

KLASIFIKASI KEMATANGAN BUAH KELAPA SAWIT MENGUNAKAN MODEL YOLOV8 BERBASIS *DEEP LEARNING*

Oil Palm Fruit Ripeness Classification Using YOLOv8 Deep Learning Model

Mukhes Sri Muna^{1*}, Yohanes Setiyo¹, I Putu Surya Wirawan¹, Muhdan Syarovy², Gigieh Henggar Jaya³

¹ Program Studi Teknik Pertanian dan Biosistem, Fakultas Teknologi Pertanian, Universitas Udayana, Bali, Indonesia

² Pusat Penelitian Kelapa Sawit, Medan, Indonesia

³ Program Studi Teknik Pertanian, Fakultas Pertanian, Universitas Jenderal Soedirman, Purwokerto, Indonesia

* Email: mukhessrimuna@unud.ac.id

DOI: <http://dx.doi.org/10.20884/1.jaber.2025.6.1.15953>

Naskah ini diterima pada 8 Mei 2025; revisi pada 29 Mei 2025;
disetujui untuk dipublikasikan pada 16 Juni 2025

ABSTRAK

Penentuan tingkat kematangan buah kelapa sawit yang akurat sangat penting untuk menjamin kualitas hasil produksi. Penelitian ini bertujuan mengimplementasikan dan mengevaluasi model klasifikasi kematangan buah kelapa sawit berbasis YOLOv8 dengan enam kelas kematangan menggunakan dataset publik dari Roboflow. Lima sub-model YOLOv8-cla (n, s, m, l, x) dilatih menggunakan dataset 3.024 gambar dan diuji pada 600 gambar uji independen. Evaluasi menggunakan metrik MAPE dan *confidence score*. Hasil pelatihan dan validasi menunjukkan seluruh model mencapai akurasi di atas 99%, dengan YOLOv8l-cla memperoleh MAPE terendah sebesar 1,167%. Visualisasi *confusion matrix* dan hasil prediksi memperkuat akurasi klasifikasi antar kelas. Meski demikian, studi ini masih terbatas pada dataset publik tanpa pengujian langsung di citra lapangan serta belum membandingkan kinerja dengan *baseline* model lain seperti YOLOv5, YOLOv11, atau Faster R-CNN. Ke depan, pengembangan diarahkan pada perluasan dataset citra lapangan, pengujian real-time berbasis UAV, serta integrasi sistem klasifikasi otomatis berbasis embedded system untuk mendukung praktik pemanenan presisi di perkebunan kelapa sawit.

Kata kunci: Kelapa Sawit, Kematangan Buah, Klasifikasi, YOLOv8

ABSTRACT

Determining the ripeness level of oil palm fruit accurately is essential to ensure the quality of production results. This study aims to implement and evaluate an oil palm fruit ripeness classification model based on the YOLOv8 architecture, using six ripeness categories and a publicly available image dataset from Roboflow. Five YOLOv8-cla sub-models (n, s, m, l, x) were trained using 3,024 images and tested on an independent dataset of 600 images. The evaluation employed MAPE and confidence score metrics. Training and validation results showed that all models achieved accuracy above 99%, with YOLOv8l-cla obtaining the lowest MAPE of 1.167%. Confusion matrix visualization and classification result samples confirmed the models' high accuracy in distinguishing between ripeness classes. However, this study is limited to publicly sourced datasets without direct field image testing and does not include comparative evaluations with other baseline models such as YOLOv5, YOLOv11 or Faster R-CNN. Future work should focus on expanding the dataset using field-collected images, conducting real-time testing with UAV imagery, and developing an embedded system-based classification platform to support precision harvesting practices in oil palm plantations.

Keywords: Classification, Fruit Ripeness, Oil Palm, YOLOv8

PENDAHULUAN

Industri kelapa sawit berkontribusi sekitar 40% dari total produksi minyak nabati di dunia, dimana sekitar 85% berasal dari Indonesia dan Malaysia (Iskandar *et al.*, 2018). Kebutuhan minyak kelapa sawit yang begitu besar harus diimbangi dengan produksi yang efisien dan berkelanjutan. Salah satu aspek penting untuk meningkatkan efisiensi dan keberlanjutan produksi adalah menentukan kematangan buah sebelum diproses. Penentuan kematangan buah sangat penting untuk menentukan waktu panen dan memastikan kemungkinan kualitas minyak kelapa sawit yang akan diekstrak (Aji & Hawari, 2019). Namun hingga saat ini, masih banyak industri yang menggunakan metode tradisional (penglihatan manusia) untuk menentukan kematangan buah kelapa sawit, akibatnya kualitas produk yang tidak konsisten (Azman & Suriani, 2023; Salim & Suharjito, 2023). Oleh karena itu, penggunaan sistem otomatis sangat dibutuhkan untuk menghindari inkonsistensi penentuan kematangan buah kelapa sawit oleh manusia (Shabdin *et al.*, 2016).

Kombinasi teknologi *Artificial Intelligence* (AI) dan *Machine Learning* (ML), untuk tugas visi komputer, mampu menganalisis pola yang kompleks pada sebuah gambar dengan akurasi dan konsistensi yang tinggi dibandingkan penglihatan manusia (Malyala, 2024). Sehingga, teknologi tersebut memiliki potensi mengatasi masalah penentuan kematangan buah kelapa sawit. Bagian dari visi komputer sendiri meliputi tugas deteksi, klasifikasi, dan segmentasi (Putra, 2019). Pada kasus penentuan kematangan buah kelapa sawit, dapat dimanfaatkan kemampuan visi komputer untuk tugas klasifikasi. Hal ini karena penentuan kematangan buah memiliki tingkat kematangan tertentu, sehingga memerlukan pengklasifikasian sesuai dengan kondisi yang nyata.

Berdasarkan penelitian sebelumnya, pendekatan AI dan ML telah banyak diterapkan pada perkebunan kelapa sawit untuk tugas visi komputer. Teknologi ini telah digunakan untuk melakukan deteksi tanaman kelapa sawit dengan berbagai model, misalnya model CNN (Li *et al.*, 2017), R-CNN (Djerriri *et al.*, 2018), Faster R-CNN (Zheng *et al.*, 2019), YOLOv3 (Muna *et al.*, 2023), hingga YOLOv5 (Daud *et al.*, 2023). Sedangkan untuk penentuan tingkat kematangan buah juga telah banyak dilakukan dengan berbagai metode untuk menentukan kematangan buah kelapa sawit, meliputi algoritma *Artificial Neural Network* (ANN), *Convolutional Neural Network* (CNN), dan *You Only Look Once* (YOLO). Berdasarkan penelitian tersebut, penentuan kematangan buah kelapa sawit berpotensi ditangani oleh kemampuan visi komputer (klasifikasi) yang menunjukkan akurasi tinggi. Alfatni *et al.* (2022) menggunakan arsitektur ANN mendapatkan akurasi 94%, Shiddiq (2022) menggunakan klasifikasi yang sama dengan menambahkan *K-fold cross validation* mendapat akurasi yang fluktuatif mencapai paling tinggi 90%. Selanjutnya, Saleh & Liansitim pada tahun 2020 mendapatkan akurasi sebesar 98% menggunakan arsitektur CNN untuk menentukan kematangan buah kelapa sawit. Ashari *et al.* (2022) juga melakukan penelitian penentuan kematangan buah kelapa sawit dengan arsitektur YOLO-v4 memperoleh akurasi 97%. Selain itu, (Mamat *et al.*, 2023) mencoba membandingkan arsitektur YOLOv3, YOLOv4 dan YOLOv5 yang menunjukkan bahwa YOLOv5 menjadi model yang paling cepat dan akurat dengan nilai akurasi mencapai 98,7%.


Meskipun arsitektur YOLOv5 menunjukkan nilai akurasi yang tinggi dan sangat berpotensi dalam klasifikasi kematangan buah, penelitian ini dilakukan untuk mengeksplorasi metode lain yang memiliki potensi lebih baik, yaitu YOLOv8. YOLOv8 merupakan model yang dikembangkan oleh Ultralytics (Jocher *et al.*, 2023), dan secara resmi dirilis tahun 2023. Model ini menghadirkan sejumlah peningkatan signifikan dibandingkan pendahulunya, di antaranya efisiensi komputasi dan fleksibilitas tugas (*object detection*, *classification*, dan *segmentation*). Casas *et al.* (2024) menunjukkan bahwa YOLOv8 mampu meningkatkan mAP hingga 4–6% dibanding YOLOv5 untuk objek kecil pada dataset agrikultur. Selain itu, YOLOv8 dinilai lebih efektif dalam mendeteksi objek dengan bentuk dan ukuran yang kompleks (Farooq *et al.*, 2024), yang sesuai dengan karakteristik buah kelapa sawit di lapangan.

Sejauh ini, YOLOv8 telah banyak digunakan dalam berbagai studi di bidang pertanian presisi, seperti klasifikasi kematangan buah tomat dan strawberry (Ajayi *et al.*, 2024; Quach *et*

al., 2024; Wang *et al.*, 2024). Adapun alasan pemilihan YOLOv8 dibandingkan dengan versi YOLO yang lebih baru seperti YOLOv11 atau YOLOv12 adalah karena stabilitas, ketersediaan dokumentasi, dan integrasi pustaka pendukung yang lebih lengkap pada YOLOv8 (Aryal *et al.*, 2020). Sharma *et al.*, (2024) menunjukkan bahwa nilai mAP YOLOv8 sebesar 0,921 lebih tinggi dibandingkan dengan model YOLOv11 yang hanya 0,914. Selain itu, nilai recall yang diperoleh juga mengungguli model YOLOv11 yaitu sebesar 0,858 dibanding 0,854. Oleh karena itu, YOLOv8 dipilih sebagai model untuk diimplementasikan dalam penelitian ini. Penelitian ini bertujuan untuk mengimplementasikan serta mengevaluasi kinerja YOLOv8 dalam mengklasifikasikan tingkat kematangan buah kelapa sawit sebagai upaya meningkatkan efisiensi panen di perkebunan kelapa sawit.

METODE PENELITIAN


Kerangka pikir penelitian ini mengikuti alur pada Gambar 1. Penelitian dimulai dengan pengumpulan data gambar dari Roboflow. Data yang terkumpul selanjutnya diproses untuk menstandarkan ukuran gambar, piksel dan augmentasi untuk menghasilkan dataset. Dataset digunakan untuk pelatihan dan validasi model dengan menggunakan arsitektur YOLOv8. Terakhir, evaluasi model dilakukan untuk mengetahui kemampuan model dalam melakukan klasifikasi tingkat kematangan buah kelapa sawit.



Gambar 1. Alur Implementasi Model YOLOv8 pada Klasifikasi Tingkat Kematangan Buah Kelapa Sawit.

YOLOv8-cls

YOLOv8 terdiri atas lima varian sub-model, yaitu YOLOv8n (*nano*), YOLOv8s (*small*), YOLOv8m (*medium*), YOLOv8l (*large*), dan YOLOv8x (*extra-large*), sehingga memungkinkan pengguna untuk menyesuaikan skala model dan kebutuhan akurasi (Jocher *et al.*, 2023). Hal ini juga yang mendasari penggunaan lima sub-model YOLOv8 untuk mengetahui kinerja model dengan dataset yang terbatas. Arsitektur YOLOv8 disajikan pada Gambar 2.




Gambar 2. Arsitektur YOLOv8.

Dalam tugas deteksi dan klasifikasi, YOLOv8 mempertahankan *backbone* serupa dengan YOLOv5, namun menggantikan CSPLayer dengan modul C2f (*Cross-Stage Partial Bottleneck* dengan dua konvolusi) yang dirancang untuk meningkatkan kemampuan deteksi dan klasifikasi

melalui integrasi fitur tingkat tinggi dan informasi kontekstual. Selain itu, YOLOv8 menerapkan pendekatan *anchor-free*, dengan kepala (*head*) terpisah untuk prediksi *objectness*, klasifikasi, dan regresi *bounding box* (Zhao *et al.*, 2019). Model ini menggunakan fungsi aktivasi sigmoid untuk skor *objectness* dan *softmax* untuk prediksi probabilitas kelas. Adapun fungsi loss yang diterapkan meliputi *Complete IoU* (CIoU) dan *Distribution Focal Loss* (DFL) untuk regresi *bounding box*, serta *binary cross-entropy* untuk tugas klasifikasi (Jocher *et al.*, 2023).

Prosedur Penelitian

Secara rinci, prosedur penelitian disajikan pada Gambar 3. penelitian terbagi ke dalam tahapan utama yaitu pengumpulan data, *preprocessing* data, pelatihan dan validasi model serta evaluasi model.



Gambar 3. Diagram Alir Prosedur Penelitian


Pengumpulan Data

Pengumpulan data merupakan tahapan yang penting untuk menyediakan data dalam proses pembangunan model klasifikasi tingkat kematangan buah kelapa sawit. Tahap ini merupakan tahapan utama dan menjadi sangat penting, sehingga data yang dikumpulkan harus memiliki pola dan karakter yang sesuai dengan kenyataan sebagai masukan pada proses selanjutnya. Penelitian menggunakan data berupa gambar buah kelapa sawit yang diperoleh dari Roboflow. Dataset berasal dari dua sumber yang berbeda, dataset yang berasal dari <https://universe.roboflow.com/palm-fruit-classification/palm-fruit-ripeness-classificationcmn> digunakan sebagai dataset pelatihan dan validasi, sedangkan dataset yang berasal dari <https://universe.roboflow.com/chiang-mai-university-skeej/ripeness-ffb-palm-oil> akan digunakan sebagai dataset uji dalam proses evaluasi model. Masing-masing dataset terdiri dari 6 kelas (tingkat kematangan) buah meliputi tandan kosong (*empty bunch*), busuk (*rotten*), terlalu matang (*overripe*), matang (*ripe*), kurang matang (*underripe*) dan tidak matang (*unripe*).

Tabel 1. Jumlah Dataset Pelatihan, Validasi dan Uji

Kelas Kematangan Buah Kelapa Sawit	Jumlah Data Pelatihan dan Validasi	Jumlah Data Uji
Tandan Kosong (<i>Empty Bunch</i>)	224	100
Tidak Matang (<i>Unripe</i>)	157	100
Kurang Matang (<i>Underripe</i>)	988	100
Matang (<i>Ripe</i>)	1.146	100
Terlalu Matang (<i>Overripe</i>)	423	100
Busuk (<i>Rotten</i>)	86	100
Jumlah Total	3.024	600

Pada Tabel 1 menyajikan jumlah sebaran dataset pelatihan, validasi dan uji masing-masing kelas tingkat kematangan buah kelapa sawit. Informasi ini membantu memahami komposisi dataset secara cepat dan mendukung pengambilan keputusan untuk pengembangan model. Selain itu sebaran jumlah data ini juga membantu untuk melihat keseimbangan data dan potensi bias dalam dataset. Beberapa contoh gambar dari masing-masing kelas juga dilakukan untuk memberikan gambaran tentang tampilan dan karakter setiap kelas tingkat kematangan buah yang disajikan pada Gambar 4.



Gambar 4. Visualisasi Contoh Data Setiap Kelas Kematangan Buah Kelapa Sawit.

Preprocessing Data

Setelah dilakukan visualisasi dataset, dilanjutkan dengan *preprocessing* data. Tahap ini dimulai dengan menyiapkan struktur direktori. Dibuat folder utama (yolov8), subfolder *train* dan subfolder *test*, yang berisi gambar-gambar pelatihan dan uji yang dikelompokkan berdasarkan 6 kelas tingkat kematangan buah. Setiap ukuran gambar diseragamkan menjadi 224x224 piksel agar data konsisten. Kemudian, gambar dinormalisasi ke rentang nilai [0, 1] dengan membagi tiap pikselnya dengan 255 menggunakan ImageDataGenerator dari Keras untuk mempercepat pelatihan model. Data gambar kemudian dimuat dari direktori menggunakan fungsi *flow_from_directory*, yang membaca gambar, mengubah ukurannya, menyusunnya dalam batch, serta mengacak urutan datanya. Selain itu, modul *glob* digunakan untuk menentukan *pipeline* gambar setiap kelas yang berguna untuk memeriksa isi dataset dan memastikan tidak ada masalah dalam komposisi data. Terakhir, data pelatihan beserta kelas dimuat dan digunakan di tahap pelatihan dan validasi model.

Pelatihan dan Validasi Model

Tahap pelatihan dan validasi model dilakukan menggunakan dataset yang telah melalui proses pra-pemrosesan dengan total sebanyak 3.024 gambar. Secara umum, pembagian dataset dalam pengembangan model *deep learning* untuk tugas deteksi objek atau klasifikasi dilakukan ke dalam tiga bagian, yaitu data pelatihan (*training set*), data validasi (*validation set*), dan data pengujian (*testing set*). Proporsi yang sering digunakan adalah sekitar 70 – 80% untuk data pelatihan, 10 – 20% untuk data validasi, dan 10 – 20% untuk data pengujian, bergantung pada jumlah dataset dan kompleksitas model (Chollet, 2021). Pada penelitian ini, dataset dibagi dengan 80% data pelatihan dan 20% data validasi, sementara pengujian model dilakukan secara terpisah menggunakan dataset uji independen yang tidak melibatkan dalam proses pelatihan dan validasi, guna memastikan kemampuan generalisasi model secara optimal.

Model yang digunakan pada penelitian ini adalah YOLOv8-cls yang terdiri dari lima sub-model (ukuran n, s, m, l, dan x). YOLOv8 digunakan untuk mengetahui performa klasifikasi tingkat kematangan buah kelapa sawit, dengan target akurasi yang lebih baik dibandingkan versi sebelumnya. YOLOv8 menggunakan CSPDarknet-AA yang telah diperbarui yang mampu memperbaiki akurasi klasifikasi dengan menggabungkan kekuatan CNN serta modul attention spasial untuk fokus area yang lebih presisi. Model ini juga mengadopsi GIoU (*Generalized Intersection over Union*) loss, yang dapat meningkatkan akurasi dalam pelokalan objek, khususnya untuk objek kecil dan tumpang tindih seperti buah sawit dalam tandan.

Pada tahap ini, disesuaikan berbagai parameter pelatihan untuk menganalisis pengaruhnya terhadap kinerja model YOLOv8, meliputi ukuran *batch*, *learning rate*, *momentum*, *weight decay*, dan jenis *optimizer*. Ukuran *batch* menggunakan 64, *learning rate* sebesar 0,01 untuk mempercepat proses penurunan *loss*. Rentang *weight decay* 0,0001 hingga 0,0005 diatur guna mencegah *overfitting*. Terakhir, optimizer SGD (*Stochastic Gradient Descent*) digunakan dengan momentum sebesar 0,937 karena untuk menghemat memori, stabil dalam proses pelatihan serta konsistensinya dalam proses deteksi. Selanjutnya seluruh model dilatih selama 20 epoch dengan menggunakan *google colab* versi pro yang menyediakan GPU A100. Pendekatan ini bertujuan mencapai keseimbangan optimal antara kedalaman pembelajaran model dan efisiensi komputasi, sehingga menghasilkan model yang tidak hanya akurat dalam klasifikasi kematangan buah kelapa sawit, tetapi juga mampu diimplementasikan secara praktis di lapangan.

Evaluasi Model

Seluruh model yang telah terlatih, selanjutnya dilakukan evaluasi dengan menggunakan dataset uji. Dataset uji memiliki total jumlah data 600 gambar dengan 6 kelas sesuai dengan

dataset pelatihan. Dataset berisi data yang berbeda dengan data pelatihan dan validasi, hal ini dimaksudkan untuk mengetahui performa model yang telah dibangun. Evaluasi menggunakan metrik MAPE (*Mean Absolute Percentage Error*) untuk mengukur seberapa besar kesalahan prediksi yang dilakukan oleh model terlatih dibandingkan dengan nilai aslinya. Persamaan MAPE mengikuti persamaan berikut ini.

$$MAPE = \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t}$$


Dimana y_t merupakan nilai aktual pada periode t dan $\hat{y}_t$ merupakan nilai prediksi pada periode t .

HASIL DAN PEMBAHASAN

Penelitian ini dilakukan untuk membangun model klasifikasi tingkat kematangan buah kelapa sawit dengan metode yang telah dijelaskan pada bab sebelumnya. Hasil pelatihan dan validasi model serta evaluasi seluruh sub model YOLOv8 akan dibahas pada subbab selanjutnya.

Model YOLOv8

Proses pelatihan dan validasi model YOLOv8 disajikan pada Gambar 5, yang memperlihatkan grafik beberapa metrik monitoring yaitu *training loss*, *validation loss*, *accuracy top-1*, dan *accuracy top-5* pada masing-masing sub-model. Berdasarkan grafik nilai *loss* dan akurasi selama proses pelatihan dan validasi, seluruh model secara umum menunjukkan tren penurunan nilai *loss* yang konsisten dan peningkatan nilai akurasi top-1 maupun top-5 yang signifikan seiring bertambahnya jumlah epoch.




Gambar 5. Metrik *Monitoring* Pelatihan dan Validasi Setiap Sub Model YOLOv8-cls: (a) YOLOv8n-cls, (b) YOLOv8s-cls, (c) YOLOv8m-cls, (d) YOLOv8l-cls dan (e) YOLOv8x-cls.

Model dengan ukuran parameter lebih besar seperti YOLOv8l-cls dan YOLOv8x-cls memperlihatkan konvergensi lebih cepat, ditandai dengan turunnya nilai *loss* secara tajam serta akurasi yang mendekati atau mencapai 100% hanya dalam beberapa epoch awal. Hasil ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa model dengan kapasitas parameter lebih besar umumnya memiliki kemampuan learning yang lebih cepat dalam mengakomodasi kompleksitas fitur (Tan & Le, 2019).

Di sisi lain, YOLOv8n-cls sebagai model *lightweight* menunjukkan akurasi yang sangat baik yaitu 0,99908, namun memerlukan lebih banyak epoch untuk mencapai performa optimalnya, sesuai karakteristik model berukuran kecil yang dioptimalkan untuk efisiensi komputasi dengan kompromi pada kecepatan konvergensi (Andrew *et al.*, 2019). Tren serupa juga terlihat pada YOLOv8s-cls sebesar 0,99342 dan YOLOv8m-cls sebesar 1,00 yang masing-masing menunjukkan peningkatan akurasi lebih cepat dengan nilai akurasi top-5 yang stabil sejak awal pelatihan.

Beberapa grafik menunjukkan fluktuasi (*noise*) pada nilai loss dan akurasi, terutama pada awal proses pelatihan, khususnya pada YOLOv8l-cla dan YOLOv8x-cla. Kondisi ini wajar terjadi akibat proses optimisasi model saat masih beradaptasi terhadap distribusi data (Chollet, 2021). Sepanjang proses pelatihan, tren penurunan nilai loss dan stabilisasi akurasi menunjukkan bahwa tidak terjadi *overfitting* yang signifikan, karena nilai loss pada data validasi tetap menurun dan nilai akurasi top-1 dan top-5 cenderung meningkat tanpa divergensi yang mencolok antara data pelatihan dan validasi. Hal ini mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik, sesuai dengan prinsip deep learning bahwa performa optimal ditandai oleh konvergensi loss pada data pelatihan dan validasi yang stabil, serta minimnya selisih di antara keduanya (Zhang *et al.*, 2021).



Gambar 6. *Confusion Matrix Normalized* Setiap Sub Model YOLOv8-cla: (a) YOLOv8n-cla, (b) YOLOv8s-cla, (c) YOLOv8m-cla, (d) YOLOv8l-cla dan (e) YOLOv8x-cla .

Pada Gambar 6. menyajikan *confusion matrix normalized* dari hasil pelatihan lima sub model, untuk klasifikasi kematangan buah kelapa sawit. Secara umum, terlihat bahwa seiring dengan meningkatnya kompleksitas model dari YOLOv8n-cla hingga YOLOv8x-cla, akurasi klasifikasi pada masing-masing kelas mengalami peningkatan. Pada YOLOv8n-cla, performa klasifikasi masih rendah, khususnya pada kelas *ripe* dan *rotten* yang masing-masing hanya mencapai akurasi 0,41 dan 0,42. Kesalahan klasifikasi yang dominan terjadi antara kelas *ripe*, *rotten*, dan *unripe*, menunjukkan keterbatasan model ringan dalam membedakan objek dengan fitur visual yang halus. Peningkatan akurasi mulai tampak pada YOLOv8s-cla dan YOLOv8m-cla, di mana YOLOv8m-cla mampu mencapai akurasi 0,61 pada kelas *ripe* dan 0,58 pada *rotten*.

Hal ini menunjukkan bahwa penambahan parameter model berpengaruh signifikan terhadap kemampuan ekstraksi fitur penting dari gambar buah kelapa sawit.

Performa klasifikasi semakin optimal pada YOLOv8l-cls, dengan nilai diagonal confusion matrix yang meningkat hampir merata di seluruh kelas, sementara YOLOv8x-cls berhasil mencapai hasil hampir sempurna dengan nilai diagonal mendekati 1 dan kesalahan antar kelas yang sangat minim. Temuan ini sejalan dengan penelitian Gunawan *et al.* (2023) yang melaporkan bahwa model YOLOv8x-cls unggul dalam klasifikasi kematangan TBS dengan akurasi 99,5%. Berdasarkan hasil ini, dapat disimpulkan bahwa model YOLOv8x menjadi pilihan paling ideal untuk diimplementasikan dalam sistem klasifikasi kematangan buah kelapa sawit, baik untuk monitoring lapangan maupun integrasi dengan sistem digital berbasis citra (Hidayat *et al.*, 2024).

Tabel 2. Perbandingan Penggunaan Memori GPU dan Waktu Selama Pelatihan

Sub Model	Penggunaan Memori GPU (G)	Waktu Pelatihan (Jam)
YOLOv8n-cls	0,4	0,068
YOLOv8s-cls	1,01	0,052
YOLOv8m-cls	1,15	0,071
YOLOv8l-cls	3,91	0,078
YOLOv8x-cls	4,11	0,082

Selanjutnya pada Tabel 2. menyajikan perbandingan lima sub-model YOLOv8-cls berdasarkan penggunaan memori GPU dan waktu selama proses pelatihan. Berdasarkan Gambar 3, seluruh model menunjukkan akurasi tinggi di atas 0,97, dengan YOLOv8x-cls mencatat nilai akurasi tertinggi sebesar 0,997, diikuti YOLOv8l-cls sebesar 0,995, serta YOLOv8m-cls dan YOLOv8n-cls yang sama-sama mencapai 0,994. Meskipun demikian, terdapat *trade-off* yang jelas antara peningkatan akurasi dengan konsumsi sumber daya komputasi (Sohan *et al.*, 2024). YOLOv8n-cls menjadi model paling ringan dengan penggunaan memori hanya 0,4 GB dan waktu pelatihan 0,068 jam, sementara YOLOv8x-cls memerlukan memori terbesar sebesar 4,11 GB dan waktu pelatihan terlama 0,082 jam. Perbedaan waktu pelatihan antar model memang relatif kecil, namun lonjakan konsumsi memori mulai terasa signifikan terutama dari YOLOv8m-cls ke YOLOv8l-cls. Hal ini menunjukkan bahwa pemilihan model ideal harus mempertimbangkan keseimbangan antara kebutuhan akurasi, efisiensi waktu, dan ketersediaan memori GPU, di mana YOLOv8n-cls atau YOLOv8s-cls cocok untuk sistem dengan keterbatasan sumber daya, sedangkan YOLOv8x-cls menawarkan akurasi maksimal untuk aplikasi klasifikasi kematangan buah kelapa sawit.

Evaluasi Model

Evaluasi performa model dengan menggunakan dataset uji yang berjumlah 600 gambar, terdiri atas 100 gambar untuk masing-masing kelas tingkat kematangan buah kelapa sawit. Berdasarkan Tabel 3, seluruh sub-model YOLOv8-cls menunjukkan performa klasifikasi yang baik dengan nilai *Mean Absolute Percentage Error* (MAPE) yang rendah, berkisar antara 0,01167 hingga 0,01500. Nilai MAPE terendah dicapai oleh YOLOv8l-cls sebesar 0,01167, diikuti oleh YOLOv8n-cls, YOLOv8s-cls, dan YOLOv8x-cls dengan nilai serupa sebesar 0,01333. Sementara itu, YOLOv8m-cls mencatatkan MAPE sedikit lebih tinggi, yakni 0,01500. Selain itu, nilai rata-rata *confidence score* dari masing-masing model memperlihatkan tingkat kepercayaan model terhadap hasil prediksinya, di mana YOLOv8m-cls dan YOLOv8l-cls unggul dengan nilai di atas 0,989, sedangkan YOLOv8n-cls berada di posisi terendah dengan 0,96351. Temuan ini sejalan dengan laporan Jocher *et al.* (2023) yang menyatakan bahwa model dengan kompleksitas parameter lebih besar memiliki performa klasifikasi dan kemampuan generalisasi yang lebih baik. Penggunaan MAPE dalam studi ini dipilih karena indikator ini bersifat intuitif, mudah diinterpretasikan, serta efektif dalam menggambarkan tingkat kesalahan relatif terhadap nilai aktual pada studi klasifikasi numerik (Kim & Kim, 2016).

Tabel 3. Perbandingan Hasil Pelatihan Model Masing-masing Sub Model YOLOv8-cl

Model	Data Aktual	Data Prediksi	MAPE	Rata-rata <i>Confidence Score</i>
YOLOv8n	600	592	0,01333	0,96351
YOLOv8s	600	592	0,01333	0,98090
YOLOv8m	600	591	0,01500	0,98916
YOLOv8l	600	593	0,01167	0,98912
YOLOv8x	600	592	0,01333	0,98783

Untuk melengkapi hasil kuantitatif, visualisasi hasil klasifikasi data uji ditampilkan pada Gambar 7. yang memperlihatkan sampel prediksi masing-masing kelas kematangan buah kelapa sawit, mulai dari *under-ripe*, *ripe*, *overripe*, *rotten*, *unripe*, hingga *empty bunch*. Visualisasi ini menunjukkan bahwa model mampu mengklasifikasikan tingkat kematangan dengan baik, ditandai oleh label prediksi yang sesuai dengan kondisi visual objek. Secara khusus, prediksi kelas *empty bunch* dan *rotten* yang memiliki karakteristik visual berbeda dari kelas lainnya, dapat diidentifikasi dengan tingkat akurasi yang tinggi. Hasil ini konsisten dengan studi Hidayat *et al.* (2024) dan Gunawan *et al.* (2023) yang menunjukkan bahwa varian YOLOv8 berkapasitas besar mampu memberikan performa deteksi dan klasifikasi tingkat kematangan buah kelapa sawit dengan akurasi di atas 95%. Dengan demikian, pengujian baik secara numerik maupun visual dalam penelitian ini mengonfirmasi bahwa model YOLOv8l-cl dan YOLOv8x-cl merupakan pilihan optimal untuk sistem klasifikasi otomatis tingkat kematangan buah kelapa sawit



Gambar 7. Sampel Prediksi Setiap Kelas Kematangan Buah Kelapa Sawit.

KESIMPULAN

Berdasarkan hasil penelitian, implementasi model YOLOv8 terbukti memiliki potensi yang sangat tinggi dalam mengklasifikasikan tingkat kematangan buah kelapa sawit, dengan akurasi sangat baik dan tingkat kesalahan prediksi yang rendah. Seluruh sub-model YOLOv8-cl menunjukkan performa klasifikasi yang konsisten, di mana hasil validasi dan uji model memperlihatkan nilai akurasi di atas 0,99 dan nilai MAPE yang rendah, berkisar antara 1,167 – 1,5%. YOLOv8l-cl tercatat sebagai model dengan performa terbaik, diikuti oleh YOLOv8x-cl

yang meskipun memiliki akurasi lebih tinggi (0,997) namun memerlukan konsumsi memori GPU lebih besar (4,11 GB). Hasil evaluasi visual melalui *confusion matrix* dan sampel prediksi data uji memperkuat temuan numerik, menunjukkan kemampuan model dalam membedakan fitur visual antar kelas kematangan dengan baik. Meskipun demikian, penelitian ini memiliki keterbatasan pada cakupan dataset yang masih terbatas dari dua sumber Roboflow, tanpa pengujian langsung menggunakan citra drone di lapangan, serta belum melakukan perbandingan performa dengan baseline model lain seperti Faster R-CNN, YOLOv5, YOLOv11 dan YOLOv12. Ke depan, pengembangan dapat diarahkan pada perluasan dataset berbasis citra lapangan, pengujian *real-time* di kondisi perkebunan, serta eksplorasi arsitektur YOLOv8-seg untuk segmentasi area tandan buah dan integrasi ke dalam sistem monitoring berbasis *mobile* atau *embedded system* untuk mendukung praktik pertanian presisi dan berkelanjutan.

DAFTAR PUSTAKA

- Ajayi, O. G., Ibrahim, P. O., & Adegboyega, O. S. (2024). Effect of Hyperparameter Tuning on the Performance of YOLOv8 for Multi Crop Classification on UAV Images. *Applied Sciences (Switzerland)*, 14(13). <https://doi.org/10.3390/app14135708>
- Aji, W., & Hawari, K. (2019). A Study of Deep Learning Method Opportunity on Palm Oil FFB (Fresh Fruit Bunch) Grading Methods. *Ahmad Dahlan International Conference Series on Engineering and Science (ADICS-ES 2019)*, 189, 35–38. <https://doi.org/10.2991/adics-es-19.2019.9>
- Alfatni, M. S. M., Khairunniza-Bejo, S., Marhaban, M. H. B., Saaed, O. M. B., Mustapha, A., & Shariff, A. R. M. (2022). Towards a Real-Time Oil Palm Fruit Maturity System Using Supervised Classifiers Based on Feature Analysis. *Agriculture (Switzerland)*, 12(9). <https://doi.org/10.3390/agriculture12091461>
- Andrew, H., Mark, S., Grace, C., Liang-Chieh, C., Bo, C., Mingxing, T., Weijun, W., Yukun, Z., Ruoming, P., & Vijay, V. (2019). Searching for mobilenetv3. *Proceedings of the IEEE International Conference on Computer Vision*, 1314–1324.
- Aryal, J. P., Sapkota, T. B., Khurana, R., Khatri-Chhetri, A., Rahut, D. B., & Jat, M. L. (2020). Climate change and agriculture in South Asia: adaptation options in smallholder production systems. In *Environment, Development and Sustainability* (Vol. 22, Issue 6). Springer Netherlands. <https://doi.org/10.1007/s10668-019-00414-4>
- Ashari, S., Yanris, G. J., & Purnama, I. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning. *Sinkron*, 7(2), 649–656. <https://doi.org/10.33395/sinkron.v7i2.11420>
- Azman, H., & Suriani, N. S. (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network. *Evolution in Electrical and Electronic Engineering*, 4(1), 185–194. <http://publisher.uthm.edu.my/periodicals/index.php/eeee>
- Casas, E., Ramos, L., Romero, C., & Rivas-Echeverría, F. (2024). A comparative study of YOLOv5 and YOLOv8 for corrosion segmentation tasks in metal surfaces. *Array*, 22(March). <https://doi.org/10.1016/j.array.2024.100351>
- Chollet, F. (2021). *Deep Learning with Python* (Second Edi). Manning Publications Co.
- Daud, M. M., Kadim, Z., & Woon, H. H. (2023). Detection of Oil Palm Tree and Loose Fruitlets for Fresh Fruit Bunch's Ready-to-Harvest Prediction via Deep Learning Approach. *IAENG International Journal of Computer Science*, 50(4).
- Djerri, K., Ghabi, M., Karoui, M. S., & Adjoudj, R. (2018). Palm trees counting in remote sensing imagery using regression convolutional neural network. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2018-July, 2627–2630. <https://doi.org/10.1109/IGARSS.2018.8519188>
- Farooq, J., Muaz, M., Khan Jadoon, K., Aafaq, N., & Khan, M. K. A. (2024). An improved YOLOv8 for foreign object debris detection with optimized architecture for small objects. *Multimedia Tools and Applications*, 83(21), 60921–60947. <https://doi.org/10.1007/s11042-023-17838-w>

- Gunawan, T. S., Kartiwi, M., Mansor, H., & Yusoff, N. M. (2023). Palm Fruit Ripeness Detection and Classification Using Various YOLOv8 Models. *ICSIMA 2023 - 9th IEEE International Conference on Smart Instrumentation, Measurement and Applications*, 193–198. <https://doi.org/10.1109/ICSIMA59853.2023.10373435>
- Hidayat, M. R., Sulisty, P. A., Oktario, H., Gunawan, A. A. S., & Mimboro, P. (2024). Establishing a Standard Operating Procedure (SOP) for Palm Oil Plantation FFB Image Capture: Utilizing YOLOv8 for Counting and Ripeness Classification. *2024 6th International Conference on Cybernetics and Intelligent System, ICORIS 2024*, 1–6. <https://doi.org/10.1109/ICORIS63540.2024.10903724>
- Iskandar, M. J., Baharum, A., Anuar, F. H., & Othaman, R. (2018). Palm oil industry in South East Asia and the effluent treatment technology—A review. *Environmental Technology and Innovation*, 9(May 2017), 169–185. <https://doi.org/10.1016/j.eti.2017.11.003>
- Jocher, G., Chaurasia, A., Qiu, J., & Stoken, A. (2023). YOLOv8: Ultralytics Official Documentation. In *YOLOv8*. Ultralytics. <https://docs.ultralytics.com>
- Kim, S., & Kim, H. (2016). A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, 32(3), 669–679. <https://doi.org/10.1016/j.ijforecast.2015.12.003>
- Li, W., Fu, H., Yu, L., & Cracknell, A. (2017). Deep learning based oil palm tree detection and counting for high-resolution remote sensing images. *Remote Sensing*, 9(1). <https://doi.org/10.3390/rs9010022>
- Malyala, R. (2024). *Development of a Convolutional Neural Network Model for Automated Ripeness Classification of Palm Oil Fresh Fruit Bunches*. 9(11), 1040–1046.
- Mamat, N., Othman, M. F., Abdulghafor, R., Alwan, A. A., & Gulzar, Y. (2023). Enhancing Image Annotation Technique of Fruit Classification Using a Deep Learning Approach. *Sustainability (Switzerland)*, 15(2). <https://doi.org/10.3390/su15020901>
- Muna, M. S., Nugroho, A. P., Syarovy, M., Wiratmoko, A., Suwardi, & Sutiarso, L. (2023). Development of Automatic Counting System for Palm Oil Tree Based on Remote Sensing Imagery. *Proceedings of the International Conference on Sustainable Environment, Agriculture and Tourism (ICOSEAT 2022)*, 26(DI), 503–508. https://doi.org/10.2991/978-94-6463-086-2_68
- Putra, J. W. G. (2019). Pengenalan konsep pembelajaran mesin dan deep learning. *Computational Linguistics and Natural Language Processing Laboratory*, 4(August), 1–235. <https://www.researchgate.net/publication/323700644>
- Quach, L. Da, Quoc, K. N., Quynh, A. N., Ngoc, H. T., & Thai-Nghe, N. (2024). Tomato Health Monitoring System: Tomato Classification, Detection, and Counting System Based on YOLOv8 Model With Explainable MobileNet Models Using Grad-CAM++. *IEEE Access*, 12, 9719–9737. <https://doi.org/10.1109/ACCESS.2024.3351805>
- Saleh, A. Y., & Liansitim, E. (2020). Palm oil classification using deep learning. *Science in Information Technology Letters*, 1(1), 1–8. <https://doi.org/10.31763/sitech.v1i1.1>
- Salim, E., & Suharjito. (2023). Hyperparameter optimization of YOLOv4 tiny for palm oil fresh fruit bunches maturity detection using genetics algorithms. *Smart Agricultural Technology*, 6(November), 100364. <https://doi.org/10.1016/j.atech.2023.100364>
- Shabdin, M. K., Shariff, A. R. M., Johari, M. N. A., Saat, N. K., & Abbas, Z. (2016). A study on the oil palm fresh fruit bunch (FFB) ripeness detection by using Hue, Saturation and Intensity (HSI) approach. *IOP Conference Series: Earth and Environmental Science*, 37(1). <https://doi.org/10.1088/1755-1315/37/1/012039>
- Sharma, A., Kumar, V., & Longchamps, L. (2024). Comparative performance of YOLOv8, YOLOv9, YOLOv10, YOLOv11 and Faster R-CNN models for detection of multiple weed species. *Smart Agricultural Technology*, 9(August), 100648. <https://doi.org/10.1016/j.atech.2024.100648>
- Shiddiq, M. (2022). Counting of Oil Palm Fresh Fruit Bunches Using Computer Vision. *Journal of Oil Palm Research*. <https://doi.org/10.21894/jopr.2022.0029>
- Sohan, M., Sai Ram, T., & Rami Reddy, C. V. (2024). *A Review on YOLOv8 and Its*

- Advancements. January*, 529–545. https://doi.org/10.1007/978-981-99-7962-2_39
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks Mingxing. *Canadian Journal of Emergency Medicine*, 15(3), 190.
- Wang, C., Wang, H., Han, Q., Zhang, Z., Kong, D., & Zou, X. (2024). Strawberry Detection and Ripeness Classification Using YOLOv8+ Model and Image Processing Method. *Agriculture (Switzerland)*, 14(5). <https://doi.org/10.3390/agriculture14050751>
- Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2021). Understanding deep learning (still) requires rethinking generalization. *Communications of the ACM*, 64(3), 107–115. <https://doi.org/10.1145/3446776>
- Zhao, Z. Q., Zheng, P., Xu, S. T., & Wu, X. (2019). Object Detection with Deep Learning: A Review. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3212–3232. <https://doi.org/10.1109/TNNLS.2018.2876865>
- Zheng, J., Li, W., Xia, M., Dong, R., Fu, H., & Yuan, S. (2019). LARGE-SCALE OIL PALM TREE DETECTION FROM HIGH-RESOLUTION REMOTE SENSING IMAGES USING FASTER-RCNN. *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, 1422–1425.