



## Deteksi Tahap Perkembangan Putik Sawit Menggunakan YOLO8n

(*Detection of Palm Oil Pistil Development Stages Using YOLOv8n*)

**Doms Upuy<sup>1\*</sup>, Victor Eric Pattiradjawane<sup>2</sup>**

<sup>1,2</sup> Program Studi Ilmu Komputer, Universitas Pattimura

Jl. Ir. M. Putuhena, Ambon, 97233, Indonesia

Corresponding Author: [doms.upuy@lecturer.unpatti.ac.id](mailto:doms.upuy@lecturer.unpatti.ac.id)

*Manuscript submitted:*  
12<sup>th</sup> November 2025

*Manuscript revision:*  
20<sup>th</sup> November 2025

*Accepted for publication:*  
22<sup>nd</sup> November 2025

### Abstract

Palm Oil productivity is strongly influenced by the success of the pollination process, particularly in female flowers at the anthesis stage, when they are receptive to fertilization. Identification of this stage is generally performed manually, which is inefficient and prone to detection errors in the field. This study proposes an automatic detection system for oil palm female flowers at the receptive stage using the YOLOv8n model, a lightweight variant of the YOLOv8 family that is well suited for CPU-based computation. The dataset consists of three main classes: female flowers, live male flowers, and dead male flowers. The data are divided into training (82%), validation (12%), and testing (6%) sets. Model training is conducted for 80 epochs with an input resolution of 640×640. Evaluation results show that the model achieves an mAP50 of 0.86, a precision of 0.89, and a recall of 0.85. These results indicate that YOLOv8n is capable of accurately detecting receptive female palm oil flowers even under limited computational resources. This system has the potential to serve as a foundation for the development of computer vision-based technologies for monitoring oil palm phenology and pollination.

**Keywords:** Palm Oil; Object Detection; YOLO8n; Deep Learning; Female Flowers



This article is an open access article distributed under the terms and conditions of the [Creative Commons Attribution-ShareAlike 4.0 International License](#).

**How to cite this article:**

D. Upuy, and V.E Pattiradjawane, "Deteksi Tahap Perkembangan Putik Sawit Menggunakan YOLO8n", *algorithm*, vol. 1, no. 2, pp. 69-78, November 2025.

Copyright © 2025  
Journal homepage: <https://ojs3.unpatti.ac.id/index.php/algorithm>  
Research Article [Open Access](#)

## 1. PENDAHULUAN

Deteksi bunga kelapa sawit yang siap penyerbukan menggunakan model YOLOv8n didasarkan pada kemampuan model dalam mengenali ciri-ciri visual spesifik seperti warna, bentuk, ukuran, serta kondisi morfologis bunga jantan maupun betina. Akurasi deteksi sangat bergantung pada kualitas dataset pelatihan yang harus mencakup variasi kondisi lapangan, seperti pencahayaan, sudut pengambilan gambar, dan tingkat occlusion [1], [2]. Dataset yang representatif memungkinkan YOLOv8n mempelajari perbedaan antar fase kematangan bunga secara lebih stabil sehingga model mampu melakukan inferensi yang akurat pada situasi lapangan yang dinamis [3],[4]. Dibandingkan metode tradisional yang mengharuskan inspeksi manual oleh pekerja kebun, pendekatan berbasis YOLOv8n jauh lebih efisien dan akurat. Deteksi manual sering menimbulkan inkonsistensi dan membutuhkan tenaga kerja yang besar, sedangkan YOLOv8n mampu menghasilkan precision dan recall tinggi, bahkan beberapa studi mencapai F1-score lebih dari 99% dalam aplikasi serupa [5]. Selain itu, kecepatan inferensi YOLOv8n yang dapat mencapai sekitar 0.4 detik per gambar memungkinkan penerapan secara real-time pada area perkebunan yang luas, termasuk pada perangkat edge yang mendukung pemantauan berkelanjutan [6].

Implementasi YOLOv8n untuk deteksi bunga siap penyerbukan membawa manfaat besar dalam sektor pertanian, termasuk peningkatan hasil produksi melalui optimasi waktu penyerbukan, pengurangan beban tenaga kerja, dan efisiensi biaya operasional [7],[8]. Teknologi ini juga memperkuat upaya pertanian berkelanjutan karena mampu meminimalkan kesalahan deteksi dan mendukung pengambilan keputusan berbasis data. Meski demikian, tantangan seperti kebutuhan dataset besar, variabilitas lingkungan lapangan, dan kebutuhan komputasi pada perangkat tertentu masih perlu diperhatikan agar sistem dapat bekerja optimal [5],[9],[10].

Selain mengacu pada penelitian sebelumnya, studi ini memberikan kontribusi empiris melalui eksperimen langsung menggunakan model YOLOv8n pada dataset bunga kelapa sawit yang dikumpulkan dari kondisi lapangan. Eksperimen ini menunjukkan bahwa meskipun menggunakan varian YOLO paling ringan dan hanya melakukan pelatihan pada CPU, model tetap mampu mencapai tingkat akurasi yang kompetitif dengan nilai mAP50 sebesar 0.86, precision 0.89, dan recall 0.85. Hasil ini membuktikan bahwa YOLOv8n dapat digunakan sebagai solusi deteksi bunga siap penyerbukan yang efisien dengan kebutuhan komputasi minimal. Temuan ini tidak hanya memperkuat bukti efektivitas YOLOv8n untuk aplikasi pertanian presisi, tetapi juga membuka peluang pemanfaatan teknologi ini pada perangkat edge berbiaya rendah, sehingga dapat mendukung implementasi sistem deteksi otomatis secara luas di perkebunan kelapa sawit.

## 2. METODE PENELITIAN

### 2.1 Desain Penelitian

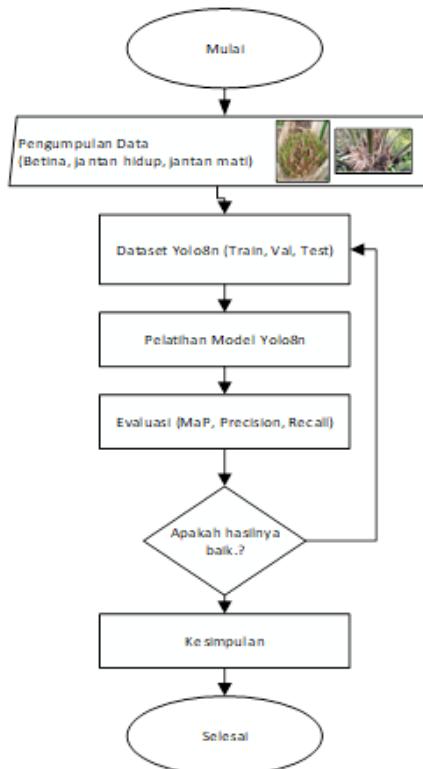
Desain penelitian ini menggunakan pendekatan computer vision berbasis *deep learning* dengan memanfaatkan arsitektur deteksi objek YOLOv8n (Nano). Penelitian difokuskan pada proses identifikasi dan klasifikasi tiga jenis objek bunga kelapa sawit yang merepresentasikan tahapan perkembangan putik, yaitu Bunga Betina, Bunga Jantan Hidup, dan Bunga Jantan Mati. Model YOLOv8n dipilih karena memiliki ukuran yang ringan, kecepatan tinggi, serta efisiensi komputasi yang memungkinkan penerapan pada perangkat dengan spesifikasi terbatas maupun lingkungan *edge computing*. Penelitian dirancang melalui serangkaian proses yang meliputi pengumpulan data lapangan, anotasi objek menggunakan Roboflow, pelatihan model menggunakan arsitektur YOLOv8n, serta evaluasi performa model menggunakan metrik standar seperti mAP, precision, dan recall. Desain penelitian ini diharapkan tidak hanya menghasilkan model deteksi yang akurat, tetapi juga memberikan gambaran awal mengenai pemanfaatan teknologi visi komputer untuk mendukung otomatisasi pemantauan perkembangan putik pada tanaman kelapa sawit.

## 2.2 Dataset

Dataset yang digunakan dalam penelitian ini berasal dari proses pengambilan citra lapangan pada tanaman kelapa sawit, khususnya yang menampilkan objek bunga dalam berbagai tahap perkembangan. Fokus utama dataset terdiri dari tiga kelas objek, yaitu Bunga Betina sebagai indikator putik siap dibuahi (0), Bunga Jantan Hidup (1), dan Bunga Jantan Mati (2). Seluruh citra hasil pengambilan lapangan diolah menggunakan platform Roboflow, yang berfungsi untuk melakukan proses anotasi, augmentasi, serta konversi format agar sesuai dengan kebutuhan pelatihan model YOLO. Secara keseluruhan, dataset berjumlah sekitar 1.137 citra dengan resolusi standar  $640 \times 640$  piksel. Dataset ini kemudian dibagi ke dalam tiga subset untuk mendukung proses pelatihan dan evaluasi model, yaitu train set sebesar 82% (936 citra), validation set sebesar 12% (134 citra), dan test set sebesar 6% (67 citra). Pembagian proporsional ini bertujuan untuk memastikan model mendapatkan data yang cukup untuk belajar, sekaligus menyediakan data validasi dan pengujian untuk mengevaluasi performa model secara lebih objektif terhadap data yang tidak pernah dilihat selama pelatihan.

## 2.3 Tahapan Penelitian

Diagram alir pada Gambar 1, menunjukkan tahapan penelitian untuk mendeteksi perkembangan putik sawit menggunakan YOLOv8n, dimulai dari pengumpulan data citra bunga sawit—meliputi bunga betina, bunga jantan hidup, dan bunga jantan mati, yang kemudian diolah menjadi dataset YOLOv8n dengan pembagian train, validation, dan test. Dataset ini digunakan untuk melatih model YOLOv8n agar mampu mengenali masing-masing kelas bunga, dan setelah proses pelatihan selesai, model dievaluasi menggunakan metrik mAP, precision, dan recall untuk menilai kualitas deteksinya. Jika hasil evaluasi belum memuaskan, penelitian dapat kembali ke tahap sebelumnya untuk perbaikan, namun apabila hasilnya sudah baik, proses dilanjutkan pada penyusunan kesimpulan hingga penelitian dinyatakan selesai.



### Gambar 1. Tahapan Penelitian

### 3. HASIL DAN PEMBAHASAN

Spesifikasi perangkat yang digunakan untuk melakukan training dapat dilihat pada Tabel 1.

**Tabel 1.** Spesifikasi Eksperimen

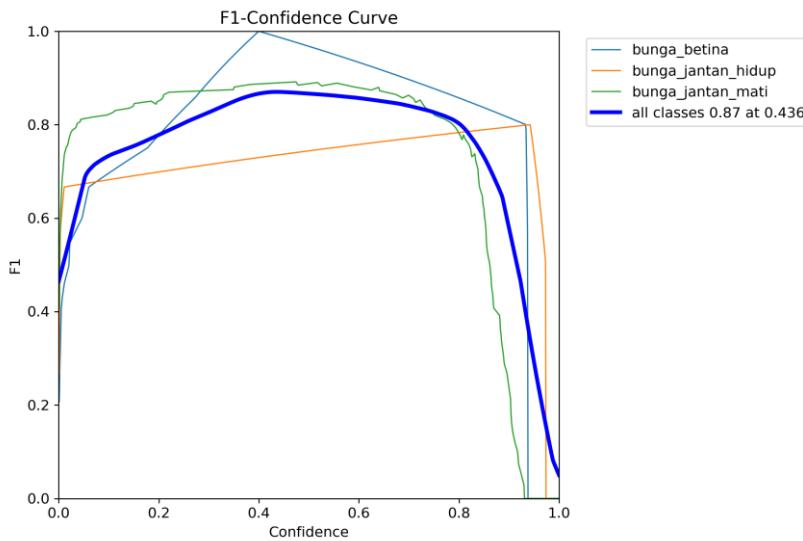
Komponen	Detail
<b>Model</b>	YOLOv8n (Nano)
<b>Jumlah Epoch</b>	80
<b>Batch Size</b>	8
<b>Image Size</b>	640×640 px
<b>Framework</b>	Ultralytics YOLOv8
Komponen	Detail
<b>Perangkat</b>	CPU Intel Core i7-8565U (1.9GHz, tanpa GPU)
<b>Lama Training</b>	±2,5 jam
<b>Dataset Source</b>	Roboflow (versi 8)
<b>Format Dataset</b>	YOLOv8 format (.jpg + .txt)

Setelah proses training selama 80 epoch, model menghasilkan *file best.pt* sebagai model terbaik. Evaluasi dilakukan secara otomatis terhadap dataset validasi dan menghasilkan metrik yang ditunjukkan pada Tabel 2.

**Tabel 2.** Metrik hasil Training

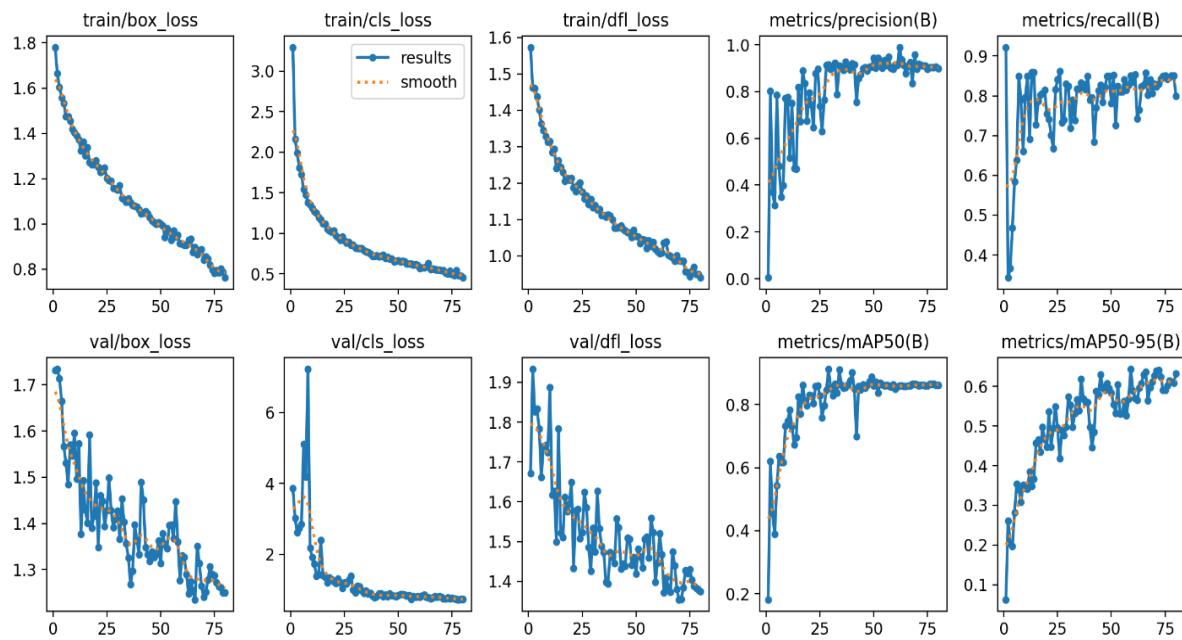
Kelas	Precision	Recall	mAP50	mAP50-95
<b>Bunga Betina</b>	0.977	0.995	0.996	0.766
<b>Bunga Jantan Hidup</b>	0.819	0.667	0.667	0.598
<b>Bunga Jantan Mati</b>	0.909	0.903	0.938	0.598
<b>Rata-rata (semua kelas)</b>	<b>0.897</b>	<b>0.851</b>	<b>0.864</b>	<b>0.644</b>

Setelah proses pelatihan selama 80 epoch menggunakan YOLOv8 dengan ukuran citra 640×640 piksel dan batch size 8, model berhasil menghasilkan *best.pt* sebagai model dengan performa terbaik berdasarkan evaluasi otomatis pada dataset validasi. Pelatihan dilakukan tanpa GPU menggunakan prosesor Intel Core i7-8565U sehingga membutuhkan waktu sekitar ±2,5 jam. Hasil evaluasi menunjukkan bahwa model mampu mendeteksi tiga kelas utama bunga sawit dengan performa yang cukup baik, ditandai dengan nilai rata-rata precision sebesar 0,897, recall 0,851, mAP50 sebesar 0,864, dan mAP50-95 sebesar 0,644. Secara khusus, kelas Bunga Betina memiliki performa tertinggi dengan mAP50 mencapai 0,996, diikuti oleh Bunga Jantan Mati dengan mAP50 sebesar 0,938, sementara Bunga Jantan Hidup menunjukkan performa yang lebih rendah. Temuan ini menggambarkan bahwa model YOLOv8n mampu mengenali objek bunga sawit dengan akurasi tinggi meskipun dilatih pada perangkat komputasi terbatas.



Gambar 2. F1-Confidence Curve

Pada Gambar 2 dapat dilihat bahwa hubungan antara nilai confidence dan skor F1 untuk masing-masing kelas objek bunga sawit, yaitu bunga betina, bunga jantan hidup, dan bunga jantan mati. Terlihat bahwa kelas bunga betina dan bunga jantan mati memiliki kurva yang lebih stabil dan mencapai nilai F1 yang lebih tinggi dibandingkan kelas bunga jantan hidup, yang menunjukkan performa deteksi yang lebih baik pada dua kelas tersebut. Sementara itu, garis tebal biru yang merepresentasikan rata-rata seluruh kelas menunjukkan nilai F1 tertinggi sebesar 0.87 pada confidence 0.436, yang berarti bahwa pada nilai confidence sekitar 0.43 model mencapai keseimbangan terbaik antara precision dan recall. Kurva ini memberikan gambaran bahwa secara umum model bekerja optimal pada nilai confidence menengah, dan performa per kelas masih bervariasi terutama pada kelas bunga jantan hidup yang memerlukan peningkatan.

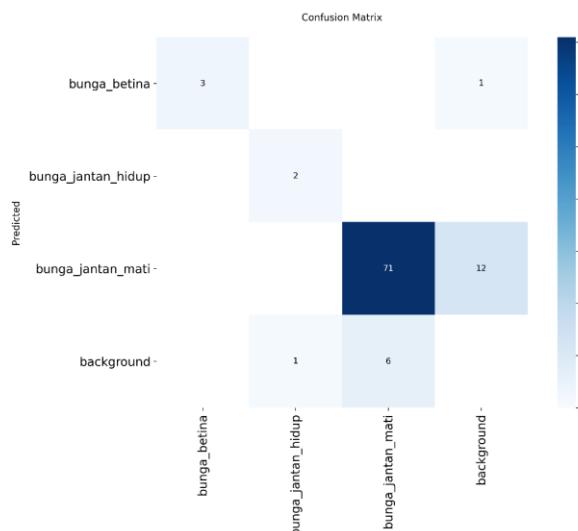


Gambar 3. Kinerja model YOLOv8n

Gambar 3 menampilkan ringkasan proses pelatihan dan evaluasi model YOLOv8n selama 80 epoch yang direpresentasikan melalui sepuluh grafik utama. Pada baris pertama, grafik train/box\_loss, train/cls\_loss, dan train/dfl\_loss menunjukkan penurunan nilai loss yang konsisten seiring bertambahnya epoch. Hal ini mengindikasikan bahwa model semakin baik dalam mempelajari lokasi bounding box, klasifikasi kelas, serta distribusi fitur objek bunga sawit. Selain itu, grafik metrics/precision dan metrics/recall memperlihatkan tren peningkatan yang relatif stabil, menandakan bahwa kemampuan model dalam menghasilkan prediksi yang tepat dan mendeteksi objek yang relevan terus membaik selama proses pelatihan.

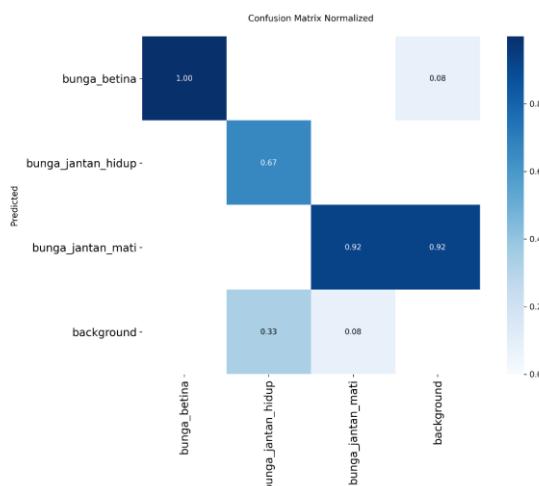
Pada baris kedua dari gambar tersebut menunjukkan grafik val/box\_loss, val/cls\_loss, dan val/dfl\_loss menunjukkan kecenderungan penurunan dan stabilisasi nilai loss pada data validasi. Kondisi ini menunjukkan bahwa model tidak hanya belajar dengan baik pada data pelatihan, tetapi juga mampu melakukan generalisasi yang cukup baik terhadap data yang tidak dilihat sebelumnya. Meskipun terdapat fluktuasi kecil pada beberapa epoch awal, pola keseluruhan grafik validasi mengindikasikan tidak adanya gejala overfitting yang signifikan, sehingga model dinilai cukup stabil dan konsisten.

Selanjutnya, grafik metrics/mAP50 dan metrics/mAP50-95 menunjukkan peningkatan performa deteksi yang cukup signifikan hingga mencapai kondisi konvergen pada epoch-epoch akhir. Nilai mAP50 yang relatif tinggi mengindikasikan bahwa model mampu mendeteksi objek bunga sawit dengan baik pada ambang IoU standar, sedangkan peningkatan mAP50-95 menunjukkan kemampuan model dalam mempertahankan akurasi pada ambang IoU yang lebih ketat. Secara keseluruhan, rangkaian grafik ini membuktikan bahwa proses pelatihan YOLOv8n berjalan efektif dan menghasilkan model deteksi yang akurat serta stabil untuk mendukung identifikasi tahap perkembangan putik sawit.



Gambar 4. Confusion matrix

Gambar 4 tentang *confusion matrix* menunjukkan kinerja klasifikasi model YOLOv8n dalam mendeteksi tiga kelas objek bunga kelapa sawit, yaitu bunga betina, bunga jantan hidup, dan bunga jantan mati, beserta kelas latar belakang (*background*). Terlihat bahwa prediksi untuk kelas bunga jantan mati memiliki jumlah benar (*true positive*) paling tinggi, yaitu sebanyak 71 data, yang menunjukkan bahwa model sangat baik dalam mengenali karakteristik visual kelas ini. Namun demikian, masih terdapat sejumlah kesalahan prediksi, khususnya pada kelas *background* yang keliru diprediksi sebagai bunga jantan mati sebanyak 12 kasus, serta beberapa objek bunga jantan hidup yang tidak terdeteksi dan masuk ke kelas *background*. Kondisi ini mengindikasikan bahwa meskipun model memiliki performa yang kuat pada kelas dominan, terdapat tantangan dalam membedakan objek dengan ciri visual yang mirip atau objek berukuran kecil. Secara keseluruhan, confusion matrix ini memberikan gambaran yang jelas mengenai kekuatan dan kelemahan model, serta menjadi dasar penting untuk perbaikan dataset dan optimasi model pada penelitian lanjutan.



Gambar 5. Confusion\_matrix\_normalized

Confusion Matrix Normalized pada gambar 5 memberikan gambaran proporsional mengenai kinerja klasifikasi model YOLOv8n untuk setiap kelas objek bunga kelapa sawit, yaitu bunga betina, bunga jantan hidup, bunga jantan mati, dan background. Nilai diagonal utama merepresentasikan tingkat prediksi benar untuk masing-masing kelas. Terlihat bahwa kelas bunga betina memiliki nilai normalisasi sebesar 1.00, yang menunjukkan bahwa seluruh objek bunga betina pada data uji berhasil terdeteksi dengan benar oleh model tanpa adanya kesalahan klasifikasi. Hal ini menandakan bahwa ciri visual bunga betina memiliki keunikan yang kuat sehingga mudah dipelajari oleh model.

Pada kelas bunga jantan mati, nilai normalisasi yang tinggi, yaitu 0.92, menunjukkan tingkat akurasi yang sangat baik dalam mengenali kelas tersebut. Namun demikian, masih terdapat sebagian kecil kesalahan, terutama pada objek background yang keliru diklasifikasikan sebagai bunga jantan mati, yang tercermin dari nilai 0.08 pada kolom background. Sementara itu, kelas bunga jantan hidup memiliki nilai normalisasi sebesar 0.67, yang mengindikasikan bahwa sekitar sepertiga objek pada kelas ini masih mengalami kesalahan prediksi, terutama terklasifikasi sebagai background. Kondisi ini menunjukkan bahwa karakteristik visual bunga jantan hidup cenderung lebih bervariasi dan memiliki kemiripan dengan elemen latar belakang di lingkungan perkebunan.

Secara keseluruhan, Confusion Matrix Normalized ini menegaskan bahwa model YOLOv8n memiliki performa sangat baik pada kelas bunga betina dan bunga jantan mati, namun masih memiliki tantangan dalam membedakan bunga jantan hidup dari background. Temuan ini menjadi dasar penting bagi pengembangan penelitian selanjutnya, khususnya dalam peningkatan kualitas dan kuantitas dataset untuk kelas bunga jantan hidup, serta penerapan teknik augmentasi atau penyesuaian parameter model agar kemampuan diskriminasi antar kelas dapat ditingkatkan secara lebih optimal.

Sedangkan pada Gambar 6 menampilkan contoh hasil prediksi model YOLOv8n terhadap tiga kelas objek bunga kelapa sawit, yaitu bunga betina, bunga jantan hidup, dan bunga jantan mati. Setiap objek berhasil terdeteksi dengan bounding box berwarna berbeda serta nilai confidence yang cukup tinggi, seperti bunga betina dengan confidence 0.9, bunga jantan hidup 0.9, dan bunga jantan mati 0.8. Hasil ini menunjukkan bahwa model mampu mengenali karakteristik visual dari masing-masing kelas.



**Gambar 6.** Hasil prediksi model YOLOv8n

#### 4. KESIMPULAN

Penelitian ini berhasil mengembangkan dan mengevaluasi model deteksi objek berbasis YOLOv8n untuk mengidentifikasi tiga kelas utama bunga kelapa sawit, yaitu bunga betina, bunga jantan hidup, dan bunga jantan mati. Berdasarkan proses pelatihan selama 80 epoch menggunakan dataset lapangan yang telah dianotasi melalui Roboflow, model menunjukkan performa yang cukup baik dengan rata-rata precision sebesar 0.897, recall 0.851, mAP50 mencapai 0.864, dan mAP50–95 sebesar 0.644. Hasil evaluasi melalui confusion matrix serta kurva F1-Confidence menunjukkan bahwa model mampu mendeteksi bunga betina dan bunga jantan mati dengan akurasi tinggi, meskipun performa pada kelas bunga jantan hidup masih perlu ditingkatkan akibat variasi bentuk dan kondisi visual yang lebih kompleks. Visualisasi hasil prediksi pada citra lapangan memperlihatkan bahwa model dapat memberikan bounding box yang konsisten dengan tingkat confidence tinggi. Secara keseluruhan, penelitian ini membuktikan bahwa YOLOv8n mampu menjadi solusi efektif dan ringan untuk mendukung otomatisasi pemantauan tahap perkembangan putik sawit.

#### SARAN

Penelitian selanjutnya disarankan untuk menambah jumlah dataset terutama pada kelas bunga jantan hidup yang memiliki performa deteksi lebih rendah. Penambahan variasi citra dalam kondisi pencahayaan berbeda, sudut pengambilan, serta tingkat kematangan bunga yang beragam dapat meningkatkan generalisasi model dan mengurangi kesalahan prediksi pada kondisi lapangan yang kompleks.

#### REFERENSI

- [1] R. R. Hutapea, E. Fransisca, A. Sihotang, and E. Irwansyah, "Palm Fruit Ripeness Detection and Counting Using YOLOv8 Algorithm in PTPN IV Medan North Sumatera Indonesia," *2024 6th Int. Conf. Cybern. Intell. Syst.*, pp. 1–6, 2020.
- [2] A. K. Chowdhury *et al.*, "Comparative Study of Different YOLO Variants for Ripeness Detection of Palm Oil Fresh Fruit Bunches," *2025 IEEE 6th Int. Conf. Robot. Manuf. Autom.*, no. August, pp. 18–23, 2025.
- [3] A. Septiarini, A. Oktavia, H. R. Hatta, A. A. Kasim, H. Hamdani, and S. Suyanto, "Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach," pp. 12–15.
- [4] F. A. Junior, Y. P. Koeswandy, P. W. Nurhayati, and M. Asrol, "Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading Using Deep Learning," pp. 1–9, 2023.
- [5] I. Sonata and Y. Arifin, "Deep Learning Approach for Palm Fruit Ripeness Classification Using MobileNet," *2025 4th Int. Conf. Creat. Commun. Innov. Technol.*, pp. 1–7, 2025.
- [6] M. G. Naftali, "Palm Oil Counter : State-of-the-Art Deep Learning Models for Detection and Counting in Plantations," *IEEE Access*, vol. 12, no. June, pp. 90395–90417, 2024.
- [7] M. Mohd, N. Hashim, A. Shahid, and A. Hamid, "Combination of laser-light backscattering imaging and computer vision for rapid determination of oil palm fresh fruit bunches maturity," *Comput. Electron. Agric.*, vol. 169, no. November 2019, p. 105235, 2020.
- [8] N. Srithai, W. Lee, and V. Sa-ing, "Ripeness Classification of Fresh Oil Palm Using Deep Learning," *2025 13th Int. Electr. Eng. Congr.*, no. 3, pp. 1–5, 2025.
- [9] Y. Alvin, A. D. I. Soetrisno, E. K. O. Handoyo, and E. W. Sinuraya, "OIL PALM LEVEL OF RIPENESS CLASSIFICATION USING EFFICIENTDET-LITE CNN ARCHITECTURE," vol. 36, no. December, pp. 618–629, 2024.
- [10] M. Naghipour and L. S. Ling, "YOLO-Based Oil Palm FFB Ripeness Detection," *2024 Int. Conf.*

*Electr. Commun. Comput. Eng.*, no. October, pp. 1–5, 2024.