

DETEKSI DAN PERHITUNGAN JUMLAH POHON SAWIT SECARA OTOMATIS PADA REMOTE SENSING IMAGERY MENGGUNAKAN ALGORITMA YOLOV11n

Model For Automatic Detection And Calculation Of The Number Of Oil Palm Trees Using The Yolov11n Algorithm

Risnawati^{1*}, Ummu Kalsum¹, Edi Minaji Pribadi¹, Ahmad Yozar Perkasa¹, Adinda Nurul Huda Manurung¹

¹ Program studi Agroteknologi, Fakultas Teknologi Industri, Universitas Gunadarma (Gunadarma University), Jl. Margonda Raya No. 100, Depok 16424, Indonesia. risnawati@staff.gunadarma.ac.id, ummukalsum89@gmail.com, edi_mp@staff.gunadarma.ac.id, achmadyozarp@yahoo.com, adinda.nhm@gmail.com

*) Penulis korespondensi

Diterima 02 Mei 2026; Disetujui 25 Juni 2026

ABSTRAK

Sawit merupakan komoditi industri penghasil minyak yang saat ini dibudidayakan dalam skala areal perkebunan yang luas. Tanaman sawit skala luas butuh teknologi agar bisa berkelanjutan dan menghasilkan capaian produksi yang maksimal. Pemantauan terhadap tanaman sawit perlu dilakukan seperti untuk menentukan jumlah pohon sawit pada areal yang luas dibutuhkan guna memprediksi kebutuhan pupuk dan pestisida yang diperlukan serta bisa mengetahui jumlah tanaman sawit yang masih tumbuh dan berproduksi. Tujuan penelitian ini adalah optimasi hyperparameter arsitektur model YOLOv11n untuk mendeteksi tanaman pohon sawit dan menghitung jumlah pohon sawit pada citra hasil remote sensing. Deteksi pohon sawit menggunakan model YOLOv11n menghasilkan nilai presisi, recall, mAP50 dan mAP50-90 masing-masing sebesar 92.3%, 96.8%, 97.3% dan 62.4%. Perhitungan pohon sawit secara otomatis pada dataset citra remote sensing menggunakan perangkat QGIS diperoleh sebesar 3867 pohon sawit. Hasil perhitungan pohon sawit tersebut membuktikan bahwa YOLOv11n mampu mendeteksi sekaligus mampu menghitung jumlah pohon sawit yang terdapat pada luasan area dalam citra spasial pohon sawit hasil akuisisi dari remote sensing.

Kata kunci: *deep learning*, model, citra

ABSTRACT

Oil palm is an industrial commodity that produces oil and is currently cultivated on a large scale. Large-scale oil palm cultivation requires technology to ensure sustainability and maximise production. Monitoring of oil palm plants is necessary to determine the number of oil palm trees in a large area in order to predict the required amount of fertiliser and pesticides and to find out the number of oil palm plants that are still growing and producing. The purpose of this study is to optimise the hyperparameters of the YOLOv11n model architecture to detect oil palm trees and calculate the number of oil palm trees in remote sensing images. Palm tree detection using the YOLOv11n model produced precision, recall, mAP50 and mAP50-90 values of 92.3%, 96.8%, 97.3% and 62.4% respectively. Automatic calculation of oil palm trees in the remote sensing image dataset using QGIS yielded a total of 3,867 oil palm trees. These results prove that YOLOv11n is capable of detecting and calculating the

number of oil palm trees in the spatial area of oil palm trees acquired from remote sensing.

Keywords: *deep learning, model, image*

PENDAHULUAN

Sawit merupakan tanaman penghasil minyak sawit terbesar di Indonesia. Minyak sawit yang dihasilkan tidak hanya dikonsumsi penduduk dalam negeri, akan tetapi menjadi kebutuhan ekspor (Hasibuan, 2021). Hal tersebut mendorong perlunya peningkatan tanaman sawit di Perkebunan sawit. Budidaya sawit dilakukan guna peningkatan produksi sawit tersebut menghendaki perluasan areal kebun sawit hingga ke bagian pelosok tanah air. Sawit dengan tingkat populasi yang tinggi pada areal lahan budidaya yang luas, tentunya dalam proses pemantauan tidak begitu mudah dan cepat penanganannya.

Pemantauan terhadap tanaman sawit dilakukan salah satunya untuk menghitung dan memastikan jumlah pohon sawit yang ditanam pada areal sawit tersebut dapat tumbuh dan berkembang dengan optimal. Jumlah pohon sawit diketahui secara pasti bertujuan untuk memprediksi jumlah pupuk atau bahan inputan lainnya dapat ditentukan dengan tepat dan cepat serta akurat.

Deteksi pohon sawit merupakan bagian dari proses pemantauan untuk

mengidentifikasi dan menentukan posisi sawit secara tepat. Saat ini pemantauan dan perhitungan jumlah pohon sawit masih cenderung konvensional, sehingga butuh tenaga yang tidak sedikit dan waktu yang lebih panjang. Hal ini tentunya butuh teknologi yang dapat mendeteksi dan menghitung jumlah pohon sawit secara akurat dan presisi.

Teknologi Penginderaan Jauh (remote sensing) dan *Artificial Intelligence* akhir-akhir ini menjadi populer dan penting digunakan untuk berbagai deteksi dan menghitung objek secara otomatis. Pemanfaatan remote sensing dengan menggunakan pesawat nir awak yang dilengkapi dengan kemampuan menangkap citra dengan resolusi tinggi menjadi jembatan penting untuk menghubungkan dengan penggunaan kecerdasan artificial (Tahir et al., 2024).

Beberapa penelitian sebelumnya bahwa YOLOv8 digunakan untuk melakukan deteksi kematangan tandan sawit, jumlah dataset 6592 dengan waktu pelatihan selama 3107 jam menghasilkan presisi sebesar 94.5%, *recall* 94.7%, (Genoveva and Syah, 2024). Hasil presisi tinggi namun waktu pemrosesan pelatihan

dataset cukup lama. Kemudian hasil penelitian (Josdaan *et al.*, 2024) melakukan deteksi dan mengklasifikasi buah sawit menjadi 5 kelas yaitu buah busuk, buah matang, buah belum matang, terlalu matang dan tandan kosong. Model YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x yang digunakan dalam mendeteksi dan mengklasifikasi jenis-jenis buah sawit tersebut. Hyperparameter yang digunakan adalah jumlah batchsize 16, *learning rate* 0.00075, momentum 0.9, *weight decay* 0.0005 dan optimizer AdamW. Hasil terbaik diperoleh pada arsitektur YOLOv8m dengan rata-rata kecepatan pemrosesan yakni sebesar 14.68 detik per iterasi selama proses pelatihan. Hasil akurasi yang diperoleh 98.85%. Selanjutnya hasil penelitian oleh (Hajjaji *et al.*, 2025) melakukan deteksi kelapa sawit menggunakan model YOLOv8 menghasilkan rata-rata presisi, presisi dan recall masing-masing sebesar 88%, 87%, 0,86.

Model arsitektur YOLO di atas telah mencapai akurasi yang cukup tinggi namun waktu pemrosesan yang dilakukan saat training dataset masih cukup lama sehingga belum efisien. Arsitektur model YOLOv11 merupakan algoritma untuk mendeteksi objek pada citra yang dapat digunakan dengan pemanfaatan cabang-

cabang konvolusi pada multi skala kedalaman dengan variasi ukuran kernel untuk melakukan ekstraksi fitur secara paralel, sehingga dapat meningkatkan kemampuan model dalam mendeteksi objek sejenis dengan skala yang berbeda (Shibo, Pan and Buhari, 2025). Selanjutnya YOLOv11 merupakan salah satu perkembangan terbaru untuk deteksi objek. Arsitektur YOLOv11n ini dikembangkan dengan pengoptimalan pada bagian inti (backbone) serta peningkatan modul pada bagian ekstraksi fitur, sehingga menghasilkan akurasi deteksi lebih baik dan efisiensi komputasi menjadi lebih tinggi. YOLOv11 secara umum berkinerja lebih baik daripada versi sebelumnya untuk menyelesaikan berbagai tugas deteksi objek, dan cocok untuk deteksi objek secara real time.

Tujuan penelitian ini adalah mengoptimasi arsitektur model YOLOv11n untuk mendeteksi pohon sawit serta menghitung jumlah pohon sawit secara otomatis pada citra hasil remote sensing menggunakan drone guna mempermudah pengelolaan perkebunan sawit. Gap penelitian ini yakni optimasi model YOLOv11n melalui tuning beberapa hyperparameter. Harapannya model YOLOv11n memiliki kemampuan ekstraksi fitur yang lebih baik,


penyesuaian hyperparameter juga dilakukan guna mencapai akurasi presisi serta waktu deteksi dan perhitungan jumlah pohon sawit dapat dihasilkan secara maksimal dan efisien, mengingat ukuran pohon sawit yang beragam. Kontribusi tersebut akan meningkatkan produktivitas dan keberlanjutan perkebunan sawit disamping mengurangi tenaga, biaya dan waktu, terlebih di sektor industri kelapa sawit.

BAHAN DAN METODE

Waktu Penelitian

Penelitian dilakukan mulai bulan Oktober 2025 hingga Maret 2026.

Bahan dan alat



Gambar 1. Bagan penelitian

Pembentukan dataset

Tahap pertama yaitu pembentukan dataset. Dataset citra remote sensing berupa geospasial area sebaran pohon sawit diperoleh dari web Open Aerial

Bahan dan alat yang digunakan pada penelitian ini berupa citra area geospasial sebaran pohon sawit, perangkat aplikasi berbasis virtual mesin yaitu QGIS, Roboflow dan Google Colab.

Prosedur penelitian

Penelitian ini dilakukan melalui enam tahapan yang terdiri atas tahap pertama pembentukan dataset, tahap kedua yaitu preprosesing dataset, tahap ketiga yaitu splitting dataset, tahap keempat yaitu pemedolen, tahap kelima yaitu evaluasi model dan perhitungan jumlah pohon sawit pada citra remote sensing geospasial sawit secara otomatis. Alur penelitian secara keseluruhan terlihat pada (Gambar 1. Bagan penelitian).

Map. Sebanyak 2 citra didonwload dari web tersebut, di mana citra yang pertama untuk dataset latih dan dataset validasi. Adapun citra yang kedua merupakan citra digunakan area sebaran pohon sawit

dengan lokasi yang berbeda digunakan sebagai dataset uji.

Preprocessing Dataset

Tahapan kedua yakni preprosesing dataset terdiri atas tiga proses yaitu proses pertama *tiling* dan *resize*, proses kedua *image labelling*, dan proses ketiga yaitu augmentasi dataset.

Tiling

Proses *tiling* adalah proses pemotongan citra geospasial area sebaran pohon sawit di potong-potong menjadi beberapa segmen citra dengan resolusi citra berukuran 640 x 640 piksel. *Tiling* dilakukan dengan tujuan agar citra dapat dipelajari oleh *deep learning* berbasis YOLOV11n. *Tiling* citra drone geospasial sawit dilakukan menggunakan mesin virtual yaitu QGIS.

Image labelling

Setelah proses *tiling* citra dataset selesai dilakukan, proses selanjutnya yakni *image labelling*. *Image labelling* merupakan proses pelabelan seluruh citra dataset yakni citra dataset untuk latih dan citra dataset untuk uji. Proses *image labelling* yakni dilakukan dengan cara memberi bounding box serta memberi nama atau label dataset tersebut. *Image*

labelling dataset ini dilakukan menggunakan Roboflow. Pemberian label pada dataset terdapat kesulitan yakni pohon sawit tampak pada citra dengan kanopi pelepah daun sawit tumpang tindih dengan pohon sawit yang letaknya saling berdekatan.

Augmentasi

Kemudian setelah proses *image labelling* dataset latih dan dataset validasi, selanjutnya dilakukan proses augmentasi dataset. Augmentasi dataset dilakukan dengan tujuan untuk meningkatkan jumlah dataset dan keragaman dataset, baik dataset latih maupun dataset validasi. Proses augmentasi akan menghasilkan file folder data train dan file folder data valid. Jenis-jenis teknik augmentasi yang dilakukan pada penelitian yaitu rotasi 90, rotasi 180, rotasi 270, *horizontal flip*, *vertikal flip* dan *bright*.


Masing-masing data train dan data valid terbagi atas kumpulan images dan kumpulan labels. Proses augmentasi dilakukan menggunakan perangkat Google Colabs.

Splitting Dataset

Selanjutnya tahap yang ketiga yaitu *splitting* dataset. *Splitting* dataset merupakan pembagian dataset menjadi

dua yakni dataset latih dan dataset validasi. Proses *splitting* dataset menggunakan teknik *stratified sampling* di mana dataset dibagi dalam jumlah proporsi yang sesuai yang telah ditentukan pada masing-masing

dataset latih dan dataset validasi. Persentase pembagian dataset latih dan dataset validasi yakni masing-masing sebesar 80% dan 20%, seperti tampak pada (Gambar 2).



Gambar 2. *Splitting dataset*

Pemodelan

Tahap selanjutnya yaitu pemodelan deteksi citra sebaran area geospasial pohon sawit menggunakan deep learning berbasis YOLOV11n. Algoritma YOLOV11n merupakan algoritma yang dapat digunakan untuk melakukan deteksi pada citra remote sensing area geospasial sebaran pohon sawit. Proses awal yaitu *transfer learning* algoritma YOLOV11n, di mana bobot dan bias menggunakan bobot dan bias dari model pre-trained, yang sebelumnya digunakan untuk mempelajari dataset imagenet. YOLOV11n memiliki jumlah lapisan sebanyak 101 lapisan, jumlah parameter sebesar 2.582.347, serta GFLOPs 6.3. Kemudian pada penelitian ini digunakan kembali bobot dan bias tersebut untuk mempelajari dataset yang baru. Tujuan penggunaan *transfer learning* yakni agar proses

pelatihan dapat berjalan dengan waktu yang lebih singkat, di samping penggunaan dataset baru memiliki jumlah yang cenderung tidak besar.

Proses setelah transfer learning, selanjutnya melakukan training dataset dengan menggunakan proses finetuned dengan menggunakan proses finetuned beberapa hyperparameter. Hyperparameter tersebut yaitu jumlah epoch 100, jumlah *batchsize* yakni 8, 16 dan 32; resolusi citra ukuran 640 x 640 piksel, optimizer berupa SGD, Adam, Adamax, Nadam dan AdamW; dan patience 20. *Patience* adalah jumlah epoch yang harus ditunggu untuk menyesuaikan *learning rate* jika nilai yang dipantau tidak memberikan kenaikan nilai akurasi.

Evaluasi model serta Perhitungan Jumlah Pohon Sawit Secara Otomatis

Evaluasi model dilakukan

menggunakan data uji citra remote sensing area spasial sawit guna melakukan deteksi kembali pada dataset yang baru. Evaluasi tersebut menggunakan model dari hasil dari pelatihan menggunakan arsitektur YOLOv11n. Model yang diperoleh diconvert terlebih dahulu menjadi bentuk file ONNX sehingga dapat digunakan untuk deteksi serta menghitung jumlah sawit yang terdapat pada citra remote sensing. Deteksi serta perhitungan tersebut menggunakan perangkat software QGIS dengan plugin deepnes. Citra yang terbounding, selanjutnya diubah menjadi


centroid guna memudahkan dalam melakukan perhitungan jumlah sawit pada citra remote sensing.

HASIL DAN PEMBAHASAN

Pembentukan Dataset

Tiling

Proses pemotongan citra dari satu citra remote sensing geospasial area sebaran pohon sawit menghasilkan citra sebesar 63 tiles atau potongan citra. Selanjutnya hasil citra tiles ini dilakukan proses *image labelling*. Contoh hasil tiles citra sebaran pohon sawit terlihat pada (Gambar 3).



Gambar 3. Contoh hasil *tiling* citra sebaran pohon sawit

Image Labelling

Hasil tiles yang diperoleh sebanyak 63 tiles, namun yang dilakukan proses *image labelling* hanya sebanyak 16 tiles (Tabel 1.)

Augmentasi

Hasil proses augmentasi menggunakan enam teknik augmentasi

yaitu rotasi 90, rotasi 180, rotasi 270, *horizontal flip*, *vertikal flip* dan *bright* diperoleh sebesar 112 citra dari 16 citra asli, seperti terlihat pada (Tabel 2.). Augmentasi dataset dilakukan untuk meningkatkan jumlah dan variasi data, serta meningkatkan nilai akurasi model (Güler et al., 2025).

Tabel 1. Kelompok Citra sebaran Pohon sawit Masukan Label Kelas sebaran Pohon sawit

	Jumlah Citra
Sebaran pohon sawit	16 tiles

Tabel 2. Jumlah citra kelas sebaran pohon sawit dalam dataset

Label Kelas Citra	Citra Asli	Citra Hasil Augmentasi	Jumlah Citra Datase
Area sebaran Pohon Sawit	16	112	112

Tabel 3. Proporsi jumlah citra area sebaran pohon sawit

	Data pelatihan	Data validasi
Citra area sebaran pohon sawit	89	23

Splitting Dataset

Splitting dataset citra sebaran pohon sawit menggunakan teknik *stratified sampling* berhasil membagi dataset menjadi dataset latih dan dataset validasi menghasilkan prosorsi citra area sebaran pohon sawit ke dalam dua bagian, yaitu dataset latih dan dataset validasi. Jumlah citra latih sebanyak 89 citra, sedangkan citra validasi sebanyak 23 citra, terlihat pada (Tabel 3). *Splitting* dataset dilakukan untuk mengetahui kemampuan mesin *learning* dalam mengenaralisasi model dari gambar objek pohon sawit dan latar gambar yang bervariasi (Kamal & Mashaly, 2026).

Hasil Pemodelan Deteksi Area Sebaran Pohon Sawit

Pemodelan deteksi pohon sawit ini melalui tiga tahap. Pertama inisiasi model, kedua tuning hyperparameter, dan ketiga

pelatihan model. Hasil model YOLOv11n dalam mendeteksi citra pohon sawit pada suatu area dalam citra di dataset validasi terlihat nilai skor confidence mulai 0.3 hingga 0.9. confidence skor ini adalah hasil deteksi pada masing-masing pohon sawit. Nilai confidence skor 0.3 merupakan nilai deteksi yang sangat rendah pada penelitian ini, artinya model gagal dalam mendeteksi sawit, akan tetapi nilai confidence skor 0.9 merupakan skor tertinggi pada penelitian ini, memiliki makna bahwa model dapat mendeteksi pohon sawit yang terdapat di area dalam citra dengan baik. Nilai confidence skor ini tampak pada contoh (Gambar 4). Bounding box menunjukkan bahwa model mampu melakukan deteksi lokalisasi pohon sawit, kemudian ditandai dengan kata 'sawit 0.9' menunjukkan bahwa kata 'sawit' sebagai kelas dataset sawit dan nilai 0.9 sebagai confidence skor.



Gambar 4. Hasil deteksi model YOLOV11n pada dataset citra area sebaran pohon sawit

Tabel 4. Hasil perbandingan nilai presisi, recall, mAP50 dan mAP50-95 pada model YOLOv11n dengan beberapa jenis optimizer dan jumlah batch size

No	Model	Jumlah batch size	Optimizer	Presisi	Recall	mAP ₅₀	mAP ₅₀₋₉₅
1	YOLOv11n	8	SGD	0.934	0.954	0.968	0.616
2	YOLOv11n	16	SGD	0.923	0.968	0.973	0.624
3	YOLOv11n	32	SGD	0.916	0.940	0.946	0.499
4	YOLOv11n	8	Adam	0.933	0.943	0.961	0.558
5	YOLOv11n	16	Adam	0.077	0.947	0.336	0.119
6	YOLOv11n	32	Adam	0.080	0.975	0.66	0.281
7	YOLOv11n	8	Adamax	0.933	0.957	0.964	0.589
8	YOLOv11n	16	Adamax	0.937	0.965	0.967	0.602
9	YOLOv11n	32	Adamax	0.913	0.924	0.953	0.506
10	YOLOv11n	8	Nadam	0.914	0.919	0.945	0.509
11	YOLOv11n	16	Nadam	0.914	0.952	0.955	0.541
12	YOLOv11n	32	Nadam	0.0787	0.959	0.601	0.218
13	YOLOv11n	8	AdamW	0.943	0.941	0.961	0.558
14	YOLOv11n	16	AdamW	0.92	0.956	0.961	0.562
15	YOLOv11n	32	AdamW	0.775	0.945	0.511	0.158

```

100 epochs completed in 0.076 hours.
Optimizer stripped from /content/drive/MyDrive/hasil_training_sawit1_model/yolov11n_deteksi_sawit/weights/last.pt, 5.5MB
Optimizer stripped from /content/drive/MyDrive/hasil_training_sawit1_model/yolov11n_deteksi_sawit/weights/best.pt, 5.5MB

Validating /content/drive/MyDrive/hasil_training_sawit1_model/yolov11n_deteksi_sawit/weights/best.pt...
Ultralytics 8.4.67 Python-3.12.13 torch-2.11.0+cu128 CUDA:0 (Tesla T4, 14913MiB)
YOLO11n summary (fused): 101 layers, 2,582,347 parameters, 0 gradients, 6.3 GFLOPs
Class Images Instances Box(P R mAP50 mAP50-95): 100% 1/1 3.7it/s 0.3s
all 23 566 0.923 0.968 0.973 0.624

Speed: 0.2ms preprocess, 3.3ms inference, 0.0ms loss, 2.4ms postprocess per image
Results saved to /content/drive/MyDrive/hasil_training_sawit1_model/yolov11n_deteksi_sawit
ultralytics.utils.metrics.DetMetrics object with attributes:

```

Gambar 5 . mAP Matri

Hasil pelatihan arsitektur model YOLOV11n dengan tuning beberapa hyperparameter seperti terlihat pada Tabel 4. Hasil model YOLOV11n pada pelatihan model dengan beberapa jenis hyperparameter seperti tampak pada tabel 4 diperoleh model YOLOv11n dengan hyperparameter terbaik yaitu dengan jumlah batch size 16, optimizer SGD. Model ini dapat mendeteksi pohon sawit pada citra sebaran pohon sawit dalam dataset latih dan dataset validasi menghasilkan nilai presisi sebesar 0.923 atau 92.3% menunjukkan bahwa dari seluruh pohon sawit yang terdapat pada citra remote sensing area geospasial sebaran pohon sawit terdapat sebesar 92.3% terdeteksi dengan benar sebagai pohon sawit (Gambar 5).

Nilai *recall* sebesar 0.954 atau sebesar 95.4% menunjukkan bahwa dari semua objek pohon sawit sebanyak 95.4% yang berhasil ditemukan. mAP50 sebesar 0.973 atau 97.3% menunjukkan bahwa deteksi pohon sawit yang dilakukan dengan benar pada indeks IoU50% sebesar 97.3% (Gambar 5). Hasil penelitian (Duan et al., 2026) mendeteksi tongkol jagung dengan nilai AP₅₀ sebesar 95.4% menggunakan YOLOv11n, nilai presisi yang dihasilkan masih lebih rendah dengan selisih sebesar 1.4%. Warna objek deteksi berbeda warna

jika dibandingkan dengan warna pohon sawit yang hampir serupa dengan warna pohon lainnya di sekitar dengan warna yang sama hijau. Pohon sawit yang di deteksi juga terdapat pohon yang letaknya tumpang tindih antara pohon satu dengan lainnya, namun hasil deteksi masih lebih tinggi. Tongkol jagung berwarna agak putih gading hingga kekuning hijauan, memiliki warna yang berbeda dengan objek sekitarnya seperti misalnya warna daun yang cenderung warna hijau. Hal tersebut menunjukkan bahwa optimasi hyperparameter yang digunakan dalam mendeteksi pohon sawit ini jauh lebih optimal dengan hyperparameter yang digunakan dalam melatih dataset.

Selanjutnya mAP50-95 sebesar 0.624 atau 62.4%, terlihat pada (Gambar 5). Hal tersebut menunjukkan bahwa deteksi pohon sawit dianggap benar pada indeks IoU 50 hingga 90% yakni sebesar 62.4%. Nilai tersebut lebih rendah dibandingkan dengan mAP50% karena masih terdapat nilai confidence skor di bawah 50%, terlihat pada (Gambar 5).


Citra yang bersumber dari akuisisi penginderaan jauh atau *remote sensing* memiliki variasi skala yang signifikan, fitur dan kontur tepi bervariasi skala serta latar citra yang kompleks. Namun dengan hiperparameter tuning yang telah

diterapkan saat pelatihan dataset citra area sebaran pohon sawit menggunakan algoritma YOLOV11n mampu menangkap, mengidentifikasi dengan presisi serta sensitif dengan fitur dan kontur tepi multi skala sehingga pohon sawit dapat terdeteksi dengan presisi yang tinggi. Hasil kurva hubungan nilai presisi dan confidence terlihat pada (Gambar 6) bahwa nilai presisi linier positif terhadap tingkat nilai confidence. Semakin tinggi nilai presisi terjadi pada nilai confidence yang semakin meningkat. Nilai presisi yang dihasilkan sebesar 1.00 terhadap nilai confidence sebesar 0.92 (Gambar 6).


Kurva presisi-recall terlihat pada (Gambar 7) bahwa pada nilai presisi semakin menurun terhadap semakin meningkatnya nilai recall. Namun

menurunnya nilai presisi tidak terlalu besar, dan mencapai titik keseimbangan nilai presisi dan recall sebesar 0.973 pada mAP_{50} .



Hal tersebut menunjukkan bahwa model YOLOV11 masih terdapat error atau kesalahan dalam melakukan deteksi pohon sawit pada citra area sebaran pohon sawit. Hal ini tercermin juga pada nilai false positif dalam tabel confusion matrix. Kurva *recall-confidence* (Gambar 8) menunjukkan bahwa nilai *recall* mencapai sebesar 0.99 pada tingkat *confidence* 0.00. Hal tersebut membuktikan bahwa model YOLOv11n memiliki kemampuan yang handal dalam melakukan deteksi terhadap pohon sawit karena dapat mendeteksi pohon sawit sebesar 99% dari total pohon sawit yang terdapat pada citra dataset.



Gambar 6. Kurva presisi-confidence



Gambar 7. Kurva presisi-recall pada mAP_{50}



Gambar 10. Grafik loss dan metrik train dan validasi model YOLOV11n

Kurva f1 skor terhadap confidence (Gambar 9) menunjukkan bahwa nilai skor f1 sebesar 0.94 terhadap confidence sebesar 0.257. Gambar 11 menunjukkan metrik evaluasi untuk nilai loss pada pelatihan dan validasi model YOLOV11n. Nilai loss cenderung menurun hingga akhir pelatihan, sedangkan nilai presisi, recall, mAP50 dan mAP50-95 cenderung meningkat.


Selanjutnya metrik evaluasi lebih lanjut tampak pada tabel Confussion matriks (Gambar 10). Jumlah true positif 550 (prediksi sawit, true label sawit), false

negatif sebesar 44 (prediksi pohon sawit, true label baground), false positif sebesar 16 (prediksi background, true label pohon sawit) terlihat pada (Gambar 11). Namun masih terdapat loss dalam pendeteksian oleh model YOLOV11n mungkin kesulitan menangkap detail tepi halus dan petunjuk kontekstual yang diperlukan untuk membedakan pohon sawit dari elemen latar belakang seperti tumbuhan pohon selain sawit yang sama-sama tampak hijau dan merumpun. Oleh karena itu, mengidentifikasi pohon sawit yang disekitarnya tumbuh tanaman jenis


lainnya, umur dan pertumbuhan sawit yang tidak seragam, serta terletak rapat dalam gambar tetap menjadi tantangan utama. Kompleksitas yang terdapat dalam latar citra remote sensing yang sangat beragam seperti tampak terlihat tanah, rumput atau gulma.

Hal tersebut menjadi noise bagi objek pohon sawit. Hal ini dapat berakibat

menimbulkan kesalahan dalam mendeteksi pohon sawit. Akan tetapi terlihat nilai confusion matrix bahwa terdapat false negatif sebesar 44 yang terdeteksi sebagai pohon sawit, padahal senyatanya adalah background atau latar citra. Kemudian terdapat false negatif sebanyak 16 citra pohon sawit yang terdeteksi sebagai latar citra.



Gambar 11. Confussion matrix model YOLOV11n



Gambar 12. Layout peta sebaran geospasial pohon kelapa sawit

Hasil Evaluasi Uji Model Serta Perhitungan Jumlah Pohon Sawit Secara Otomatis

Model yang diperoleh dari hasil pelatihan digunakan kembali pada proses evaluasi model untuk menghasilkan deteksi citra remote sensing area geospasial sebaran pohon sawit. Model YOLOV11n dari hasil pelatihan untuk mendeteksi citra remote sensing area geospasial sebaran pohon sawit menggunakan perangkat Google colabs, kemudian melakukan evaluasi model tersebut menggunakan citra dataset baru guna melihat performa hasil deteksi pohon sawit menggunakan perangkat QGIS pada plugin deepnes. Perangkat QGIS juga telah digunakan untuk menghitung radiasi matahari (Ilba, 2025). Hasil evaluasi model menyatakan bahwa deepnes dapat melakukan deteksi kembali hasil dari deteksi menggunakan model YOLOV11n dengan hasil deteksi pada seluruh area citra remote sensing dapat terbounding hampir semua pohon sawit di semua region sebaran pohon sawit pada citra. Citra remote sensing sebaran geospasial sawit dapat dilakukan perhitungan jumlah pohon sawit dengan hasil yang diperoleh sebanyak 3867 pohon sawit. Citra remote sensing area sebaran geospasial pohon sawit yang terdeteksi

dan terhitung jumlah pohon sawit terlihat pada (Gambar 12).

KESIMPULAN DAN SARAN

Citra remote sensing sebaran geospasial pohon sawit dapat terdeteksi dengan akurasi tinggi menggunakan model YOLOV11n dengan hasil precision yakni sebesar 93.4%, recall sebesar 95.4%, mAP50 sebesar 96.8% dan mAP50-90 sebesar 61.6%. Model YOLOV11n mampu melakukan deteksi dan perhitungan pohon sawit pada citra hasil remote sensing dengan performa yang tinggi pada latar citra berupa pohon selain sawit yang memiliki kesamaan warna yang hampir serupa dengan pohon sawit. Penelitian lebih lanjut perlu penambahan jumlah dataset agar akurasi lebih meningkat.

DAFTAR PUSTAKA

- Duan, Z., Jin, X., Yu, X., Ruan, X., Zhu, Y., & Jiang, T. 2026. Smart Agricultural Technology ABE-YOLO : A lightweight and efficient model for maize ear detection. *Smart Agricultural Technology*, 14(April), 102125. doi: 10.1016/j.atech.2026.102125
- Güler, O., Etem, T., & Teke, M. 2025. Hybrid augmentation for multi-channel deep learning in guava leaf disease detection. *Ain Shams Engineering Journal*, 16(11), 103716. doi: 10.1016/j.asej.2025.103716

- Ilba, M., 2025. *SoftwareX SolarQGIS: A QGIS application for calculating solar radiation on 3D vector GIS data*. 31(June), 0–6.
- Kamal, H., & Mashaly, M. 2026. ScienceDirect Advanced Anomaly Detection for Intrusion Detection Systems Using a Combined Dataset with a Hybrid Deep Learning Model. *Procedia Computer Science*, 280, 42–51. doi: 10.1016/j.procs.2026.04.007
- Tahir, N. U. A., Long, Z., Zhang, Z., Asim, M., & ELAffendi, M. 2024. PVswin-YOLOv8s: UAV-Based Pedestrian and Vehicle Detection for Traffic Management in Smart Cities Using Improved YOLOv8. *Drones*, 8(3), 1–20. doi: 10.3390/drones8030084
- Genoveva, Z. and Syah, R.D., 2024. ‘Model Machine Learning Untuk Deteksi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Metode YOLOv8’, *Jurnal Pertanian Presisi (Journal of Precision Agriculture)*, 8(2), 121–136. doi:10.35760/jpp.2024.v8i2.11848.
- Hajjaji, Y. et al., 2025. ‘Enhancing palm precision agriculture: An approach based on deep learning and UAVs for efficient palm tree detection’, *Ecological Informatics*, 85(August 2023). doi: 10.1016/j.ecoinf.2024.102952.
- Hasibuan, H.A., 2021. ‘Processing and Palm Oil-Based Food Product Development Opportunities In Indonesia’, *Jurnal Penelitian dan Pengembangan Pertanian*, 40(2), p. 111. doi: 10.21082/jp3.v40n2.2021.p111-124.
- Josdaan, J. et al., 2024. ‘Revolutionizing palm oil ripeness classification: Utilizing YOLOv8 for ultra-precise ripeness detection’, *Procedia Computer Science*, 245(C), 700–709. doi: 10.1016/j.procs.2024.10.296.
- Shibo, Y., Pan, L. and Buhari, A., 2025. ‘Edge-Guided Multi-Scale YOLOv11n : An Advanced Framework for Accurate Ship Detection in Remote Sensing Imagery’, 16(8), 249–256.