage 2, sedangkan citra Stage 3 dengan warna merah yang lebih kuat dapat menyerupai Stage 4. Sumiasih et al. (2018) juga menunjukkan bahwa tingkat kematangan saat panen berpengaruh terhadap perubahan warna dan umur simpan manggis, sehingga perbedaan antar tahap kematangan dapat bersifat gradual. Selain itu, penelitian Whidhiasih et al. (2012) menunjukkan bahwa identifikasi tingkat kematangan manggis berbasis warna memiliki tantangan karena fitur warna digunakan sebagai parameter utama dalam membedakan kelas kematangan. Oleh karena itu, kesalahan klasifikasi pada Stage 3 dapat dijelaskan oleh adanya kemiripan visual antar tingkat kematangan yang berdekatan serta perubahan biologis warna kulit manggis yang berlangsung secara bertahap.

Analisis ini menegaskan bahwa *confusion matrix* merupakan bagian penting dalam evaluasi model karena dapat digunakan untuk memahami pola kesalahan klasifikasi secara lebih rinci, tidak hanya berdasarkan metrik evaluasi secara umum. Temuan ini juga sejalan dengan prinsip dalam pengembangan model deteksi objek yang menekankan adanya *trade-off* antara kompleksitas model dan kemampuan generalisasi (Reddy Dirisala & Padidem, 2023; Redmon et al., 2016), dimana model dengan kompleksitas menengah seperti YOLOv8m cenderung memberikan performa yang lebih stabil dibandingkan model yang lebih besar.




Gambar 7. Contoh proses training menggunakan dataset manggis



Gambar 8. Contoh proses validasi menggunakan dataset manggis

6. Deployment

Proses deployment dibangun secara sederhana menggunakan framework seperti PyTorch dengan dukungan GPU serta TensorFlow untuk menjalankan model YOLOv8. *Inference engine* yang digunakan adalah OpenCV untuk memproses citra secara real-time. Selain itu, Flask digunakan untuk membangun *application programming interface* (API) inferensi apabila model diakses melalui layanan jaringan. Model terbaik hasil eksperimen dipilih pada tahap *deployment*. Gambar 9 menunjukkan contoh implementasi model terbaik dalam mendeteksi tingkat kematangan buah manggis sehingga proses sortasi menjadi lebih mudah dan efisien.



Gambar 9. Contoh deteksi buah manggis menggunakan foto

D. SIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem klasifikasi kematangan buah manggis (*Garcinia mangostana*) berbasis citra digital menggunakan You Only Look Once (YOLO) versi YOLOv8 dengan pendekatan CRISP-DM. Hasil pengujian menunjukkan bahwa YOLOv8m merupakan model terbaik dengan nilai mAP50 sebesar 0,933, mAP50-95 sebesar 0,919, dan recall sebesar 0,941. Model ini memiliki kemampuan deteksi dan lokalisasi *bounding box* yang paling baik dibandingkan varian YOLOv8 lainnya. Secara keseluruhan, YOLOv8m berpotensi diterapkan dalam proses sortasi otomatis secara *real-time* untuk meningkatkan efisiensi dan konsistensi penilaian kualitas buah.

Penelitian selanjutnya disarankan untuk menambah jumlah dan variasi dataset, terutama pada kondisi pencahayaan, sudut pengambilan gambar, jarak kamera, dan latar belakang yang berbeda. Model YOLOv8m juga dapat dikembangkan lebih lanjut ke dalam sistem deteksi *real-time* yang terintegrasi dengan kamera dan sistem sortasi otomatis buah manggis.

UCAPAN TERIMA KASIH

Penelitian ini dapat terlaksana berkat dukungan pendanaan dari Universitas Mataram melalui skema Penelitian Dosen Pemula. Pendanaan ini berasal dari sumber dana DIPA BLU (PNBP) Universitas Mataram Tahun Anggaran 2025, dengan nomor kontrak 2374/UN18.L1/PP/2025.

DAFTAR RUJUKAN

- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*. SPSS Inc.
- Heaton, J. (2017). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning. *Genetic Programming and Evolvable Machines*, 19(1–2), 305–307. <https://doi.org/10.1007/s10710-017-9314-z>
- Henderson, P., & Ferrari, V. (2017). End-to-End Training of Object Class Detectors for Mean Average Precision. In *Lecture Notes in Computer Science* (pp. 198–213). Springer International Publishing. https://doi.org/10.1007/978-3-319-54193-8_13
- Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., Fischer, I., Wojna, Z., Song, Y., Guadarrama, S., & Murphy, K. (2017). Speed/Accuracy Trade-Offs for Modern Convolutional Object Detectors. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3296–3297. <https://doi.org/10.1109/CVPR.2017.351>
- Huang, L., Chen, M., & Peng, Z. (2024). YOLOv8-G: An Improved YOLOv8 Model for Major Disease Detection in Dragon Fruit Stems. *Sensors*, 24(15), 5034. <https://doi.org/10.3390/s24155034>
- Jayashri Patil, S. N. (2021). Pomegranate Fruit Diseases Detection Using Image Processing Techniques: A Review. *Information Technology In Industry*, 9(2), 115–120. <https://doi.org/10.17762/itii.v9i2.310>
- Kader, A. A., & Yahia, E. M. (2011). Postharvest biology of tropical and subtropical fruits. In *Postharvest Biology and Technology of Tropical and Subtropical Fruits* (pp. 79–111). Elsevier. <https://doi.org/10.1533/9780857093622.79>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in*

Agriculture, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>

Kirilenko, A. P. (2025). Introduction to Data Mining. CRISP-DM Process. In *Springer Texts in Social Sciences* (pp. 1–21). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-89689-7_1

McKinney, S. M. (2022). *Comparing human and AI performance in medical machine learning: An open-source Python library for the statistical analysis of reader study data*. openRxiv. <https://doi.org/10.1101/2022.05.06.22274773>

Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., & da Silva, E. A. B. (2021). A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. *Electronics*, 10(3), 279. <https://doi.org/10.3390/electronics10030279>

Palapol, Y., Ketsa, S., Stevenson, D., Cooney, J. M., Allan, A. C., & Ferguson, I. B. (2009). Colour development and quality of mangosteen (*Garcinia mangostana* L.) fruit during ripening and after harvest. *Postharvest Biology and Technology*, 51(3), 349–353. <https://doi.org/10.1016/j.postharvbio.2008.08.003>

Reddy Dirisala, S., & Padidem, D. (2023). Comparative Study of the Different Object Detection Algorithms: YOLOv4, SSD, and RCNN based on Accuracy and Speed. *International Journal of Science and Research (IJSR)*, 12(10), 1560–1565. <https://doi.org/10.21275/sr231020230143>

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 779–788). IEEE. <https://doi.org/10.1109/cvpr.2016.91>

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>

Sumiasih, I. H., Poerwanto, R., & Efendi, D. (2019). Study of Several Stages of Maturity and Storage Temperature on Color Changes and Shelf Life of Mangosteen (*Garcinia mangostana* L.). *International Journal of Applied Biology*, 3(1), 45. <https://doi.org/10.20956/ijab.v3i1.5967>

Tock, K. (2019). Google CoLaboratory as a Platform for Python Coding with Students. In *RTSRE Proceedings*. Our Solar Siblings. <https://doi.org/10.32374/rtsre.2019.013>

Whidhiasih, R. N., Guritman, S., & Suprio, P. T. (2012). Klasifikasi Kematangan Buah Manggis Ekspor dan Lokal Berdasarkan Warna dan Tekstur Menggunakan Fuzzy Neural Network. *Jurnal Ilmu Komputer Dan Agri-Informatika*, 1(2), 71. <https://doi.org/10.29244/jika.1.2.71-77>

Xu, Y., & Goodacre, R. (2018). On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning. *Journal of Analysis and Testing*, 2(3), 249–262. <https://doi.org/10.1007/s41664-018-0068-2>