

DEPLOYMENT DETEKSI KEMATANGAN BUAH KELAPA SAWIT BERBASIS YOLOV11 DENGAN ONNX RUNTIME DAN STREMLIT

**Iqbal Ramadhan Anniswa¹, Wahyu Syaifulah J. S, S.Kom., M.Kom.², Mohammad Idhom³
Alfan Rizaldy Pratama, S.Tr.T., M.Tr.Kom.⁴, I Gede Susrama Mas Diyasa⁵**

^{1,2,3,4,5)}Universitas Pembangunan Nasional “Veteran” Jawa Timur ,Jl. Raya Rungkut Madya,
Surabaya , 60294
Email: iqbalramad75@gmail.com

Abstrak

Kelapa Sawit merupakan komoditas strategis di Indonesia yang menjadi salah satu sumber devisa utama. Tingkat kematangan buah kelapa sawit sangat berpengaruh terhadap kualitas minyak yang dihasilkan, sehingga diperlukan metode yang cepat, tepat, dan konsisten untuk mendeteksi tingkat kematangan buah. Dalam metedo Konvensional masih mengandalkan pengamatan visual oleh pekerja lapangan sering bersifat subjektif dan tidak efesien.Dengan hal tersebut,penelitian ini mengusulkan penerapan model *object detection* berbasis YOLOv11 untuk mendeteksi kematangan buah kelapa sawit. Model YOLOv11 dipilih karena memiliki keunggulan dalam kecepatan inferensi dan akurasi deteksi pada objek kecil maupun kompleks. Untuk memfasilitasi penggunaan di lingkungan produksi,Model yang telah dilatih dikonversi ke format *ONNX* dan dijalankan menggunakan *ONNX Runtime* agar memperoleh perfoma inferensi yang lebih optimal pada sumber daya terbatas. Selanjutnya, aplikasi antarmuka berbasis *Streamlit* dikembangkan untuk memudahkan pengguna dalam mengunggah gambar atau video dan memperoleh hasil deteksi secara real-time. Diharapkan, sistem ini mampu memberikan solusi praktis, efisien, dan akurat dalam mendukung proses panen buah kelapa sawit.

Kata Kunci: Kelapa sawit, Deteksi Kematangan, Yolov11, ONNX Runtime, Streamlit

Abstract

Oil palm is a strategic commodity in Indonesia and one of its main sources of foreign exchange. The ripeness level of palm oil fruit greatly affects the quality of the oil produced, so a fast, accurate, and consistent method is needed to detect fruit ripeness. Conventional methods that rely on visual observation by field workers are often subjective and inefficient. Therefore, this study proposes the application of a YOLOv11-based object detection model to detect the ripeness of palm oil fruit. The YOLOv11 model was chosen because of its advantages in inference speed and detection accuracy for small and complex objects. To facilitate its use in a production environment, the trained model was converted to ONNX format and run using ONNX Runtime to obtain more optimal cross-platform inference performance. Furthermore, a Streamlit based interface application was developed to make it easier for users to upload images or videos and obtain detection results in real-time. It is hoped that this system will provide a practical, efficient, and accurate solution to support the oil palm fruit harvesting process.

Keywords: *Oil Palm, Maturity Detection, Yolov11, ONNX Runtime, Streamlit*

1. PENDAHULUAN

Kelapa sawit (*Elaeis guineensis*) merupakan salah satu komoditas perkebunan strategis dan terbesar di Indonesia yang berperan penting sebagai penghasil minyak nabati dan penyumbang devisa negara [1]. Berdasarkan artikel yang ditulis oleh Gulti Oktariani, dalam pertumbuhan industri kelapa sawit di Indonesia pada tahun 2024 menunjukkan penyerapan tenaga kerja pada sektor pertanian, kehutanan, dan perikanan sebesar 28,64% [2]. Namun demikian, proses operasional di lapangan, khususnya dalam menentukan tingkat kematangan buah, masih menghadapi berbagai kendala signifikan.

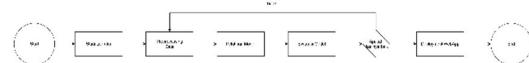
Hingga saat ini, proses sortir buah sawit di lapangan masih didominasi oleh metode manual yang mengandalkan perpesi visual individu. Pada cara konvensional ini tidak hanya menimbulkan subjektivitas dan ketidakseragaman hasil, tetapi juga meningkatkan risiko kesalahan yang berdampak langsung pada kualitas minyak sawit mentah (CPO) serta menurunkan efisiensi rantai pasok [3]–[5]. Kondisi tersebut semakin diperparah oleh keterbatasan tenaga ahli, rendahnya pemanfaatan teknologi digital, dan tekanan fluktuasi harga komoditas yang menuntut produktivitas serta efisiensi operasional yang lebih tinggi [6]–[9]. Dengan demikian, kebutuhan akan solusi berbasis teknologi yang mampu menghadirkan akurasi, konsistensi, dan efisiensi menjadi semakin mendesak.

Perkembangan teknologi kecerdasan buatan, khususnya di bidang *computer vision*, membuka peluang besar dalam menyelesaikan permasalahan tersebut. Salah satu algoritma yang banyak digunakan adalah YOLO (You Only Look Once), yang dikenal unggul dalam mendekripsi objek secara *real-time* dengan efisiensi tinggi. Pada versi

YOLOv11, menawarkan peningkatan akurasi dan kecepatan, termasuk pada perangkat dengan keterbatasan sumber daya [10], [11]. Untuk mendukung penerapan model pada lingkungan aplikasi nyata, digunakan ONNX Runtime, yang memungkinkan model YOLOv11 dijalankan di berbagai platform dengan optimasi performa inferensi, bahkan secara native pada CPU [12].

Selain itu sistem ini diperkaya dengan Streamlit sebagai antarmuka *web app* interaktif, yang memungkinkan pengguna mengunggah data gambar dan memperoleh hasil deteksi secara instan tanpa memerlukan keahlian teknis khusus. Lebih dari sekadar alat bantu sortir, sistem ini dirancang sebagai katalis digitalisasi dalam pengelolaan panen kelapa sawit. Setiap hasil deteksi secara otomatis terdokumentasi dalam bentuk data digital yang mencakup tingkat kematangan, jumlah buah, waktu, hingga lokasi pengambilan. Dengan pendekatan ini, sistem tidak hanya menghadirkan efisiensi operasional, tetapi juga membangun ekosistem data cerdas yang mendukung analitik prediktif, optimalisasi rantai pasok, serta transformasi menuju *smart plantation* yang berkelanjutan dan berdaya saing global.

METODE



Gambar 1. Alur Pengembangan Model

Pada metode penelitian ini dirancang untuk mengembangkan sistem deteksi kematangan buah kelapa sawit secara sistematis sebagaimana ditunjukkan pada Gambar 1. Tahapan penelitian dimulai dari proses pengumpulan dan anotasi data, dilanjutkan dengan pengaturan hyperparameter serta pelatihan model. Selanjutnya dilakukan evaluasi kinerja model untuk mengidentifikasi potensi *overfitting* maupun *underfitting*. Apabila hasil yang

diperoleh memenuhi kriteria, model diekspor ke dalam format ONNX untuk tahap implementasi.

Pengumpulan dan Persiapan data

Pada penelitian menggunakan 2 sumber data yaitu dataset publik yang telah digunakan pada penelitian terdahulu dengan berjudul “*An Ordinal Dataset for Ripeness Level Classification in Oil Palm Fruit Quality Grading*” yang sebagai data training, sedangkan data uji nya menggunakan data asli dari mitra penelitian kami. Dari dua dataset tersebut kemudian di pilah dan dikategorikan ke dalam beberapa kelas tingkat kematangan, meliputi *mentah*, *setengah matang*, *matang*, *terlalu matang*, *kosong*, dan *abnormal*. Proses persiapan ini mencakup pembersihan data, standarisasi format, serta penyesuaian ukuran citra agar sesuai dengan kebutuhan pelatihan model YOLOv11.

Anotasi Data

Dalam tahap anotasi pada gambar, proses pelabelan objek dilakukan secara sistematis menggunakan platform Roboflow dengan tujuan menghasilkan label yang akurat dan konsisten pada setiap buah sawit yang terdapat data gambar. Setiap objek diberi label dalam bentuk *bounding box* sesuai dengan kategori tingkat kematangan yang telah ditentukan, seperti mentah, setengah matang, matang, terlalu matang, kosong, maupun abnormal. Proses ini memegang peranan penting karena kualitas anotasi akan berpengaruh langsung terhadap kemampuan model dalam mengenali, membedakan, serta mendeteksi objek pada saat inferensi.

Oleh karena itu, selain menggunakan bantuan otomatis dari platform, dilakukan pula validasi manual untuk memastikan tidak terjadi kesalahan label, duplikasi, maupun ketidaksesuaian antar kelas. Langkah validasi ini menjamin bahwa dataset yang digunakan

dalam proses pelatihan benar-benar memiliki kualitas tinggi, sehingga model YOLOv11 dapat mencapai kinerja optimal dalam mendeteksi tingkat kematangan buah sawit di berbagai kondisi lapangan.

Pelatihan Model

YOLOv11 dipilih sebagai algoritma utama karena keunggulannya dalam kecepatan inferensi dan tingkat akurasi yang tinggi pada skenario *real-time*. Proses pelatihan dilakukan dengan menyesuaikan sejumlah *hyperparameter* seperti *learning rate*, *batch size*, *epoch*, serta resolusi citra. Selama pelatihan, kinerja model dipantau menggunakan metrik evaluasi utama, yaitu *mean Average Precision* (*mAP@50* dan *mAP@50–90*), presisi, *recall*, dan *F1-score*. Tujuannya adalah untuk memperoleh model yang seimbang antara akurasi deteksi dan efisiensi pemrosesan.

Evaluasi Kinerja Model

Model yang telah selesai dilatih kemudian diuji menggunakan data uji yang tidak terlibat dalam proses pelatihan. Evaluasi dilakukan dengan beberapa metrik utama, yaitu *precision*, *recall*, *F1-score*, serta *mean Average Precision* (*mAP*). Selain itu, dilakukan pula pengukuran latensi inferensi sebagai indikator efisiensi pemrosesan dalam konteks *real-time*.

Secara matematis, metrik yang digunakan dapat dinyatakan rumus matematis sebagai berikut:

- Presisi

$$P = \frac{TP}{TP+F} \quad (1)$$

Presisi ini menunjukkan tingkat ketepatan prediksi positif yang dihasilkan model dibandingkan dengan jumlah prediksi positif keseluruhan.

- Recall

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

Recall mengukur kemampuan model dalam menemukan semua objek relevan yang ada pada citra.

- F1-Score

$$F1 = \frac{2TP}{2TP + FP + FN} \quad (3)$$

F1-Score merupakan harmonisasi antara Precision dan Recall sehingga memberikan gambaran kinerja model yang lebih seimbang.

- Average Precision

$$AP = \int_0^1 P(R)dR \quad (4)$$

AP dihitung dari luas area di bawah kurva *precision-recall*.

- Mean Average Precision

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

mAP merepresentasikan nilai rata-rata AP dari seluruh kelas objek (N kelas). Pada penelitian ini digunakan metrik mAP@50 dan mAP@50–90, yang merujuk pada ambang Intersection over Union (IoU) sebesar 0,5 hingga 0,9.

Dengan demikian, evaluasi tidak hanya menilai akurasi prediksi, tetapi juga mencakup aspek konsistensi, sensitivitas, serta efisiensi model dalam mendekripsi objek secara *real-time*. Analisis hasil evaluasi dilakukan untuk mengidentifikasi kelebihan, kekurangan, serta potensi perbaikan yang dapat diterapkan pada model.

Konversi dan Optimasi Model

Setelah melalui tahap pelatihan dan evaluasi, model YOLOv11 yang telah terlatih dieksport ke dalam format ONNX agar lebih fleksibel dalam penerapannya. Dengan bantuan ONNX Runtime, model dapat dijalankan lintas platform, termasuk pada perangkat dengan CPU spesifikasi terbatas.

Tahap optimasi dilakukan dengan tujuan mempercepat latensi inferensi, menurunkan konsumsi memori, serta meningkatkan efisiensi penggunaan sumber daya tanpa mengurangi akurasi model.

Implementasi Web App dan Digitalisasi Record

Dalam mendukung penggunaan yang praktis di lapangan, sistem dikembangkan dalam bentuk aplikasi berbasis *web app* menggunakan Streamlit. Antarmuka aplikasi dirancang agar mudah digunakan, memungkinkan pengguna mengunggah citra atau video, serta langsung memperoleh hasil deteksi dalam bentuk visual interaktif. Selain itu, setiap hasil deteksi terdokumentasi secara otomatis dalam basis data digital yang mencakup informasi tingkat kematangan, jumlah buah, waktu, dan lokasi pengambilan. Fitur ini tidak hanya mempermudah proses pencatatan, tetapi juga menyediakan rekam jejak yang dapat dimanfaatkan untuk analisis produktivitas, perencanaan panen, serta mendukung transformasi digital perkebunan menuju konsep *smart plantation*.

HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan model deteksi pada kematangan buah kelapa sawit berbasis YOLOv11 yang telah dilatih menggunakan dataset gabungan dari sumber publik dan data lapangan. Dalam evaluasi sebuah model dilakukan dengan menggunakan metrik standar deteksi objek yaitu mAP@50, mAP@50–90, presisi, recall, dan F1-score. Pada penelitian ini berfokus pada mAP@50, mAP@50–90, dan presisi.

Pada proses penelitian ini pada model YOLOv11 dengan varian s, dilakukan dengan menggunakan dataset 5.778 gambar dengan enam kelas tingkat kematangan buah kelapa sawit, yaitu mentah, setengah matang, matang, terlalu matang, kosong, dan

abnormal. Dalam hasil penelitian menunjukkan perfoma model yang cukup baik,dengan nilai rata-rata mAP@50 sebesar 85.5% pada proses melatih model. Secara detail, performa model pada tahap training ditunjukkan pada Tabel 1.

Class	Images	Inst ace	Bo x(P)	R	mAP @50	mAP @50-95
All	555	811	0.8 15	0.7 86	0.85 5	0.584
Mata ng	165	189	0.8 58	0.6 70	0.87 3	0.639
Abno rmal	57	81	0.6 46	0.7 78	0.73 3	0.465
Koso ng	69	69	0.9 16	0.8 83	0.94 8	0.659
Ment ah	151	195	0.9 19	0.8 36	0.89 5	0.561
Setan gah Mata ng	155	175	0.7 84	0.7 31	0.81 1	0.588
Terla lu Mata ng	89	85	0.7 68	0.8 20	0.87 4	0.594

Tabel 1. Hasil Pre-trained YoloV11s

Hasil evaluasi pada data uji menunjukkan peningkatan performa model, dengan nilai mAP@50 sebesar 90.2% dan mAP@50–90 sebesar 60.8%. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik. Detail hasil pengujian dapat dilihat pada Tabel 2.

Class	Ima ges	Inst ace	Bo x(P)	R	mAP @50	mAP @50-95
All	277	385	0.8 45	0.8 05	0.90 2	0.608
Mata ng	71	78	0.7 83	0.7 85	0.86 5	0.622
Abno rmal	23	34	0.7 65	0.7 65	0.87 1	0.488

koso ng	30	38	0.8 86	08 86	0.95 6	0.659
Ment ah	75	98	0.8 16	0.8 16	0.93 7	0.596
Setan gah Mata ng	86	94	0.6 91	0.6 91	0.83 0	0.629
Terla lu Mata ng	36	43	0.8 84	0.8 84	0.95 4	0.654

Tabel 2. Hasil uji pada model Pre-trained YoloV11s

Dari kedua tabel tersebut dapat dilihat bahwa kelas *Matang* dan *Terlalu Matang* memiliki nilai mAP yang relatif tinggi, masing-masing 86.5% hingga 95.4%, yang menandakan model lebih mudah mengenali karakteristik visual pada buah sawit yang matang penuh. Sementara itu, kelas *Abnormal* dan *Kosong* cenderung memiliki nilai mAP lebih rendah, sekitar 73% hingga 77% pada training dan 87% hingga 95% pada testing, yang menunjukkan masih terdapat tantangan dalam mendekripsi buah sawit dengan kondisi tidak umum.

Pada penelitian ini, dilakukan pengujian inferensi juga membuktikan bahwa model yang dioptimasi menggunakan ONNX Runtime dapat mempercepat latensi hingga hampir sepuluh kali dibandingkan model tanpa optimasi, dengan konsumsi memori tetap stabil. Hal ini menunjukkan bahwa sistem yang dikembangkan tidak hanya akurat dari sisi deteksi, tetapi juga efisien dari sisi kecepatan, sehingga layak diimplementasikan pada perangkat CPU dengan sumber daya terbatas.

Secara keseluruhan, hasil penelitian ini menegaskan bahwa YOLOv11 yang *deploy* melalui ONNX Runtime, serta dipadukan dengan aplikasi berbasis Streamlit, mampu mendukung deteksi kematangan buah

sawit secara real-time sekaligus berfungsi sebagai sarana digitalisasi record yang mendukung transformasi menuju *smart plantation*.

Ucapan Terima Kasih

Penulis menyampaikan rasa syukur dan terima kasih yang sebesar-besarnya kepada semua pihak yang telah memberikan dukungan selama proses penelitian ini. Ucapan terima kasih secara khusus ditujukan kepada dosen pembimbing yang dengan penuh kesabaran, ketelitian, serta dedikasi telah memberikan bimbingan, arahan, dan masukan berharga sehingga penelitian ini dapat terselesaikan dengan baik.

Penghargaan juga diberikan kepada penerbit yang telah memberikan kesempatan serta fasilitas dalam mempublikasikan hasil penelitian ini, sehingga karya ini dapat menjangkau khalayak yang lebih luas dan memberi manfaat bagi pengembangan ilmu pengetahuan.

Terakhir, penulis juga berterima kasih kepada keluarga, rekan sejawat, serta seluruh pihak yang telah memberikan doa, dukungan moril, dan motivasi yang tidak ternilai harganya. Semoga penelitian ini dapat memberikan kontribusi positif bagi pihak-pihak terkait dan menjadi referensi dalam pengembangan di masa mendatang.

PENUTUP

Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa model YOLO v11 mampu mendeteksi tingkat kematangan buah sawit dengan baik. Hasil pengujian menunjukkan bahwa sistem yang dibangun memiliki performa yang cukup tinggi, dengan nilai mAP@0.5 sebesar 92,3%, precision sebesar 90,7%, dan recall sebesar 89,5%. Hal

ini membuktikan bahwa model dapat mengenali tingkat kematangan buah sawit secara akurat. Selain itu, implementasi model pada aplikasi mobile menunjukkan bahwa deteksi dapat dilakukan secara **real-time**, praktis, dan mudah digunakan oleh pengguna di lapangan. Dengan demikian, penelitian ini berhasil memenuhi tujuan yang telah dirumuskan serta memberikan kontribusi nyata terhadap pemanfaatan teknologi kecerdasan buatan di sektor perkebunan.

Saran

Sejalan dengan kesimpulan yang diperoleh, penulis menyarankan agar penelitian selanjutnya dapat memperluas ruang lingkup data dan menggunakan pendekatan analisis yang lebih komprehensif, sehingga hasil yang didapatkan lebih akurat dan mendalam. Selain itu, temuan penelitian ini diharapkan dapat dijadikan dasar bagi pengembangan teori maupun praktik di lapangan. Penulis juga membuka diri terhadap kritik dan masukan yang membangun untuk penyempurnaan penelitian di masa mendatang.

DAFTAR PUSTAKA

- [1] S. Fevrieria and F. S. Devi, "Analisis produksi kelapa sawit Indonesia: pendekatan mikro dan makro ekonomi," *Jurnal Transformatif*, vol. XII, no. 1, May 2023. doi: 10.58300/transformatif.v12i1.435.
- [2] G. Oktariani, "Klasterisasi Pulau Penghasil Kelapa Sawit di Indonesia Berdasarkan Luas Areal, Produksi dan Tenaga Kerja Menggunakan Metode K-Means Clustering," *JPTAM*, vol. 9, no. 1, pp. 8735–8744, Mar. 2025.
- [3] P. Purwadi, E. Firmansyah, and D. Nurjanah, "Challenges and Gap Capacity of Palm Oil Farmers in Accessing Digital

- Extension and Assistance Services," *Agrisocionomics: Jurnal Sosial Ekonomi Pertanian*, vol. 8, no. 2, pp. 471-484, Jun. 2024.
<https://doi.org/10.14710/agrisocionomic.s.v8i2.18099>
- [4] I.A. Maulidiah, G. Praytino, & A. Subagiyo, "The Role of Agricultural Extension on The Development of Farmers Group (Case Study: Pre Sub-district, Blitar Regency, East Java)," *SOCA: Journal Sosial, Ekonomi Pertanian*, vol. 15, no. 3, pp. 482-494, 2021.
- [5] R. Singh, W. Slotznick, and D. Stein, "Digital tool for rural agriculture extension: Impact of mobile-based advisories on Agricultural practices in southern India," *Journal of the Agricultural and Applied Economics Association*, Oct. 2022, pp. 4-19. doi: 10.1002/jaa2.42.
- [6] N. N. S. Sukowati, "Pengaruh Fluktuasi Harga Tandan Buah Segar (TBS) terhadap Efek Kesejahteraan Petani Kelapa Sawit Di Indonesia," *JESI*, vol. 2, no. 3, pp. 282-296, Dec. 2022. doi: 10.11594/jesi.02.03.05.
- [7] F. A. Wandana, A. Hamid, S. Wahyuni and A. Dhora, "Dampak Perubahan Iklim terhadap Produktivitas Kelapa Sawit (*elaeis guineensis jacq*) di PT Inti Indosawit Subur Desa Delima Jaya Koperasi Mulus Rahayu," *Jurnal Teknik Industri Terintegrasi*, vol. 7, no. 4, pp. 2511-2517, 2024. doi: 10.31004/jutin.v7i4.37313.
- [8] T. Anggrahini, S. Widystuti, and M. Sihite, "Pengaruh internal kontrol, organization behaviour dan digitalisasi terhadap kinerja perusahaan," *Jurnal LOCUS: Penelitian & Pengabdian*, vol. 2, no. 11, Nov. 2023. doi: 10.58344/locus.v2i11.1860.
- [9] Basuki & N. Suwarno, "Teknologi Digital Memediasi Dampak Strategi Bisnis Terhadap Kinerja UMKM di Nusa Tenggara Barat," *Jurnal Ekonomi dan Keuangan (EKUITAS)*, vol. 5, no. 3, pp. 300-320, 2021. doi: 10.24034/j25485024.y2021.v5.i3.4892.
- [10] C.-Y. Wang, H.-Y. M. Liao, Y.-H. Wu, P.-Y. Chen, J.-W. Hsieh, and I.-H. Yeh, "CSPNet: A new backbone that can enhance learning capability of CNN," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW)*, Seattle, WA, USA, Jun. 14–19, 2020, pp. 1571–1580, doi: 10.1109/CVPRW50498.2020.00203.
- [11] A. Sharma, V. Kumar, and L. Longchamps, "Comparative performance of YOLOv8, YOLOv9, YOLOv10, YOLOv11 and Faster R-CNN models for detection of multiple weed species," *Smart Agricultural Technology*, vol. 9, Art. no. 100648, Nov. 2024, doi: 10.1016/j.atech.2024.100648.
- [12] M. A. Maruf, A. Azim, N. Auluck, and M. Sahi, "Optimizing DNN training with pipeline model parallelism for enhanced performance in embedded systems," *Journal of Parallel and Distributed Computing*, vol. 190, p. 104890, 2024, doi: 10.1016/j.jpdc.2024.104890.