

Performa YOLOv26n dalam Mendeteksi Tandan Buah Kelapa Sawit berbasis Citra UAV

Shindy Ekawati¹, Andi Wahyu², Akramunnisa³

¹³Universitas Cokroaminoto Palopo, ²Universitas Teknologi Akba Makassar


shindy.ekawati@uncp.ac.id

Article Info

Kata Kunci:

Deteksi, Kelapa Sawit, YOLO, Deep Learning, UAV

Copyright © 2026
The Author(s)



Lisensi: cc-by-sa

Abstrak

Penelitian ini bertujuan untuk mengevaluasi performa model YOLOv26-nano dalam mendeteksi tandan buah kelapa sawit berbasis citra UAV pada kondisi lapangan nyata. Data diperoleh menggunakan drone dengan variasi kondisi pencahayaan, sudut pengambilan, serta gangguan lingkungan seperti occlusion dan noise visual. Tahapan penelitian meliputi akuisisi data, preprocessing (ekstraksi *frame*, *cleaning*, *anotasi*, *resizing*), pembagian dataset (*training*, *validation*, *testing*), serta pelatihan model menggunakan arsitektur YOLOv26 dengan parameter *default*. Evaluasi dilakukan menggunakan metrik *precision*, *recall*, dan *mean Average Precision* (mAP). Hasil penelitian menunjukkan bahwa pada proses pelatihan, model mencapai *precision* sebesar 0.90–0.93, *recall* 0.88–0.92, serta mAP₅₀ sebesar 0.91–0.94, yang menunjukkan kemampuan deteksi yang sangat baik. Pada tahap pengujian, model terbaik (*best model*) memperoleh *precision* 0.936–0.938, *recall* 0.775–0.799, mAP₅₀ 0.773–0.851, dan mAP_{50–95} sebesar 0.631–0.643. Sementara itu, model terakhir (*last model*) menunjukkan performa yang sedikit lebih rendah. Hasil ini menunjukkan bahwa YOLOv26 memiliki kemampuan yang baik dalam mendeteksi objek, namun masih memiliki keterbatasan dalam lokalisasi bounding box pada objek kecil dan kompleks. Penelitian ini membuktikan bahwa YOLOv26 efektif digunakan untuk deteksi tandan kelapa sawit berbasis UAV, meskipun masih memerlukan pengembangan lebih lanjut untuk meningkatkan akurasi pada kondisi lapangan yang kompleks.

PENDAHULUAN

Perkembangan teknologi *computer vision* berbasis *deep learning* telah memberikan dampak signifikan dalam otomatisasi deteksi objek, khususnya pada bidang pertanian presisi. Salah satu pendekatan yang paling banyak digunakan adalah *You Only Look Once* (YOLO) karena mampu melakukan deteksi objek secara real-time dengan keseimbangan antara kecepatan dan akurasi [1]. Dalam konteks pertanian, YOLO telah diterapkan pada berbagai tugas seperti pemantauan tanaman, deteksi penyakit, hingga identifikasi objek pada citra udara. Penggunaan *Unmanned Aerial Vehicle* (UAV) semakin memperkuat kemampuan akuisisi data karena mampu menghasilkan citra resolusi tinggi dalam area luas dengan efisiensi waktu yang tinggi [2]. Namun, integrasi YOLO dan UAV masih menghadapi tantangan pada objek kecil dan lingkungan yang kompleks.

Beberapa penelitian sebelumnya menunjukkan bahwa YOLO mampu memberikan performa yang cukup tinggi dalam deteksi objek pertanian berbasis UAV. Penelitian deteksi kelapa sawit menggunakan YOLO pada citra UAV menunjukkan hasil dengan precision sebesar 92% dan recall 96%, serta kemampuan deteksi real-time pada area perkebunan luas [3]. Penelitian lain pada deteksi pohon kelapa sawit berbasis YOLOv5–YOLOv8 menunjukkan nilai mAP mencapai 0.77–0.92 tergantung dataset dan kondisi citra [4]. Selain itu, penggunaan metode peningkatan data seperti augmentasi dan synthetic dataset mampu meningkatkan nilai mAP hingga 0.88 dari baseline 0.65 pada kondisi data terbatas [5]. Hasil ini menunjukkan bahwa YOLO cukup efektif dalam domain pertanian, terutama pada data UAV.


Meskipun demikian, berbagai penelitian sebelumnya juga mengungkapkan beberapa kelemahan pada sistem deteksi berbasis YOLO. Salah satu masalah utama adalah kesulitan dalam mendeteksi objek kecil (*small object detection*) seperti tandan buah kelapa sawit yang sering tertutup oleh daun atau berada pada sudut pengambilan UAV yang tidak optimal [6]. Selain itu, variasi pencahayaan, resolusi citra, serta kondisi lingkungan seperti bayangan dan kepadatan vegetasi dapat menurunkan akurasi model secara signifikan [7]. Beberapa penelitian juga menunjukkan bahwa performa YOLO sangat bergantung pada kualitas dataset, di mana dataset yang tidak seimbang dapat menyebabkan penurunan nilai recall dan meningkatnya false detection [8]. Hal ini menunjukkan bahwa meskipun YOLO memiliki performa tinggi, terdapat keterbatasan pada kondisi lapangan yang kompleks.

YOLOv26 merupakan pengembangan terbaru dari *You Only Look Once* (YOLO) yang dirancang untuk meningkatkan keseimbangan antara kecepatan inferensi dan akurasi deteksi pada berbagai skenario kompleks. Berdasarkan perkembangan arsitektur YOLO generasi terbaru, YOLOv26 mengadopsi peningkatan pada struktur backbone dan neck yang lebih efisien dalam mengekstraksi fitur multi-skala, sehingga lebih adaptif terhadap objek berukuran kecil dan tersembunyi pada latar belakang yang kompleks [12]. Selain itu, YOLOv26 juga mengoptimalkan mekanisme feature fusion dan strategi decoupled head untuk meningkatkan kemampuan model dalam membedakan objek yang memiliki kemiripan visual tinggi. Peningkatan ini menjadikan YOLOv26 lebih potensial untuk diterapkan pada citra UAV yang memiliki karakteristik objek kecil, kepadatan tinggi, serta variasi sudut pandang yang ekstrem.

Berdasarkan penelitian sebelumnya tersebut, masih diperlukan evaluasi lebih lanjut terhadap performa model YOLO26 pada kondisi nyata perkebunan kelapa sawit berbasis citra UAV. Hal ini penting karena karakteristik objek seperti tandan buah kelapa sawit memiliki ukuran kecil, tingkat occlusion tinggi, serta variasi bentuk yang kompleks. Oleh karena itu, penelitian ini berfokus pada analisis performa YOLOv26 dalam mendeteksi tandan buah kelapa sawit berbasis citra UAV untuk mengevaluasi tingkat akurasi, *precision*, *recall*, serta *mean Average Precision* (mAP) dalam kondisi pengambilan data lapangan yang sebenarnya [9][10][11]. Hasil penelitian ini diharapkan dapat memberikan gambaran performa model terbaru YOLO dalam mendukung sistem pemantauan perkebunan kelapa sawit secara otomatis.

METODE

Penelitian ini mengevaluasi kinerja YOLO26n dalam mendeteksi tandan buah kelapa sawit di lingkungan perkebunan. Tahapan penelitian dapat dilihat pada gambar 1, dimana tahapan penelitian meliputi akuisisi dan praproses data, konfigurasi pelatihan, serta evaluasi performa menggunakan metrik mAP, precision, recall, dan F1-Score. Pendekatan ini bertujuan untuk menganalisis pengaruh ketidakseimbangan data terhadap performa deteksi serta kemampuan YOLO26 Nano dalam menghasilkan kinerja yang optimal.



Gambar 1. Alur Penelitian

Akuisisi Data

Akuisisi citra dilakukan langsung di perkebunan kelapa sawit di Sulawesi Selatan, Indonesia, menggunakan kamera drone DJI Neo. Pengambilan data memanfaatkan pengaturan *auto-focus* dan *auto-exposure* pada kondisi pencahayaan alami, dengan kamera diarahkan secara horizontal ke tandan pada jarak $\pm 1-1,5$ meter. Akuisisi dilakukan pada pagi, siang, dan sore hari untuk merepresentasikan variasi intensitas

cahaya, mulai dari kondisi berbayang hingga pencahayaan rendah. Data mentah penelitian berupa rekaman video tandan buah kelapa sawit berdurasi ± 8 detik per video dengan resolusi 1920×1080 dan frame rate 30 FPS. Video direkam tanpa stabilisasi, denoising, maupun koreksi pencahayaan, sehingga merepresentasikan kondisi lapangan nyata yang mencakup motion blur, getaran kamera, variasi pencahayaan, oklusi, serta keberadaan objek non-target seperti pelepah dan gulma.

Praproses Data

Setelah data mentah diperoleh, tahap selanjutnya adalah melakukan preprocessing untuk memastikan data berada dalam kondisi optimal sebelum proses pelatihan model. Pada tahap preprocessing ini, terdapat sejumlah langkah yang dilakukan, antara lain sebagai berikut:

- Extract to Image:** Ekstraksi frame dilakukan menggunakan Roboflow dengan metode sampling otomatis 1 frame setiap 1 detik durasi video. Hasil ekstraksi disimpan dalam format JPG dengan resolusi mengikuti video asli tanpa peningkatan kualitas atau penyaringan tambahan.
- Cleaning Data:** Tahap ini menyaring frame hasil ekstraksi untuk menghapus gambar buram, terlalu gelap/terang, duplikat, atau yang tidak menampilkan tandan kelapa sawit, sehingga hanya citra relevan yang digunakan untuk pelatihan model.
- Annotation and Labelling:** Anotasi dilakukan manual menggunakan Roboflow dengan metode bounding box untuk menandai tandan kelapa sawit pada setiap citra, diberi label dua kelas yaitu Matang dan Mentah. Hasil anotasi diekspor dalam format YOLOv26 untuk pelatihan model.
- Resize:** Citra hasil anotasi diubah ukurannya menjadi 640×640 piksel untuk menyesuaikan input YOLO, mengurangi variasi skala antar sampel, serta menjaga detail visual tandan kelapa sawit yang saling tumpang tindih maupun dengan pelepah.
- Split Data:** Dataset dibagi menjadi 70% pelatihan, 20% validasi, dan 10% pengujian untuk memastikan model memperoleh data yang cukup untuk belajar, dievaluasi, dan diuji secara independen.
- Augmentasi:** Diterapkan hanya pada data latih untuk mencegah overfitting dan menambah keragaman citra, dengan transformasi rotasi 45° , shear 10° , dan flipping horizontal. Rangkuman dataset ditampilkan pada Tabel 1.

Tabel 1. Uraian Dataset yang digunakan dalam Penelitian

Subset Data	Persentase	Jumlah Citra Sebelum Augmentasi	Teknik Augmentasi yang digunakan	Jumlah Citra Setelah Augmentasi	Jumlah Tandan Matang	Jumlah Tandan Mentah
Train	70%	550	Rotasi 45° , Shear 10° , dan flipping horizontal	1650	702	1686
Validation	20%	157	-	157	201	482
Testing	10%	79	-	79	100	241
Total				1886	1004	2409

Pelatihan Model YOLO26

Model YOLO26n diinisialisasi menggunakan bobot pre-trained resmi serta memanfaatkan mekanisme warmup dan scheduler default, sehingga memungkinkan analisis stabilitas konvergensi dan efisiensi optimasi. Pemilihan ukuran model didasarkan pada kebutuhan kecepatan inferensi untuk implementasi pada edge device berbasis drone. Pelatihan dilakukan dengan mengatur hiperparameter menggunakan nilai default pada YOLO26 untuk menjaga stabilitas optimasi dan konsistensi eksperimen. Penyesuaian hanya dilakukan pada ukuran input, jumlah epoch, dan batch size sesuai kapasitas memori GPU, sehingga evaluasi berfokus pada kapabilitas intrinsik arsitektur, meminimalkan bias akibat tuning berlebihan.

Evaluasi Model

Pengujian dilakukan menggunakan Confusion Matrix dengan nilai minimal confidence sebesar 50%. Melalui Confusion Matrix, berbagai metrik evaluasi penting seperti presisi, recall dapat dihitung. Evaluasi performa model juga memperhitungkan mAP50 dan mAP50:95 yang memberikan gambaran lebih komprehensif mengenai kemampuan model dalam mendeteksi tandan buah kelapa sawit.

- a. Precision digunakan untuk mengukur ketepatan model dalam menghasilkan prediksi positif yang benar, sehingga mencerminkan tingkat kesalahan deteksi. Rumus precision ditunjukkan pada Persamaan (1).

$$Precision = TP / (TP + FP) \quad (1)$$

- b. Recall mengukur proporsi tandan kelapa sawit yang benar-benar terdeteksi oleh model terhadap seluruh tandan kelapa sawit pada data aktual, sehingga merefleksikan kemampuan model dalam meminimalkan kesalahan false negative. Rumus recall ditunjukkan pada Persamaan (2).

$$Recall = TP / (TP + FN) \quad (2)$$

- c. *Mean Average Precision* (mAP) digunakan untuk mengukur rata-rata ketepatan deteksi model pada semua kelas objek (matang dan mentah) dengan mempertimbangkan berbagai tingkat confidence threshold. Metrik ini digunakan untuk menilai kinerja keseluruhan model dalam mendeteksi objek. Rumus mAP ditunjukkan pada Persamaan (4).

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (3)$$

Keterangan:

TP = Deteksi tandan kelapa sawit benar dengan bounding box, kelas, dan IoU memenuhi ambang.

FP = Deteksi model salah sebagai tandan kelapa sawit, karena objek, kelas, atau IoU tidak sesuai.

FN = Tandan kelapa sawit yang ada pada citra tidak berhasil terdeteksi oleh model.

N = Jumlah Kelas


AP_i = Average Precision pada kelas ke-i.

HASIL

Bagian hasil dan pembahasan ini menyajikan performa model YOLO26n dalam mendeteksi serta menentukan tingkat kematangan tandan buah segar (TBS) kelapa sawit pada pohon menggunakan citra drone. Evaluasi dilakukan menggunakan metrik *precision*, *recall* dan *mean Average Precision*(mAP) pada dataset yang mencerminkan kemampuan model dalam menghadapi kondisi lapangan nyata.

Performa Pelatihan

Performa pelatihan yang dihasilkan selama proses pelatihan YOLO26 dapat dilihat pada gambar 3. Nilai *precision* berada pada kisaran 0.90–0.93, menunjukkan bahwa model mampu mendeteksi objek dengan tingkat kesalahan false positive yang rendah. Hal ini dipengaruhi oleh arsitektur backbone yang lebih efisien dalam mengekstraksi fitur, sehingga mampu membedakan tandan kelapa sawit dari latar belakang seperti daun dan bayangan. Kelebihannya adalah deteksi menjadi lebih akurat, namun kelemahannya masih terdapat kesalahan pada objek yang memiliki kemiripan visual dengan tandan sawit di area vegetasi padat.



Gambar 3. Performa Pelatihan Model YOLO26

Sedangkan nilai *recall* diperoleh berkisar 0.88–0.92, menandakan bahwa sebagian besar objek berhasil terdeteksi dengan baik. Kemampuan ini didukung oleh mekanisme multi-scale feature fusion pada YOLO26 yang memungkinkan deteksi objek dengan berbagai ukuran, termasuk objek kecil pada citra UAV. Meskipun demikian, beberapa objek masih tidak terdeteksi akibat occlusion atau posisi objek yang terlalu kecil dan jauh dari kamera.


Nilai mAP50 mencapai 0.91–0.94 menunjukkan bahwa performa deteksi yang sangat baik, namun mAP50-95 yang lebih rendah (0.63–0.66) mengindikasikan keterbatasan dalam presisi bounding box. Hal ini berkaitan dengan tantangan regresi lokasi pada objek kecil, meskipun YOLO26 telah menggunakan decoupled head untuk meningkatkan stabilitas deteksi. Dengan demikian, YOLO26 unggul dalam deteksi objek secara umum, tetapi masih memiliki kelemahan pada ketepatan lokalisasi detail.

Performa Pengujian

Pengujian kinerja pada penelitian ini difokuskan untuk menilai kemampuan model YOLO26n dalam mendeteksi tandan buah segar (TBS) kelapa sawit pada citra perkebunan. Data uji yang digunakan sepenuhnya tidak digunakan selama proses pelatihan model. Penilaian performa menggunakan metrik precision, recall guna merepresentasikan keseimbangan antara ketepatan prediksi dan kelengkapan deteksi, serta mean Average Precision pada ambang IoU 0.5 dan 0.5–0.95 untuk mengevaluasi akurasi deteksi.

Best Model

Model terbaik (*best model*) merupakan bobot terbaik yang terpilih secara otomatis pada saat proses training. Hasil pengujian pada *model best* yang dapat dilihat pada gambar 4. *Model best* YOLO26 menunjukkan precision yang sangat tinggi (0.936–0.938) pada seluruh kelas, yang menandakan kemampuan model dalam meminimalkan false positive dan menghasilkan deteksi yang akurat. Hal ini menunjukkan bahwa pada kondisi terbaiknya, arsitektur backbone YOLO26 mampu mengekstraksi fitur secara optimal dan membedakan objek tandan kelapa sawit dari latar belakang kompleks pada citra UAV.




Gambar 4. Performa Pengujian Model Best YOLO26

Nilai recall pada model best berada pada kisaran 0.775–0.799, dengan performa tertinggi pada kelas Raw. Hal ini menunjukkan bahwa sebagian besar objek berhasil terdeteksi, meskipun masih terdapat beberapa miss detection, terutama pada objek kecil atau yang mengalami occlusion. Kemampuan ini dipengaruhi oleh mekanisme multi-scale feature fusion yang dimiliki YOLO26, yang membantu deteksi objek dengan berbagai ukuran, namun belum sepenuhnya optimal pada kondisi tertentu.

Sementara itu, mAP50 model best (0.773–0.851) menunjukkan performa deteksi yang baik pada IoU standar, tetapi mAP50–95 (0.631–0.643) yang lebih rendah mengindikasikan bahwa presisi lokalisasi bounding box masih menjadi tantangan. Meskipun YOLO26 telah menggunakan decoupled head untuk meningkatkan stabilitas klasifikasi dan regresi, keterbatasan tetap muncul pada objek kecil dan kompleks dalam citra UAV.

Model Last

Model Terakhir (*last model*) merupakan bobot terakhir selama proses pelatihan ketika mencapai 100 epoch. Hasil pengujian pada *model last* yang dapat dilihat pada gambar 5. *Model best* YOLO26 menunjukkan nilai precision berada pada kisaran 0.916–0.922, sedikit lebih rendah dibanding model best, namun masih menunjukkan kemampuan yang baik dalam meminimalkan false positive. Hal ini menunjukkan bahwa arsitektur backbone YOLO26 tetap mampu mengekstraksi fitur dengan cukup baik, meskipun performanya belum mencapai kondisi optimal seperti pada model best. Penurunan ini umumnya terjadi karena bobot pada epoch terakhir tidak selalu merepresentasikan titik performa terbaik selama training.



Gambar 5. Performa Pengujian Model Last YOLO26

Nilai recall model last berkisar antara 0.775–0.812, dengan performa tertinggi pada kelas Raw. Hal ini menunjukkan bahwa sebagian besar objek masih berhasil terdeteksi, bahkan sedikit lebih tinggi dibanding model best pada beberapa kelas. Kemampuan ini tetap dipengaruhi oleh multi-scale feature fusion pada YOLO26, namun fluktuasi selama training menyebabkan performa deteksi tidak sepenuhnya stabil, khususnya pada objek kecil atau yang mengalami occlusion.

Sementara itu, mAP₅₀ (0.773–0.849) menunjukkan performa deteksi yang cukup baik, tetapi tidak setinggi model best, sedangkan mAP₅₀₋₉₅ (0.627–0.647) relatif mirip dan sedikit bervariasi. Hal ini mengindikasikan bahwa kemampuan lokalisasi bounding box pada model last masih menghadapi tantangan yang sama, terutama pada objek kecil di citra UAV. Meskipun YOLO26 telah menggunakan decoupled head, model last belum mencapai kondisi optimal dalam menyeimbangkan klasifikasi dan regresi, sehingga secara keseluruhan performanya sedikit di bawah model best.

SIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model YOLOv26-nano mampu mendeteksi tandan buah kelapa sawit pada citra UAV dengan performa yang baik. Pada tahap pelatihan, model menunjukkan nilai precision, recall, dan mAP₅₀ yang tinggi, yang mengindikasikan kemampuan model dalam mengenali objek secara akurat dan stabil. Hal ini didukung oleh arsitektur YOLOv26

yang mampu mengekstraksi fitur secara optimal serta mendukung deteksi objek dengan berbagai ukuran melalui mekanisme multi-scale feature fusion.

Berdasarkan hasil penelitian, model YOLOv26-nano mampu mendeteksi tandan buah kelapa sawit dengan performa yang baik. Pada tahap pelatihan, model mencapai precision sebesar 0.90–0.93, recall 0.88–0.92, dan mAP₅₀ sebesar 0.91–0.94. Pada tahap pengujian, model terbaik (best model) memperoleh precision 0.936–0.938, recall 0.775–0.799, mAP₅₀ 0.773–0.851, dan mAP₅₀₋₉₅ sebesar 0.631–0.643, sedangkan model terakhir (last model) menunjukkan precision 0.916–0.922, recall 0.775–0.812, mAP₅₀ 0.773–0.849, dan mAP₅₀₋₉₅ sebesar 0.627–0.647.

Hasil tersebut menunjukkan bahwa YOLOv26 memiliki kemampuan deteksi yang tinggi, khususnya dalam meminimalkan false positive, namun masih memiliki keterbatasan dalam mendeteksi objek kecil dan dalam presisi lokalisasi bounding box pada tingkat IoU yang lebih tinggi. Secara keseluruhan, model best memberikan performa yang lebih optimal dibandingkan model last.

DAFTAR PUSTAKA

- Agung Syaputra, & Tata Sutabri. (2024). Pengantar Internet of Things: Konsep dan Implementasi. Bandung: Informatika.
- Armbrust, M., Fox, A., Griffith, R., Joseph, A. D., Katz, R., Konwinski, A., Lee, G., Patterson, D., Rabkin, A., Stoica, I., & Zaharia, M. (2021). A View of Cloud Computing. *Communications of the ACM*, 53(4), 50–58.
- Gupta, S., & Priyadarshini, I. (2021). Design and Development of a Mobile-Based IoT Monitoring Interface for Industrial Applications. *Journal of Ambient Intelligence and Humanized Computing*, 12, 5673–5682.
- Usman, M. M., Putra, A. R., & Fauzi, R. (2020). Perancangan Sistem Pendeteksi Banjir dan Sistem Peringatan Dini Berbasis Bot Telegram. *Jurnal Teknik Elektro dan Komputer*, 9(3), 210–218.
- Wang, Y., & Zhang, Y. (2021). IoT Applications in Smart Mining: Challenges and Opportunities. *Resources Policy*, 73, 102176.