

Deteksi Otomatis Kematangan Buah Kelapa Sawit Menggunakan YOLOv8 untuk Pemilihan Model Deteksi Terbaik

Anranur Uwaisy Marchiningrum^{*1}, Alfian Akbar Gozali², Villy Satria Pradithae³, Ario Harry Prayogo⁴

¹Sistem Informasi Kota Cerdas, Universitas Telkom

²Rekayasa Perangkat Lunak Aplikasi, Universitas Telkom

^{3,4}Rekayasa Perangkat Lunak, Universitas Telkom

Email: ¹anranurumarchi@telkomuniversity.ac.id, ²alfian@telkomuniversity.ac.id,
³villysatria@telkomuniversity.ac.id, ⁴ariohp@telkomuniversity.ac.id

Abstrak

Deteksi kematangan buah kelapa sawit secara akurat merupakan faktor penting dalam menjamin kualitas hasil panen dan efisiensi produksi di sektor perkebunan. Metode penilaian manual yang masih banyak digunakan cenderung bersifat subjektif dan tidak konsisten, sehingga diperlukan sistem otomatis yang mampu menganalisis citra buah secara akurat dan terukur. Penelitian ini bertujuan mengembangkan dan membandingkan performa tiga varian model YOLOv8, yaitu YOLOv8n (nano), YOLOv8s (small), dan YOLOv8m (medium), dalam mendeteksi tingkat kematangan buah kelapa sawit yang diklasifikasikan ke dalam tiga kelas, yaitu mentah, setengah matang, dan matang. Dataset beranotasi diperoleh dari Roboflow dan terdiri dari 150 citra dengan distribusi kelas yang seimbang, sehingga mendukung proses pelatihan dan evaluasi model secara objektif. Model dilatih menggunakan Google Colab selama 20 epoch dan dievaluasi menggunakan metrik mean Average Precision (mAP), recall, dan precision. Hasil evaluasi menunjukkan bahwa YOLOv8s merupakan model paling optimal dengan nilai mAP sebesar 0.944, precision 0.956, dan recall 0.895. YOLOv8n unggul dari sisi kecepatan inferensi (2.0 ms), namun memiliki tingkat akurasi yang lebih rendah, sedangkan YOLOv8m menunjukkan performa yang kompetitif dengan kebutuhan sumber daya komputasi yang lebih besar. Berdasarkan analisis keseimbangan antara akurasi dan efisiensi komputasi, YOLOv8s direkomendasikan sebagai solusi deteksi otomatis yang paling efektif. Secara ilmiah, penelitian ini berkontribusi dalam pengembangan metode analisis citra berbasis *deep learning* untuk mendukung pertanian presisi, khususnya dalam pemilihan model deteksi objek yang optimal pada sistem pemantauan kematangan buah kelapa sawit.

Kata kunci: *deep learning*, deteksi objek, kelapa sawit, kematangan buah, YOLOv8

Automatic Detection of Palm Oil Fruit Ripeness Using YOLOv8 for Selection of the Best Detection Model

Abstract

Accurately detecting oil palm fruit ripeness is a crucial factor in ensuring crop quality and production efficiency in the plantation sector. Widely used manual assessment methods tend to be subjective and inconsistent, necessitating an automated system capable of analyzing fruit images accurately and measurably. This study aims to develop and compare the performance of three YOLOv8 model variants, namely YOLOv8n (nano), YOLOv8s (small), and YOLOv8m (medium), in detecting the ripeness level of oil palm fruit classified into three classes: unripe, semi-ripe, and ripe. The annotated dataset was obtained from Roboflow and consists of 150 images with a balanced class distribution, thus supporting objective model training and evaluation processes. The model was trained using Google Colab for 20 epochs and evaluated using the metrics of mean average precision (mAP), recall, and precision. The evaluation results showed that YOLOv8s was the most optimal model with an mAP value of 0.944, a precision of 0.956, and a recall of 0.895. YOLOv8n excels in inference speed (2.0 ms); but has a lower accuracy rate, while YOLOv8m shows competitive performance with greater computational resource requirements. Based on the analysis of the balance between accuracy and computational efficiency, YOLOv8s is recommended as the most effective automatic detection solution. Scientifically, this research contributes to the development of deep learning-based image analysis methods to support precision agriculture, particularly in selecting optimal object detection models in oil palm fruit ripeness monitoring systems.

Keywords: *deep learning, fruit ripeness, object detection, oil palm, YOLOv8*

1. PENDAHULUAN

Produktivitas di sektor perkebunan kelapa sawit menghadapi tantangan utama dalam memastikan akurasi penentuan tingkat kematangan buah. Pemanenan yang dilakukan secara manual oleh pekerja lapangan sering kali menghasilkan penilaian yang subjektif dan tidak konsisten, sehingga berpotensi menimbulkan kerugian akibat panen yang dilakukan terlalu cepat atau terlalu lambat. Ketidaktepatan penentuan kematangan buah berdampak langsung pada kualitas minyak sawit mentah (CPO) serta efisiensi proses produksi secara keseluruhan. Penelitian yang dilakukan oleh Bonet et al. [1] menemukan bahwa klasifikasi kematangan yang dilakukan secara manual menunjukkan tingkat variabilitas yang tinggi, sehingga berdampak pada mutu minyak dan efisiensi proses panen. Ashari et al. [2] juga melaporkan bahwa meskipun metode berbasis convolutional neural network (CNN) menunjukkan akurasi tinggi sebesar 92% pada data uji, akurasi tersebut menurun drastis menjadi 76% pada data nyata karena pengaruh kondisi lingkungan yang tidak terkontrol. Junior dan Suharjito menambahkan bahwa deteksi kematangan menggunakan data video menghadapi hambatan teknis seperti efek kabur dan fluktuasi pencahayaan [3]. Lai et al. [4] menyoroti bahwa metode berbasis warna dan tekstur masih belum optimal dalam mengenali kematangan buah akibat variasi spesies dan kondisi visual buah sawit di lapangan. Selain itu, Wong et al. [5] menemukan bahwa tanpa penggunaan algoritma pendeteksi yang sesuai, deteksi loose fruit dalam citra berlapis menghasilkan performa yang rendah. Beberapa penelitian terkini mengonfirmasi keunggulan algoritma You Only Look Once (YOLO) dalam mendeteksi objek berukuran kecil secara efisien, seperti yang dilakukan oleh Cai et al. [6] dan Gamani et al. [7], di mana YOLOv8 menunjukkan performa tinggi dalam klasifikasi buah matang pada berbagai tanaman. Temuan lapangan juga memperkuat urgensi penelitian ini, di mana hasil wawancara dengan salah satu manajer pengolahan di PT Perkebunan Nusantara mengungkapkan bahwa proses pemilihan buah kelapa sawit masih dilakukan secara manual dan keberadaan buah mentah yang tercampur dapat menurunkan kualitas warna serta hasil akhir CPO.

Sejumlah penelitian sebelumnya telah mengusulkan solusi berbasis analisis citra digital dan *deep learning* untuk mengatasi permasalahan tersebut. Bonet et al. [1] berhasil mengimplementasikan model YOLOv8 untuk mendeteksi tingkat kematangan buah kelapa sawit secara akurat dalam kondisi lapangan. Di sisi lain, Junior dan Suharjito [3] merancang pendekatan real-time berbasis video menggunakan YOLOv4 yang diperkuat dengan strategi augmentasi data dan fine-tuning guna meningkatkan akurasi. Wong et al. [5] juga melakukan evaluasi komprehensif terhadap beberapa versi YOLO (YOLOv5, YOLOv8, YOLO-NAS, dan YOLOX) [5], dan mencatat bahwa model YOLOv8 mampu mencapai nilai mean Average Precision (mAP) hingga 0.934 dalam mendeteksi loose fruit dan Fresh Fruit Bunch (FFB) [8]. Meskipun demikian, sebagian besar penelitian terdahulu masih berfokus pada peningkatan akurasi model secara individual, tanpa melakukan analisis komparatif mendalam terhadap efisiensi dan keseimbangan performa antarvarian model dalam konteks implementasi nyata di perkebunan.


Penelitian ini dirancang untuk membangun sistem deteksi otomatis tingkat kematangan buah kelapa sawit dengan memanfaatkan tiga varian algoritma YOLOv8, yaitu YOLOv8n, YOLOv8s, dan YOLOv8m. Dataset yang digunakan berasal dari sumber publik yang telah dianotasi dan dikelompokkan ke dalam tiga kategori kematangan, meliputi buah mentah, setengah matang, dan matang. Pengembangan sistem dilakukan melalui beberapa tahapan terstruktur, mulai dari pengumpulan dan eksplorasi data citra, pelatihan model menggunakan platform Google Colab berbasis GPU, hingga evaluasi performa model menggunakan metrik mAP, recall, dan precision.

Oleh karena itu, perbedaan utama dari penelitian sebelumnya adalah penelitian ini secara eksplisit melakukan analisis komparatif terhadap tiga varian YOLOv8 untuk mengidentifikasi model yang paling optimal berdasarkan keseimbangan antara akurasi deteksi dan efisiensi komputasi. Kontribusi utama penelitian ini terletak pada penyediaan dasar empiris dalam pemilihan konfigurasi model deteksi objek yang paling sesuai untuk diterapkan pada sistem pemantauan kematangan buah kelapa sawit secara otomatis. Dengan demikian, penelitian ini tidak hanya bersifat aplikatif, tetapi juga memberikan kontribusi ilmiah dalam pengembangan sistem analisis citra berbasis pembelajaran mendalam untuk mendukung implementasi pertanian presisi di sektor perkebunan kelapa sawit.

2. METODE PENELITIAN

Penelitian ini dilakukan untuk membandingkan kinerja tiga varian algoritma deteksi objek YOLO versi 8, yaitu YOLOv8n, YOLOv8s, dan YOLOv8m. Kajian ini berfokus pada proses pendeteksian dan pengelompokan tingkat kematangan buah yang memiliki pengaruh langsung terhadap kualitas hasil panen dan efisiensi produksi. Tingkat kematangan buah dalam penelitian ini diklasifikasikan ke dalam tiga kategori, yakni buah mentah, buah setengah matang, dan buah matang. Pendekatan analisis komparatif dipilih untuk mengevaluasi keseimbangan antara akurasi deteksi dan efisiensi komputasi dari masing-masing varian model. Evaluasi komparatif terhadap beberapa varian YOLOv8 pada domain pertanian kompleks yang dilakukan oleh Bektaş [14] menunjukkan pentingnya analisis keseimbangan antara akurasi deteksi dan efisiensi komputasi, sehingga pendekatan analisis

komparatif antarvarian YOLOv8 juga diterapkan pada penelitian ini. Proses penelitian dilakukan melalui beberapa tahapan yang saling berkaitan, sebagaimana ditampilkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Data Acquisition

Data Acquisition adalah proses mengumpulkan data yang akan digunakan untuk melatih model AI [9]. Data citra yang digunakan pada penelitian ini bersumber dari dataset publik yang disediakan melalui platform Roboflow, sebuah platform yang menyediakan kumpulan data (dataset) dengan anotasi siap pakai untuk pelatihan model AI. Dataset ini sudah dilengkapi dengan bounding box dan label yang relevan untuk tiga kelas kematangan buah, yaitu: (1) buah_mentah, (2) buah_setengah_matang, dan (3) buah_matang. Seluruh data tersedia dalam format .png dan dapat langsung digunakan untuk proses pelatihan model. Pemanfaatan dataset publik beranotasi dipilih untuk menjamin konsistensi label serta mendukung reproduktibilitas penelitian.

2.2. Data Exploration

Data Exploration adalah proses awal untuk memahami isi dataset yang telah dikumpulkan [9]. Langkah ini bertujuan untuk memastikan bahwa data cukup representatif untuk semua kelas (buah mentah, setengah matang, dan matang), serta memahami kemungkinan tantangan saat pelatihan seperti ketidakseimbangan data antar kelas.

Tahap ini melibatkan proses eksplorasi dan praproses terhadap dataset. Penyesuaian format dilakukan menggunakan fitur export Roboflow, yang memungkinkan konversi dataset ke format YOLOv8. Dataset kemudian dibagi menjadi tiga subset:

- Train = 105 gambar → digunakan untuk mengajarkan model mengenali objek.
- Validation = 30 gambar → digunakan untuk menguji model selama pelatihan agar tidak overfitting (belajar terlalu spesifik pada data latihan).
- Test = 15 gambar → digunakan untuk mengevaluasi performa akhir model setelah pelatihan selesai.

Pembagian dataset mengikuti rasio 70:20:10 yang umum digunakan dalam penelitian pembelajaran mendalam untuk menjaga keseimbangan antara proses pelatihan dan evaluasi model [8]. Dataset yang digunakan terdiri dari total 150 gambar, dengan distribusi yang seimbang untuk setiap kelas, yaitu masing-masing 50 gambar untuk masing-masing label. Seluruh gambar kemudian diubah ukurannya menjadi 640×640 piksel agar sesuai dengan spesifikasi input model YOLOv8 yang digunakan dalam pelatihan. Resolusi ini dipilih karena merupakan ukuran standar pada YOLOv8 yang mampu menjaga keseimbangan antara detail fitur visual dan efisiensi komputasi [6]. Penggunaan resolusi input standar YOLO dan pembagian dataset terstruktur pada penelitian identifikasi kematangan buah apel oleh Oktapian dan Giri [15] menunjukkan bahwa konfigurasi pelatihan yang seimbang berpengaruh signifikan terhadap kestabilan nilai mAP dan precision, sehingga pendekatan serupa diadopsi dalam penelitian ini.

2.3. Model Training

Model Training adalah proses ketika model AI belajar mengenali objek (dalam hal ini, buah dengan berbagai tingkat kematangan) dari data yang sudah diberi label [9]. Proses ini dilakukan menggunakan Google Colab, dengan memanfaatkan GPU (Graphics Processing Unit) untuk mempercepat komputasi.

Dalam pelatihan ini digunakan tiga varian model dari YOLOv8, yaitu YOLOv8n (nano), YOLOv8s (small), dan YOLOv8m (medium). Masing-masing memiliki kompleksitas dan ukuran model yang berbeda. YOLOv8n merupakan model dengan ukuran terkecil dan tercepat, namun dengan akurasi yang lebih rendah dibandingkan model lainnya, YOLOv8s merupakan versi menengah yang seimbang antara ukuran dan akurasi, sedangkan

YOLOv8m memiliki kompleksitas lebih tinggi dan performa yang lebih baik, namun dengan kebutuhan komputasi yang lebih besar [10], [11].

Model dilatih selama 20 epoch, di mana satu epoch merupakan satu kali putaran lengkap ketika model mempelajari seluruh data pelatihan. Artinya, dalam pelatihan ini model mempelajari seluruh data pelatihan sebanyak 20 kali. Selama pelatihan, digunakan batch size sebesar 16, yang berarti model memproses 16 gambar sekaligus dalam satu waktu sebelum memperbarui bobot atau parameter internalnya.

Pemilihan jumlah epoch didasarkan pada pertimbangan konvergensi model pada dataset berukuran sedang, di mana peningkatan epoch di atas nilai tersebut berpotensi menyebabkan overfitting tanpa peningkatan performa yang signifikan [7]. Batch size 16 dipilih karena memberikan keseimbangan antara stabilitas pembaruan bobot dan keterbatasan memori GPU, sebagaimana direkomendasikan dalam pelatihan model YOLO untuk deteksi objek [13]. Selain itu, Pendekatan pelatihan YOLOv8 dengan jumlah epoch terbatas pada dataset pertanian berskala kecil hingga menengah telah terbukti mampu mencapai konvergensi model yang stabil tanpa overfitting, sebagaimana ditunjukkan pada sistem identifikasi kematangan buah tomat ceri oleh Fathurahman dan Hanum [16].

2.4. Evaluation

Evaluasi model merupakan langkah penting dalam menilai performa dari model yang telah dilatih. Proses ini dilakukan untuk mengukur keandalan model ketika digunakan pada data yang belum pernah dilihat sebelumnya [12]. Dalam penelitian ini, digunakan tiga metrik utama untuk mengevaluasi performa model deteksi objek, yaitu mean Average Precision (mAP), Recall, dan Precision. Ketiga metrik ini merupakan indikator standar yang umum digunakan dalam tugas deteksi objek berbasis YOLO [13].

Metrik mAP mengevaluasi seberapa akurat model dalam mendeteksi dan mengklasifikasikan objek (dalam hal ini buah) dalam berbagai kondisi. Perhitungan mAP disajikan dalam Persamaan (1):

$$mAP@50 = \frac{1}{N} \sum_{i=1}^N AP_i \quad (1)$$

Recall digunakan untuk mengukur seberapa banyak objek yang benar-benar ada berhasil dikenali oleh model. Semakin tinggi nilai recall, semakin baik kemampuan model dalam mendeteksi objek secara menyeluruh, meskipun hal ini kadang berdampak pada menurunnya ketepatan prediksi. Nilai recall dihitung menggunakan Persamaan (2):

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

Sementara itu, precision mengukur sejauh mana prediksi positif dari model memang benar-benar tepat. Precision yang tinggi menunjukkan bahwa model jarang melakukan kesalahan dalam mendeteksi objek yang sebenarnya tidak ada (false positive). Nilai precision dihitung menggunakan Persamaan (3):

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

Kombinasi ketiga metrik ini digunakan untuk memberikan evaluasi yang komprehensif terhadap performa model, sehingga memungkinkan analisis yang seimbang antara sensitivitas deteksi dan tingkat kesalahan prediksi pada penerapan nyata di lapangan.

3. HASIL DAN PEMBAHASAN

YOLOv8 yang telah dilatih pada dataset kematangan buah, serta analisis terhadap performa masing-masing varian model. Evaluasi dilakukan untuk menilai kemampuan model dalam mendeteksi tiga kategori tingkat kematangan buah.

Proses pelatihan menghasilkan metrik evaluasi berupa precision, recall, dan mean average precision (mAP) yang kemudian digunakan sebagai dasar perbandingan performa antara YOLOv8n, YOLOv8s, dan YOLOv8m. Selain itu, visualisasi hasil deteksi dan analisis performa juga disertakan untuk mendukung pemilihan model terbaik yang paling sesuai untuk diterapkan dalam sistem deteksi otomatis pada sektor pertanian.

3.1. Evaluasi Model

Hasil evaluasi dari ketiga varian YOLOv8 terhadap dataset kematangan buah disajikan pada Tabel 1 berikut:

Tabel 1. Hasil Evaluasi Model

Tipe Yolo	mAP	Recall	Precision	Waktu Inferensi
YOLOv8n	0.807	0.933	0.935	2.0ms
YOLOv8s	0.956	0.895	0.944	4.6ms
YOLOv8m	0.932	0.869	0.941	10.4ms

Model YOLOv8n (nano) memiliki nilai Recall tertinggi sebesar 0.933 dan mAP sebesar 0.935, yang menunjukkan kemampuannya dalam menjangkau hampir seluruh objek dalam gambar, meskipun tingkat Precision-nya lebih rendah dibanding model lain. Sementara itu, YOLOv8s (small) menunjukkan performa paling seimbang, dengan nilai Precision tertinggi sebesar 0.956 dan mAP tertinggi sebesar 0.944, menjadikannya kandidat terbaik untuk diimplementasikan dalam sistem nyata karena mampu memberikan hasil deteksi yang akurat dan konsisten. Adapun model YOLOv8m (medium) tetap unggul dari sisi akurasi keseluruhan, namun memerlukan sumber daya komputasi lebih besar dan memiliki kecepatan inferensi yang sedikit lebih lambat dibandingkan varian lainnya.

3.2. Pemilihan Model Terbaik

Berdasarkan hasil evaluasi, model YOLOv8s (small) dipilih sebagai model terbaik dalam tugas deteksi kematangan buah. Pemilihan model tersebut didasarkan pada capaian nilai precision dan mAP yang relatif tinggi, masing-masing sebesar 0.956 dan 0.944, yang mengindikasikan kemampuan model dalam menghasilkan deteksi dengan tingkat akurasi tinggi serta kesalahan prediksi yang minimal.

Keseimbangan antara akurasi deteksi dan efisiensi menjadikan YOLOv8s ideal untuk diterapkan dalam sistem monitoring kualitas panen secara otomatis. Deteksi terhadap tiga kelas kematangan buah—buah_mentah, buah_setengah_matang, dan buah_matang—dilakukan secara konsisten dengan tingkat kepercayaan yang tinggi, sehingga model ini cocok digunakan dalam aplikasi nyata.


3.3. Visualisasi Deteksi

Visualisasi hasil deteksi objek dilakukan pada citra buah kelapa sawit yang mewakili setiap tingkat kematangan, yaitu buah_mentah, buah_setengah_matang, dan buah_matang. Deteksi objek ditampilkan dalam bentuk bounding box yang mencantumkan label kelas kematangan serta confidence score dari model YOLOv8s.



Gambar 2. Visualisasi Kelapa Sawit Mentah

Gambar 2 menampilkan hasil deteksi buah kelapa sawit dalam kategori buah_mentah, ditandai dengan bounding box berwarna hijau dan skor kepercayaan sebesar 0.97. Warna buah yang dominan merah tua kehitaman tanpa adanya perubahan warna signifikan menunjukkan ciri khas buah yang belum matang. Deteksi dilakukan dengan sangat presisi di lingkungan terbuka dengan pencahayaan alami.



Gambar 3. Visualisasi Kelapa Sawit Setengah Matang

Deteksi pada gambar 3 menunjukkan buah kelapa sawit dengan label `buah_setengah_matang` dan skor kepercayaan 0.99, yang mengindikasikan keyakinan model sangat tinggi terhadap klasifikasi tersebut. Buah menunjukkan kombinasi warna merah tua dan oranye cerah, menandakan transisi kematangan. Area deteksi cukup rapat dan fokus pada kelompok buah yang seragam secara visual.



Gambar 4. Visualisasi Kelapa Sawit Matang

Gambar 4 menunjukkan model mendeteksi buah kelapa sawit matang (`buah_matang`) dengan bounding box berwarna biru dan confidence score 0.97. Warna buah yang dominan oranye terang hingga kemerahan menjadi indikator visual kematangan penuh. Meskipun terdapat beberapa tandan buah di dalam gambar, model tetap mampu mendeteksi satu area dominan yang merepresentasikan kematangan secara keseluruhan.

3.4. Diskusi

Bagian ini merupakan bagian untuk mengaitkan hasil yang diperoleh dari penelitian ini dengan temuan penelitian lain yang sejenis. Tabel 2 menyajikan perbandingan hasil penelitian ini dengan beberapa studi terkait pada bidang deteksi kematangan buah berbasis algoritma YOLO dalam lima tahun terakhir. Perbandingan tersebut menunjukkan keterkaitan antara performa model YOLOv8 yang dihasilkan pada penelitian ini dengan temuan-temuan metodologis dari penelitian sebelumnya dalam konteks pertanian presisi.

Tabel 2. Diskusi Komparatif Hasil Penelitian dengan Studi Terkait

Penelitian	Objek	Model Terbaik	Temuan Utama	Keterkaitan dengan Penelitian Ini
Bektaş (2024) [14]	Pertanian kompleks	YOLOv8s	Varian YOLOv8 berukuran menengah memberikan keseimbangan terbaik antara akurasi dan efisiensi komputasi	Menguatkan pemilihan YOLOv8s sebagai model optimal
Oktapian & Giri (2025) [15]	Buah apel	YOLOv8s	Stabilitas mAP dan precision pada dataset kecil	Konsisten dengan performa YOLOv8s pada dataset 150 citra
Fathurahman & Hanum (2025) [16]	Tomat ceri	YOLOv8s	Konvergensi cepat dengan epoch terbatas	Mendukung konfigurasi 20 epoch yang digunakan
Chen et al. (2024) [17]	Buah melon	YOLOv8-CML	mAP tinggi dan inferensi efisien pada latar belakang kompleks	Menguatkan keunggulan YOLOv8s pada variasi visual kematangan buah

4. KESIMPULAN

Penerapan algoritma deteksi objek berbasis YOLOv8 pada klasifikasi tingkat kematangan buah kelapa sawit memberikan hasil yang signifikan dalam meningkatkan akurasi sistem pemantauan panen. Berdasarkan proses pelatihan dan evaluasi terhadap tiga varian model, penelitian ini memberikan pemahaman yang lebih komprehensif mengenai trade-off antara performa deteksi dan efisiensi komputasi pada masing-masing varian YOLOv8. YOLOv8s (*small*) menunjukkan keunggulan dalam hal kestabilan hasil dan ketepatan identifikasi di berbagai kategori kematangan buah, sehingga dapat disimpulkan sebagai model yang paling adaptif untuk diterapkan pada kondisi operasional perkebunan dengan keterbatasan sumber daya komputasi. Sementara itu, YOLOv8n (*nano*) menawarkan kecepatan tinggi yang dapat bermanfaat dalam aplikasi real-time dengan sumber daya terbatas, dan YOLOv8m (*medium*) cocok digunakan untuk kebutuhan deteksi dengan akurasi maksimal di lingkungan dengan daya komputasi tinggi. Penelitian ini menegaskan bahwa pemilihan model deteksi objek tidak hanya ditentukan oleh tingkat akurasi, tetapi juga harus mempertimbangkan konteks penggunaan, skala data, serta ketersediaan infrastruktur komputasi.

Meskipun demikian, penelitian ini memiliki beberapa keterbatasan, yaitu penggunaan dataset publik dengan jumlah citra yang relatif terbatas. Kondisi tersebut berpotensi memengaruhi generalisasi model ketika dihadapkan pada variasi pencahayaan, latar belakang, dan kondisi cuaca yang lebih kompleks. Sebagai arah penelitian lanjutan, disarankan untuk memperluas jumlah dan variasi dataset melalui akuisisi data lapangan, menerapkan teknik augmentasi lanjutan, serta melakukan pengujian sistem secara real-time pada lingkungan perkebunan kelapa sawit. Selain itu, integrasi sistem deteksi dengan perangkat edge computing atau kamera cerdas juga dapat dieksplorasi untuk meningkatkan kesiapan implementasi di lapangan. Dengan demikian, pendekatan berbasis YOLOv8 tidak hanya berkontribusi secara aplikatif dalam mendukung digitalisasi proses pemanenan kelapa sawit, tetapi juga memberikan kontribusi metodologis dalam pemilihan model deteksi objek yang optimal pada domain pertanian presisi.

DAFTAR PUSTAKA

[1] I. Bonet, M. Gongora, F. Acevedo, and I. Ochoa, “Deep learning model to predict the ripeness of oil palm fruit,” in *Proceedings of the 16th International Conference on Agents and Artificial Intelligence*, SCITEPRESS - Science and Technology Publications, 2024, pp. 1068–1075, DOI: 10.5220/0012434600003636.

[2] S. Ashari, G. J. Yanris, and I. Purnama, “Oil palm fruit ripeness detection using deep learning,” *Sinkron*, vol. 7, no. 2, pp. 649–656, May 2022, DOI: 10.33395/sinkron.v7i2.11420.

[3] F. A. Junior and Suharjito, “Video based oil palm ripeness detection model using deep learning,” *Heliyon*, vol. 9, no. 1, p. e13036, Jan. 2023, DOI: 10.1016/j.heliyon.2023.e13036.

-
- [4] J. W. Lai, H. R. Ramli, L. I. Ismail, and W. Z. Wan Hasan, "Oil palm fresh fruit bunch ripeness detection methods: A systematic review," *Agriculture*, vol. 13, no. 1, p. 156, Jan. 2023, DOI: <https://doi.org/10.3390/agriculture13010156>.
- [5] Z. H. Wong *et al.*, "Palm oil loose fruit detection performance comparison based on deep learning architecture," *Available at SSRN 5252640*, DOI: <http://dx.doi.org/10.2139/ssrn.5252640>.
- [6] W. Cai *et al.*, "Rice growth-stage recognition based on improved {YOLOv8} with {UAV} imagery," *Agronomy (Basel)*, vol. 14, no. 12, p. 2751, Nov. 2024, DOI: <https://doi.org/10.3390/agronomy14122751>.
- [7] A.-R. A. Gamani, I. Arhin, and A. K. Asamoah, "Performance evaluation of {YOLOv8} model configurations, for instance segmentation of strawberry fruit development stages in an open field environment," *arXiv [cs.CV]*, Aug. 2024, DOI: <https://doi.org/10.48550/arXiv.2408.05661>.
- [8] A. Paul, R. Machavaram, Ambuj, D. Kumar, and H. Nagar, "Smart solutions for capsicum Harvesting: Unleashing the power of {YOLO} for Detection, Segmentation, growth stage Classification, Counting, and real-time mobile identification," *Comput. Electron. Agric.*, vol. 219, no. 108832, p. 108832, Apr. 2024, DOI: <https://doi.org/10.1016/j.compag.2024.108832>.
- [9] C. Ren, "Development of a deep learning-based insect recognition system: a comparative analysis of different {YOLO} models," 2025.
- [10] M. Rahevar, N. Shah, H. K. Pathak, and S. M. Patel, "Enhancing small object detection in aerial imagery using {YOLOv8} architecture: A study on small birds detection," in *AIP Conference Proceedings*, AIP Publishing, 2025, p. 30001, DOI: <https://doi.org/10.1063/5.0254155>.
- [11] R. Vaghela *et al.*, "Land cover classification for identifying the agriculture fields using versions of {YOLO} {V8}," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 18, pp. 8672–8684, 2025, doi: 10.1109/JSTARS.2025.3547058.
- [12] B. Hutchinson, N. Rostamzadeh, C. Greer, K. Heller, and V. Prabhakaran, "Evaluation gaps in machine learning practice," in *2022 ACM Conference on Fairness, Accountability, and Transparency*, New York, NY, USA: ACM, Jun. 2022, <https://doi.org/10.1145/3531146.3533233>.
- [13] U. Ali, M. A. Ismail, H. R. A. A., and S. S. R. A., "Performance evaluation of {YOLO} models in plant disease detection," *Journal of Informatics and Web Engineering*, vol. 3, no. 2, pp. 199–211, 2024, DOI: <https://doi.org/10.33093/jiwe.2024.3.2.15>.
- [14] J. Bektaş, "Evaluation of YOLOv8 model series with HOP for object detection in complex agriculture domains," *International Journal of Pure and Applied Sciences*, vol. 10, no. 1, pp. 162–173, 2024, doi: 10.29132/ijpas.1448068, DOI: <https://doi.org/10.29132/ijpas.1448068>.
- [15] I. G. L. A. Oktapian and G. A. M. Giri, "Identifikasi kematangan buah apel menggunakan algoritma YOLOv8," *Jurnal Nasional Teknologi Informasi dan Aplikasinya*, vol. 4, no. 1, pp. 16–27, 2025, DOI: <https://doi.org/10.24843/JNATIA.2025.v04.i01.p16>.
- [16] M. Fathurahman and H. F. Hanum, "Analisis realisasi sistem identifikasi tingkat kematangan buah tomat ceri dengan model YOLOv8 di BBPP Lembang," *Spektral*, vol. 6, no. 1, pp. 311–316, Apr. 2025, DOI: <https://doi.org/10.32722/spektral.v6i1.7544>.
- [17] G. Chen, Y. Hou, T. Cui, H. Li, F. Shangguan, and L. Cao, "YOLOv8-CML: a lightweight target detection method for color-changing melon ripening in intelligent agriculture," *Scientific Reports*, vol. 14, art. no. 14400, 2024, doi: 10.1038/s41598-024-65293-w.