



Implementasi Model YOLOv5 untuk Estimasi Jumlah Tanaman Kelapa Sawit (*Elaeis guineensis* Jacq.)

Implementation of YOLOv5 for Estimating the Number of Oil Palm (*Elaeis guineensis* Jacq.) Trees

Mukhes Sri Muna¹, Muhdan Syarovy, Suwardi³, Andri Prima Nugroho², Lilik Sutiarto²,
Yohanes Setiyo¹, dan I Putu Surya Wirawan¹

Abstrak Deteksi dan estimasi jumlah tanaman kelapa sawit merupakan aspek penting dalam pengelolaan perkebunan. Metode konvensional yang mengandalkan pencatatan manual memiliki kelemahan dalam hal efisiensi, akurasi, dan biaya. Oleh karena itu, penelitian ini mengimplementasikan model YOLOv5 sebagai pendekatan berbasis *deep learning* untuk mendeteksi tanaman kelapa sawit dari citra udara. *Dataset* yang digunakan dalam penelitian ini diperoleh dari gambar hasil foto udara perkebunan kelapa sawit PT Kerry Sawit Indonesia (KSY) 1 dan telah melalui tahapan pra-pemrosesan, pelabelan, serta pelatihan menggunakan Google Colaborator. Evaluasi dilakukan dengan menggunakan data uji dari gambar hasil foto udara kebun percobaan Pusat Penelitian Kelapa Sawit. Hasil evaluasi menunjukkan bahwa model YOLOv5 memiliki tingkat akurasi sebesar 96,85%, presisi 98,48%, *recall* 98,32%, dan *F1-score* 98,40%. Dibandingkan dengan metode sebelumnya, YOLOv5 menunjukkan keseimbangan antara kecepatan deteksi dan akurasi yang tinggi, menjadikannya solusi yang lebih efektif untuk estimasi jumlah tanaman kelapa sawit dalam skala besar.

Kata kunci: *Deep Learning*, Deteksi Objek, Foto Udara, YOLO

Abstract Detection and estimation of oil palm tree populations are essential aspects of plantation management. Conventional methods that rely on manual recording have limitations in terms of efficiency, accuracy, and cost. Therefore, this study implements the YOLOv5 model as a deep learning-based approach to detect oil palm trees from aerial imagery. The dataset used in this study was obtained from aerial photographs of oil palm plantations owned by PT Kerry Sawit Indonesia (KSY) 1 and underwent preprocessing, labeling, and training using Google Colaboratory. The model was evaluated using test data from aerial photographs of the experimental plantation at the Indonesian Oil Palm Research Institute. The evaluation results indicate that the YOLOv5 model achieved an accuracy of 96.85%, precision of 98.48%, recall of 98.32%, and an F1-score of 98.40%. Compared to previous methods, YOLOv5 demonstrates a strong balance between detection speed and high accuracy, making it a more effective solution for large-scale oil palm tree population estimation.

Keywords: *Aerial Imagery, Deep Learning, Object Detection, YOLO*

PENDAHULUAN

Pada pengelolaan perkebunan kelapa sawit, data jumlah pokok tanaman sangat penting karena informasi ini digunakan dalam berbagai kegiatan operasional, seperti perencanaan pemupukan, prediksi produksi, evaluasi kesehatan tanaman dan alokasi tenaga kerja (Inderiati, 2023; Ngapiyatun *et al.*, 2023; Wardah, 2017). Pengumpulan data jumlah tanaman dilakukan secara berkala karena tanaman dapat mengalami kematian akibat penyakit, stres, atau drainase yang buruk. Hingga saat ini, pengumpulan

Penulis yang tidak disertai dengan catatan kaki instansi adalah peneliti pada Pusat Penelitian Kelapa Sawit

Mukhes Sri Muna^{*} (✉)

¹Teknik Pertanian dan Biosistem, Universitas Udayana, Bali, Indonesia

²Teknik Pertanian dan Biosistem, Universitas Gadjah Mada, Yogyakarta, Indonesia

³PT. Kerry Sawit Indonesia 1, Palangkaraya, Indonesia

Email: mukhessrimuna@unud.ac.id

data tersebut masih mengandalkan metode manual atau *terrestrial* yang memiliki beberapa kelemahan, seperti biaya tenaga kerja yang tinggi, penggunaan waktu yang tidak efisien, keterbatasan area yang dapat dijangkau, serta kemungkinan kesalahan dalam pengumpulan data oleh petugas akibat kelelahan atau kekurangan tenaga kerja terampil (Morrison, 2021; Morrison & Young, 2016).

Seiring dengan berkembangnya teknologi, penggabungan teknologi penginderaan jauh dengan *computer vision* telah banyak digunakan untuk menggantikan metode manual dalam pengumpulan data jumlah tanaman kelapa sawit (Ayoub Shaikh *et al.*, 2022). *Unmanned Aerial Vehicle* (UAV), sebagai bagian dari penginderaan jauh, sangat efektif dalam mengambil foto udara dengan kualitas sedang hingga tinggi, dan memberikan data spasial yang lebih detail (Hartling *et al.*, 2019). Selanjutnya, teknologi *computer vision* dapat digunakan untuk interpretasi visual guna mendeteksi tanaman atau kanopi kelapa sawit, sehingga memudahkan dalam memperoleh data jumlah tanaman (El Hoummaid *et al.*, 2021).

Penggunaan *computer vision* untuk mendeteksi tanaman kelapa sawit dari citra udara telah banyak diterapkan sebelumnya. Awalnya, metode sederhana seperti *local maximum filter*, *image binarization*, *scale analysis*, *template matching*, *semi-variogram computation* dan *non maximum suppression* (Ke & Quackenbush, 2011; Pouliot *et al.*, 2002; Srestasathien & Rakwatin, 2014). Lebih lanjut, beberapa peneliti mulai menerapkan metode *machine learning* untuk tugas ini, seperti *Scale-Invariant Feature Transformation* (SIFT) dan *supervised extreme learning machine classifier* (Malek *et al.*, 2014). Namun demikian, penelitian-penelitian tersebut umumnya hanya berfokus pada deteksi tanaman kelapa sawit yang tidak terlalu padat, sehingga pada tanaman dengan kerapatan tinggi, metode-metode ini mengalami penurunan kinerja. Sebagai contoh, metode *template matching* tidak efektif dalam mendeteksi tanaman dengan kanopi yang saling tumpang tindih (Shafri *et al.*, 2002), sementara metode *local maximum filter* tidak dapat mendeteksi tanaman muda atau yang berukuran kecil (Pouliot *et al.*, 2002).

Dengan berkembangnya *computer vision*, model *Convolutional Neural Network* (CNN), yang merupakan bagian dari metode *deep learning*, telah banyak diaplikasikan untuk tugas deteksi objek. Model

ini terkenal karena memiliki akurasi yang tinggi, memerlukan sedikit intervensi pengguna, serta mampu beradaptasi di berbagai bidang, seperti klasifikasi gambar, pengenalan wajah, dan lainnya (Boyagoda & Da Silva, 2020). CNN juga telah banyak diterapkan dalam mendeteksi tanaman kelapa sawit. Li *et al.* (2017) menggunakan CNN untuk mengekstraksi fitur dari citra udara, dengan pendekatan *sliding window* untuk mengklasifikasikan tiap bagian gambar apakah mengandung pohon kelapa sawit atau tidak. Meskipun hasil yang diperoleh lebih baik dibandingkan metode *machine learning* dan tradisional, pendekatan tersebut masih memerlukan penggabungan sampel untuk mendeteksi satu objek, yang membuatnya kurang efisien.

Sementara itu, Djerriri *et al.* (2018) mengajukan penggunaan model *Regression Convolutional Neural Network* (R-CNN) untuk tugas serupa, namun kinerjanya bergantung pada kualitas dan resolusi citra udara. Sementara itu, Zheng *et al.* (2019) memperkenalkan model *Regional Proposal Network* (RPN) untuk deteksi kelapa sawit dalam citra udara, yang merupakan pengembangan dari model *Fast R-CNN*, atau dikenal sebagai *Faster R-CNN*. Model ini menawarkan peningkatan dalam hal recall, akurasi rata-rata, dan kecepatan pemrosesan. Namun demikian, meskipun *Faster R-CNN* memberikan hasil yang lebih baik, model ini masih sulit diterapkan untuk deteksi waktu nyata dan mungkin kurang efektif pada gambar dengan tanaman yang padat. Secara keseluruhan, kelemahan utama dari model-model tersebut adalah kompleksitas komputasi yang tinggi dan ketidakmampuan menghasilkan hasil waktu nyata pada citra beresolusi tinggi.

Redmon *et al.* (2016) pertama kali memperkenalkan YOLO (*You Only Look Once*) versi 1 (YOLOv1), sebuah model deteksi objek yang inovatif karena mampu mendeteksi objek dalam gambar secara *real time* dengan satu tahap prediksi. Meskipun cepat, YOLOv1 memiliki keterbatasan dalam mendeteksi objek kecil dan tidak terlalu akurat dalam kasus objek yang berdekatan. Untuk mengatasi kelemahan ini, kemudian mengembangkan YOLO versi 2 (YOLOv2), yang membawa peningkatan signifikan dalam hal akurasi dan kemampuan deteksi objek kecil.

Selanjutnya, Redmon & Farhadi (2018) meluncurkan YOLO versi 3 (YOLOv3), yang lebih

lanjut menyempurnakan kemampuan model dalam mendeteksi objek kecil dengan memperkenalkan arsitektur yang lebih dalam dan menggunakan prediksi multi skala. YOLOv3 juga menawarkan kinerja yang lebih baik dari pendahulunya dalam hal kecepatan, akurasi, dan efisiensi komputasi, serta lebih mudah dimodifikasi (Tan *et al.*, 2021). Namun demikian, seiring dengan perkembangannya, algoritma YOLOv5 telah dikembangkan dan menawarkan solusi lebih cepat dan akurat dalam mendeteksi objek dari citra. YOLOv5 merupakan model *deep learning* yang dioptimalkan untuk deteksi objek dalam gambar dengan kecepatan yang sangat tinggi dan akurasi yang teruji dalam berbagai bidang, termasuk pengolahan citra satelit dan drone (Hofinger *et al.*, 2023; Redmon *et al.*, 2016).

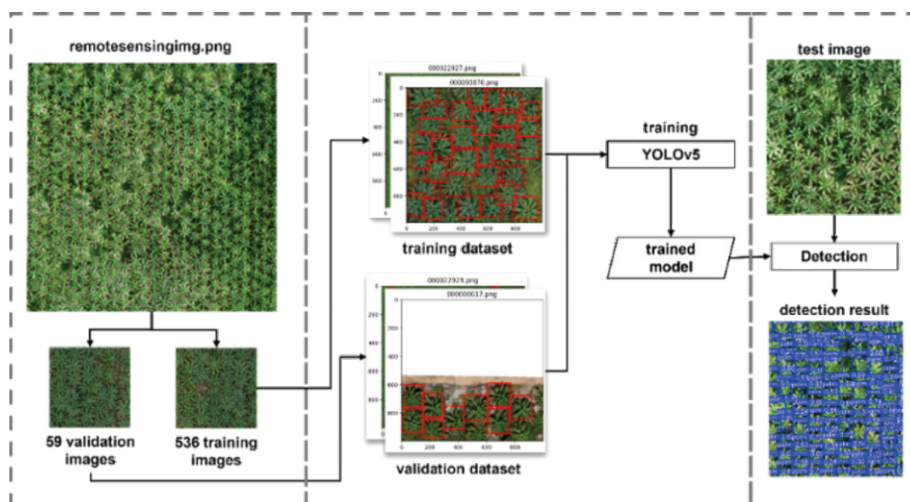
Beberapa penelitian telah menunjukkan keunggulan YOLOv5 dalam sektor pertanian. Misalnya, dalam deteksi dan penghitungan tanaman (Bhavan & Mohana, 2022), serta pemantauan kesehatan pohon dalam hutan produksi menggunakan citra drone (Hofinger *et al.*, 2023). Penelitian lain yang dilakukan oleh Zhou *et al.* (2023) menunjukkan bahwa penggunaan YOLOv5 dapat mempercepat dan meningkatkan akurasi deteksi tanaman pada lahan perkebunan besar dibandingkan dengan model deteksi konvensional. Walaupun teknologi ini telah banyak diaplikasikan dalam berbagai bidang pertanian, penerapan khusus pada kelapa sawit masih

relatif jarang, sehingga eksplorasi lebih lanjut sangat diperlukan.

Dengan potensi luas dalam pengelolaan perkebunan, penerapan YOLOv5 dalam deteksi dan estimasi jumlah pokok tanaman kelapa sawit berbasis citra udara atau drone diharapkan mampu meningkatkan efisiensi operasional di sektor perkebunan kelapa sawit. Penelitian ini bertujuan untuk mengembangkan model berbasis YOLOv5 guna menghitung pokok kelapa sawit secara otomatis melalui teknologi citra, sekaligus mengevaluasi keakuratan dan efektivitas model tersebut dalam berbagai kondisi lapangan.

BAHAN DAN METODE

Alur penelitian implementasi model YOLOv5 untuk pengembangan sistem deteksi tanaman kelapa sawit disajikan pada Gambar 1. Penelitian ini merupakan penelitian lanjutan dari pengembangan sistem deteksi tanaman kelapa sawit berbasis metode *deep learning* yang menggunakan model YOLOv3 (Muna *et al.*, 2023). Penelitian ini terdiri dari 3 tahapan utama: *pre-processing data*, proses pelatihan, dan proses deteksi. Data yang digunakan adalah data sekunder yang terbagi menjadi 2 jenis, pertama adalah sekumpulan data (*dataset*) untuk pelatihan dan validasi, kedua adalah data untuk uji dalam proses deteksi.

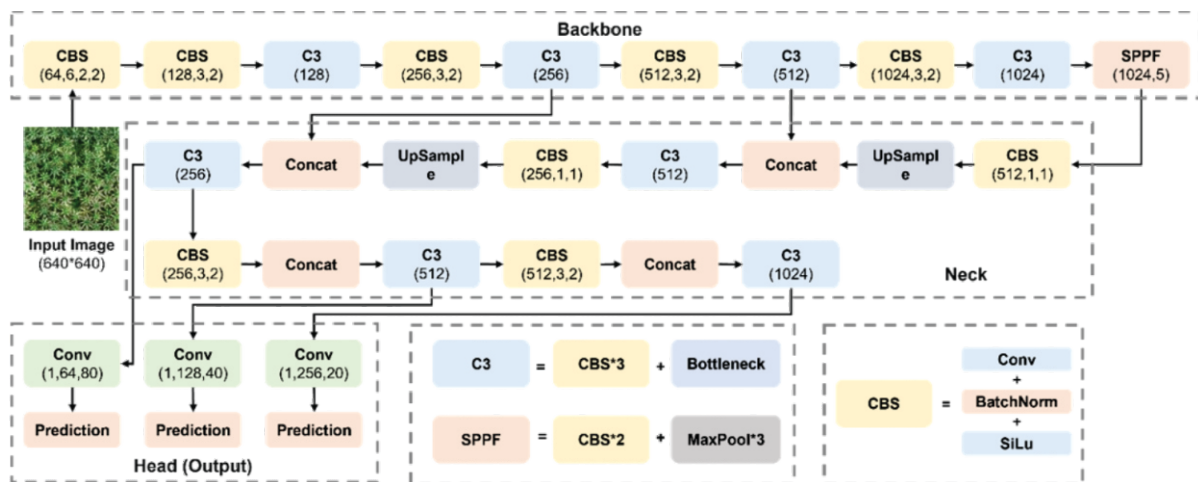


Gambar 1. Alur Proses Penelitian.
Figure 1. Research Flow Process.

Pre-processing Data. Tahap ini mempersiapkan *dataset* pelatihan dan validasi dari gambar udara, yang disimpan dalam format (.png) dan dibagi menjadi bagian-bagian kecil berukuran 1.000 x 1.000 piksel. *Dataset* yang dihasilkan terdiri dari 535 gambar untuk pelatihan dan 60 gambar untuk validasi. *Dataset* ini diperoleh dari gambar foto udara perkebunan kelapa sawit PT. Kerry Sawit Indonesia (KSY) 1 di Baung, Seruyan, Kalimantan Tengah. Setiap gambar diberikan label dengan *bounding box* (format YOLO) untuk setiap pohon, menggunakan aplikasi Labellmg (versi 1.8.6), dan disimpan sebagai file anotasi (.txt).

Training Process. Pada tahap ini dilakukan

menggunakan *Google Collaborator*, yang dapat dijalankan secara gratis dan didukung oleh sumber daya komputasi tinggi seperti GPU (*Graphic Processing Unit*) dan TPU (*Tensor Processing Unit*) dari *server Google*, dan dijalankan langsung melalui *browser* (Bisong, 2019). Tahap ini menggunakan *dataset* yang telah disiapkan pada tahap sebelumnya (*Pre-processing Data*). *Dataset* tersebut dibutuhkan untuk melatih dan memvalidasi model YOLO v5. Arsitektur model dapat dilihat pada Gambar 2 yang terdiri dari bagian utama: *backbone*, *neck* dan *head*. Proses *training* yang dilakukan pada penelitian ini menggunakan *hyper parameters* sebagai berikut: *batch size* = 16, *learning rate* = 0,001 dan *epoch* = 100.



Gambar 2. Arsitektur YOLO-5n.
Figure 2. YOLO-5n Architecture.

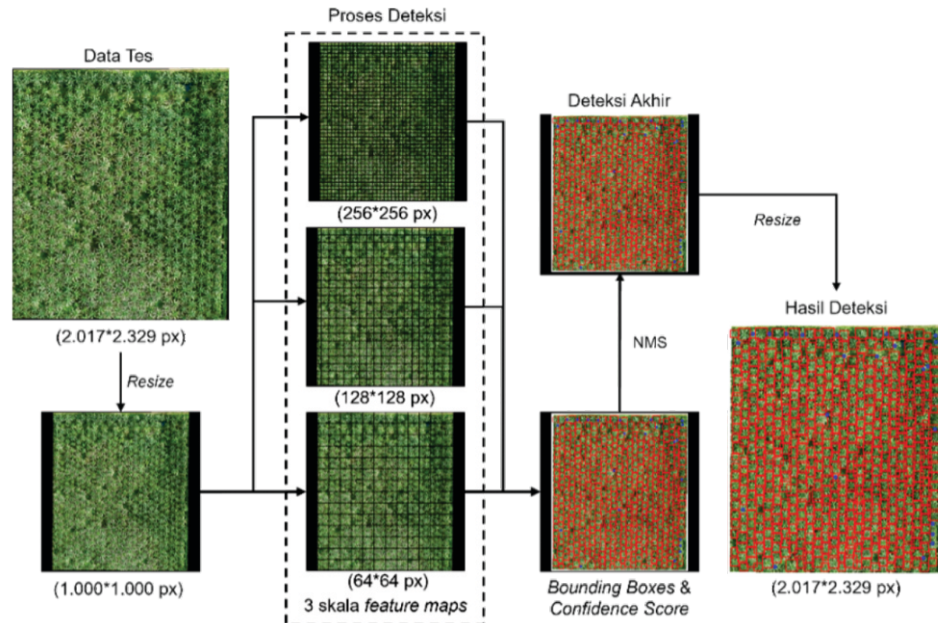
Struktur *backbone* model YOLOv5 terdiri dari modul CBS (Conv + BatchNorm + SiLU), modul C3, dan diakhiri dengan modul SPPF. Modul CBS mendukung C3 dalam ekstraksi fitur, sedangkan SPPF meningkatkan kemampuan backbone. Modul C3, terinspirasi dari *Cross Stage Partial Network* (CSPNet) (Wang *et al.*, 2020), penting untuk mengekstraksi fitur tingkat tinggi, mempertahankan akurasi, dan mempercepat pemrosesan. Di bagian *neck*, YOLOv5 menggunakan *Feature Pyramid Network* (FPN) dan *Path Aggregation Network* (PANet) (Liu *et al.*, 2018) untuk menghasilkan piramida fitur yang membantu model mengenali objek dengan berbagai ukuran dan skala. Pada bagian *head*, model mendeteksi objek menggunakan *anchor boxes* pada peta fitur terakhir, menghasilkan vektor output yang mencakup skor objektivitas dan kelas.

Detecting Process. Model yang telah terlatih digunakan untuk mendeteksi tanaman kelapa sawit pada data uji berformat GeoTIFF yang mengandung informasi geografis (Jakacki *et al.*, 2020). Alur deteksi ditampilkan pada Gambar 3, dimana data uji diubah ukurannya sebelum dilakukan deteksi. Model mendeteksi objek pada 3 skala gambar, menghasilkan *bounding box* yang menunjukkan keberadaan tanaman kelapa sawit. Proses *non-maximum suppression* (NMS) kemudian digunakan untuk memilih satu *bounding box* dari beberapa yang saling tumpang tindih pada objek yang sama. Setelah NMS, sejumlah objek (tanaman kelapa sawit) terdeteksi, dan data uji dikembalikan ke ukuran semula.

Data uji yang digunakan berukuran 2.017 x 2.329

piksel yang berasal dari kebun percobaan Pusat Penelitian Kelapa Sawit di Tanjung Morawa, Deli Serdang, Sumatera Utara. Ukuran data uji selanjutnya diubah menjadi 1.000×1.000 piksel menggunakan teknik *padding* tanpa mengubah rasio asli. Data uji kemudian diproses melalui ekstraksi

fitur untuk menghasilkan *feature maps* dengan ukuran 512×512 , 256×256 , dan 128×128 untuk prediksi. *Feature map* 512×512 digunakan untuk mendeteksi tanaman kelapa sawit kecil, 256×256 untuk ukuran sedang, dan 128×128 untuk ukuran besar.




Gambar 3. Alur Proses Deteksi Tanaman Kelapa Sawit.
Figure 3. Palm Oil Plantation Crop Detection Process Flow.

Pada setiap skala prediksi, setiap sel *feature map* memprediksi tiga *bounding box* menggunakan *anchor box* yang dipelajari selama pelatihan. Setiap *bounding box* berisi koordinat (x, y), lebar, tinggi, *confidence score*, dan *class probability*. Jika *confidence score* rendah atau nol, *bounding box* dianggap tidak mengandung objek. *Bounding box* dengan *confidence score* rendah dapat dihapus menggunakan nilai ambang batas untuk mengurangi *false positif*. Selanjutnya, dilakukan *Non-Maximum Suppression* (NMS) untuk menghapus *bounding box* yang berlebihan dan menskalakan ulang hasil deteksi ke ukuran gambar asli.

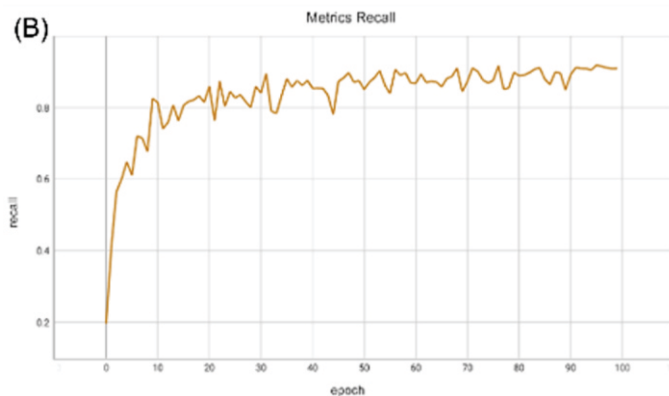
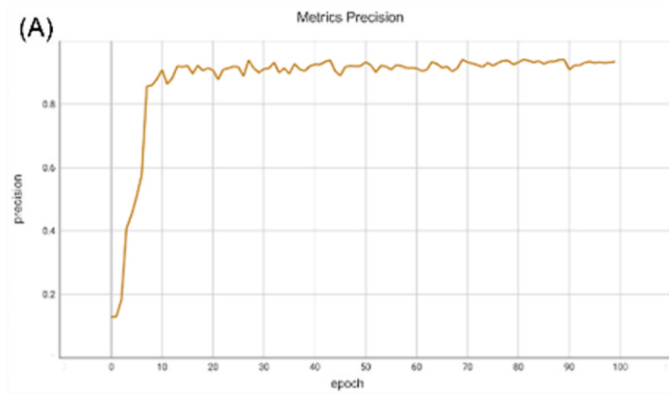
HASIL DAN PEMBAHASAN

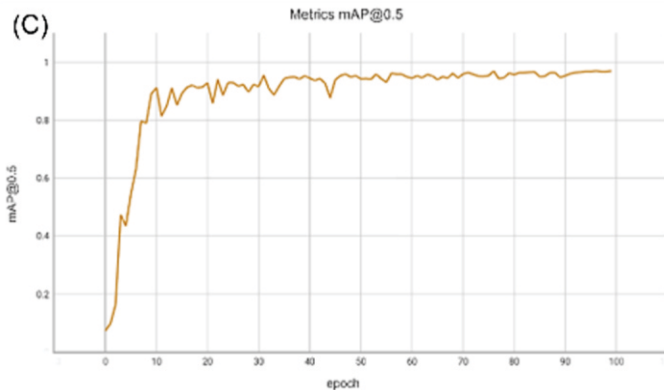
Hasil dari proses *training* model YOLOv5 tanaman kelapa sawit disajikan dalam *confusion*

matrix, *performance metrics* dan *loss*. *Confusion matrix* model YOLOv5 pada epoch terakhir dapat dilihat pada Gambar 4. Nilai *true positive* (TP) diperoleh sebesar 0,97 yang menunjukkan bahwa model dapat mendeteksi tanaman kelapa sawit dengan benar. Nilai *false negative* (FN) sebesar 0,03 yang menunjukkan bahwa model berhasil mendeteksi namun tanpa kelas. Nilai *false positive* (FP) sebesar 1 yang menunjukkan bahwa semua kesalahan deteksi oleh model pada *background* (latar belakang). Hal ini disebabkan karena hanya ada satu kelas (kelapa sawit) sehingga proses deteksi tidak cocok dengan label sebenarnya (*ground truth*) dan nilainya adalah 1. Sementara itu, Nilai *True Negatives* (TN) di *background* mengacu pada objek sebenarnya (*ground truth*) yang tidak dapat terdeteksi oleh model. Hal ini ditunjukkan dengan nilai yang kosong atau nol.



Gambar 4. Matriks Konfusi
Figure 4. Confusion Matrix

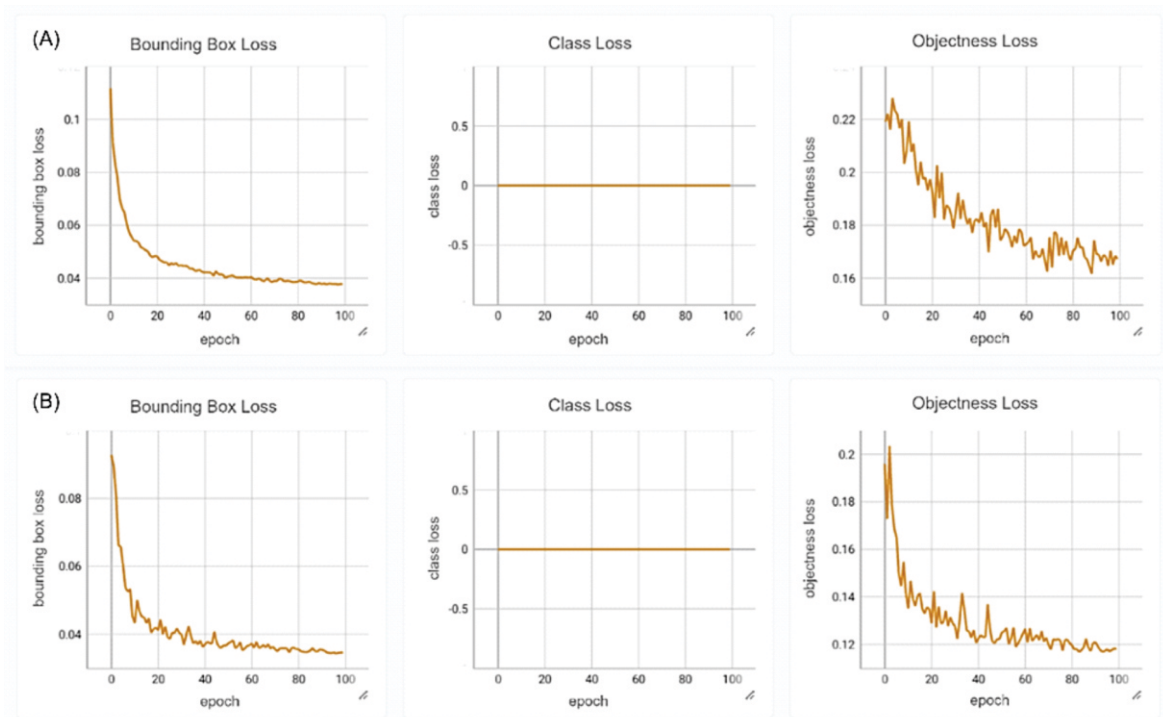




Gambar 5. Metrik Performa: Ketepatan (A), Daya Ingat (B), dan mAP@0,5 (C).
 Figure 5. Performance Metrics: Precision (A), Recall (B), dan mAP@0.5 (C).

Performance metrics yang digunakan pada proses training yaitu precision (a), recall (b) dan Mean Average Precision/mAP@0,5 (c), disajikan pada Gambar 5. Metric precision yang diperoleh sebesar 0,9344, recall sebesar 0,9099 dan mAP@0,5 sebesar 0,9694 pada akhir epoch. Apabila hasil tersebut dibandingkan dengan penelitian dari (Jintasuttisak *et al.* (2022) yang menggunakan model YOLOv5 untuk mendeteksi tanaman kurma (*date palm*), hasil dari penelitian kali ini

memiliki kesamaan nilai metrics precision, recall, dan mAP@0,5 sebesar >0,90. Selain itu, terlihat pada Gambar 5 metrik performa mengalami kenaikan dari awal hingga akhir epoch. Hal tersebut menunjukkan bahwa tidak terjadi *overfitting* dan *underfitting* pada proses *training model*, atau disebut kondisi *correct fitting*. Sehingga proses pembelajaran model dapat berjalan dengan baik untuk menghasilkan model yang siap untuk mendeteksi tanaman kelapa sawit.




Gambar 6. Nilai Kerugian Selama Proses Pelatihan (A) dan Validasi (B).
 Figure 6. The Value of Loss During the Training (A) and Validation Process (B).

Loss selama proses pelatihan dan validasi pada penelitian ini terdiri dari 3 komponen, yaitu *bounding box*, *class* dan *objectness loss* yang disajikan pada Gambar 6. Pada grafik *bounding box* dan *objectness loss* baik pada proses *training* dan *validation* menunjukkan penurunan nilai loss mendekati 0 dari awal hingga akhir epoch. Hal tersebut menunjukkan bahwa terjadinya penurunan error atau kesalahan deteksi *bounding box* dan object seiring berjalannya proses *training* dan *validation*. Sedangkan grafik pada class loss menunjukkan nilai 0 dari awal hingga akhir proses

training dan *validation*, hal ini karena hanya digunakan satu kelas (kelapa sawit) sehingga tidak ada proses klasifikasi antar kelas. Secara keseluruhan, proses *training* dan *validation* berjalan dengan baik, ditunjukkan pada nilai loss sebesar 0,0000 - 0,1672.

Setelah melalui proses *training* dan *validation*, maka dihasilkan model deteksi tanaman kelapa sawit yang siap digunakan. Model tersebut diuji untuk mendeteksi tanaman kelapa sawit dalam gambar hasil foto udara (*data test*) dengan luas sebesar 5,76 hektare.



Gambar 7. Visualisasi Hasil Deteksi Model YOLOv5. Kotak biru = pohon yang berhasil terdeteksi oleh model. Titik merah = pohon yang tidak berhasil terdeteksi oleh model.

Figure 7. Visualization of YOLOv5 Model Detection Results. Blue box = tree successfully detected by the model. Red dot = tree not successfully detected by the model.

Hasil deteksi disajikan pada Gambar 7, dapat dilihat hampir semua tanaman pada *data test* dapat terdeteksi oleh model dan beberapa tanaman kelapa sawit tidak dapat terdeteksi. Dari hasil deteksi model, selanjutnya dilakukan deteksi secara manual untuk melakukan validasi dengan *confusion matrix* dan *performance metrics*. Hasil deteksi tersebut disajikan

ke dalam *confusion matrix* dan *performance metrics* pada Tabel 1. yang menunjukkan bahwa *performance metrics* (*accuracy*, *precision*, *recall* dan *F1-score*) memiliki nilai dalam rentang 96 – 99%. Nilai ini menunjukkan bahwa model yang dikembangkan memiliki performa yang sangat baik dalam mendeteksi tanaman kelapa sawit.

Tabel 1. Matriks Konfusi Hasil Deteksi Model Tanaman Kelapa Sawit.

Table 1. Confusion Matrix of Palm Oil Plant Detection Model Results.

Confusion Matrix	Hasil Deteksi Model	Performance Metrics	Performance Metrics Values
True Positive	584	Accuracy	96,85%
True Negative	0	Precision	98,48%
False Positive	9	Recall	98,32%
False Negative	10	F1-Score	98,40%

Terdapat beberapa penelitian sebelumnya tentang pengembangan model deteksi tanaman kelapa sawit dengan menggunakan beberapa model yang berbeda, diantaranya *Artificial Neural Network* (ANN), *Convolutional Neural Network* (CNN), *Faster R-CNN* dan YOLOv3. Sehingga untuk mengetahui perbandingan performa model pada penelitian ini (YOLOv5), maka dapat dilihat pada Tabel 2. yang menyajikan hasil *performance metrics* penelitian sebelumnya dengan hasil penelitian kali ini.

Berdasarkan Tabel 2, terlihat model *Faster R-CNN* dan CNN LeNet menunjukkan performa yang baik dengan masing-masing akurasi 94,64% dan 97,64%, serta F1-Score 97,25% dan 92,71%. Namun demikian, kedua model ini masih kalah bersaing dengan model YOLO (YOLOv3 dan YOLOv5). Model ANN mencatat performa terendah, dengan akurasi 88,55%, presisi 91,56%, recall 96,43%, dan F1-Score 93,93%, menunjukkan kemampuan deteksi yang lebih

terbatas dibandingkan model lainnya. Model YOLOv3 menunjukkan hasil terbaik secara keseluruhan dengan akurasi 98,32%, presisi 100%, recall 98,32%, dan F1-Score 99,15%. Model ini unggul dalam mendeteksi objek dengan tingkat akurasi yang sangat tinggi. Secara performa, YOLOv3 mengungguli model YOLOv5 yang berada di posisi kedua dengan akurasi 96,85%, presisi 98,48%, recall 98,32%, dan F1-Score 98,40%, yang sedikit lebih rendah dibanding YOLOv3 tetapi tetap menunjukkan performa yang juga sangat baik. Namun dari hasil kecepatan deteksi yang diperoleh, model YOLOv5 memiliki keunggulan dibandingkan dengan model YOLOv3. Model YOLOv5 memiliki kecepatan deteksi setiap obyek (tanaman kelapa sawit) sebesar 28 ms, sedangkan model YOLOv3 hanya sebesar 35 ms. Secara keseluruhan, YOLOv3 dan YOLOv5 merupakan pilihan terbaik untuk mendeteksi tanaman kelapa sawit yang membutuhkan tingkat presisi dan recall tinggi tanpa mengorbankan keseimbangan performa.

Tabel 2. Perbandingan Hasil Metrik Performa Beberapa Model Deteksi Tanaman Kelapa Sawit.
 Table 2. Comparison of Performance Metric Results of Several Oil Palm Detection Models.

Performance Metrics	ANN	CNN	Faster R-CNN	YOLOv3	YOLOv5 (Hasil Penelitian)
	(Li et al., 2017)	(Mubin et al., 2019)	(Zheng et al., 2019)	(Muna et al., 2023)	
	Accuracy	88,55%	97,64%	94,64%	98,32%
Precision	91,56%	88,12%	96,52%	100,00%	98,48%
Recall	96,43%	97,80%	97,98%	98,32%	98,32%
F1-Score	93,93%	92,71%	97,25%	99,15%	98,40%

KESIMPULAN

Penelitian ini membuktikan bahwa model YOLOv5 dapat digunakan secara efektif untuk mendeteksi dan estimasi jumlah tanaman kelapa sawit dari citra udara. Model ini menghasilkan akurasi yang tinggi dengan nilai precision 98,48%, recall 98,32%, dan F1-score 98,40%. Dibandingkan dengan metode deteksi lainnya seperti ANN, CNN, dan *Faster R-CNN*, YOLOv5 menawarkan keseimbangan optimal antara kecepatan dan akurasi deteksi. Keunggulan utama dari model ini adalah kemampuannya dalam mendeteksi objek secara real-time dengan waktu deteksi rata-rata 28 ms per tanaman, lebih cepat dibandingkan YOLOv3 yang membutuhkan 35 ms. Dengan demikian, penerapan YOLOv5 dapat meningkatkan efisiensi operasional dalam pengelolaan perkebunan kelapa sawit, khususnya dalam penghitungan jumlah pokok tanaman secara otomatis dan presisi tinggi.

DAFTAR PUSTAKA

Ayoub Shaikh, T., Rasool, T., & Rasheed Lone, F. (2022). Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming. *Computers and Electronics in Agriculture*, 198(June 2021), 107119.

Bhavan, S. A., & Mohana. (2022). YOLOv5 Crop Detection Deep Learning Model using Artificial Intelligence (AI) and Edge Computing. *Proceedings - International Conference on Augmented Intelligence and Sustainable Systems, ICAISS 2022, November 2022*, 21–24.

Bisong, E. (2019). *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. Apress, Canada.

Boyagoda, E. M. R. C. L. ., & Da Silva, J. (2020). *Object Detection for Single Tree Species*. New university of Lisbon. <http://hdl.handle.net/10362/93643>. Diakses pada tanggal 25 Januari 2025.

Djerriri, K., Ghabi, M., Karoui, M. S., & Adjoudj, R. (2018). Palm trees counting in remote sensing imagery using regression convolutional neural network. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2018-July, 2627–2630.

El Hoummadi, L., Larabi, A., & Alam, K. (2021). Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon*, 7(10), e08154.

- Hartling, S., Sagan, V., Sidike, P., Maimaitijiang, M., & Carron, J. (2019). Urban tree species classification using a worldview-2/3 and LiDAR data fusion approach and deep learning. *Sensors (Switzerland)*, 19(6), 1–23.
- Hofinger, P., Klemmt, H., Ecke, S., Rogg, S., & Dempewolf, J. (2023). Application of YOLOv5 for Point Label Based Object Detection of Black Pine Trees with Vitality Losses in UAV Data. *Remote Sensing*, 15(1964), 1–13.
- Inderiati, S. (2023). PRODUKTIVITAS TANAMAN SAWIT (*Elaeis guineensis* Jacq.) BERUMUR TUA BERDASARKAN KEPADATAN POPULASI DI PTPN XIV UNIT PKS LUWU. *Agroplantae: Jurnal Ilmiah Terapan Budidaya Dan Pengelolaan Tanaman Pertanian Dan Perkebunan*, 12(1), 41–48
- Jakacki, J., Andrzejewski, J., Przyborska, A., Muzyka, M., Gordon, D., Nawa, J., Popiel, S., Golenko, M., Zhurbas, V., & Paka, V. (2020). High resolution model for assessment of contamination by chemical warfare agents dumped in the Baltic Sea. *Marine Environmental Research*, 161(July 2020), 105079.
- Jintasuttisak, T., Edirisinghe, E., & Elbattay, A. (2022). Deep neural network based date palm tree detection in drone imagery. *Computers and Electronics in Agriculture*, 192(November 2021), 106560.
- Ke, Y., & Quackenbush, L. J. (2011). A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *International Journal of Remote Sensing*, 32(17), 4725–4747.
- Li, W., Fu, H., Yu, L., & Cracknell, A. (2017). Deep learning based oil palm tree detection and counting for high-resolution remote sensing images. *Remote Sensing*, 9(1), 22.
- Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). Path Aggregation Network for Instance Segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 8759–8768.
- Malek, S., Bazi, Y., Alajlan, N., AlHichri, H., & Melgani, F. (2014). Efficient framework for palm tree detection in UAV images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(12), 4692–4703.
- Morrison, L. W. (2021). Nonsampling error in vegetation surveys: understanding error types and recommendations for reducing their occurrence. *Plant Ecology*, 222(5), 577–586.
- Morrison, L. W., & Young, C. C. (2016). Standardization and quality control in data collection and assessment of threatened plant species. *Data*, 1(3), 1–11.
- Mubin, N. A., Nadarajoo, E., Shafri, H. Z. M., & Hamedianfar, A. (2019). Young and mature oil palm tree detection and counting using convolutional neural network deep learning method. *International Journal of Remote Sensing*, 40(19), 7500–7515.
- Muna, M. S., Nugroho, A. P., Syarovy, M., Wiratmoko, A., Suwardi, & Sutiarmo, L. (2023). Development of Automatic Counting System for Palm Oil Tree Based on Remote Sensing Imagery. *Proceedings of the International Conference on Sustainable Environment, Agriculture and Tourism (ICOSEAT 2022)*, 26(DI), 503–508.
- Ngapiyatun, S., Pagayang, D., Roby, Aziza, H., Wartomo, & Malaysia, E. (2023). Studi Evaluasi Manajemen Penerapan Teknik Pemupukan Tanaman Kelapa Sawit Menggunakan Prinsip Empat Tepat (4T) di Perkebunan Sawit Long Mesangat. *Buletin LOUPE*, 19(01), 71–78.
- Pouliot, D. A., King, D. J., Bell, F. W., & Pitt, D. G. (2002). Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. *Remote Sensing of Environment*, 82(2–3), 322–334.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 779–788.
- Redmon, J., & Farhadi, A. (2017). YOLO9000: Better, faster, stronger. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern*

- Recognition, CVPR 2017, 2017-Janua*, 6517–6525.
- Redmon, J., & Farhadi, A. (2018). *YOLOv3: An Incremental Improvement*. <http://arxiv.org/abs/1804.02767>. Diakses pada tanggal 20 Januari 2025.
- Shafri, H. Z. M., Hamdan, N., Saripan, M. I., Pouliot, D. A., King, D. J., Bell, F. W., Pitt, D. G., Srestasathiern, P., & Rakwatin, P. (2002). Semi-automatic detection and counting of oil palm trees from high spatial resolution airborne imagery. *International Journal of Remote Sensing*, 32(10), 2095–2115.
- Srestasathiern, P., & Rakwatin, P. (2014). Oil palm tree detection with high resolution multi-spectral satellite imagery. *Remote Sensing*, 6(10), 9749–9774.
- Tan, L., Huangfu, T., Wu, L., & Chen, W. (2021). *Comparison of yolo v3, faster r-cnn, and ssd for real-time pill identification*. <https://doi.org/10.21203/rs.3.rs-668895/v1>. Diakses pada tanggal 21 Januari 2025.
- Wang, C. Y., Mark Liao, H. Y., Wu, Y. H., Chen, P. Y., Hsieh, J. W., & Yeh, I. H. (2020). CSPNet: A new backbone that can enhance learning capability of CNN. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, 2020-June*, 1571–1580.
- Wardah, S. (2017). Penentuan Jumlah Karyawan Yang Optimal Pada Penanaman Lahan Kelapa Sawit Dengan Menggunakan Metode Work Load Analysis (Wla). *Jurnal Teknik Industri: Jurnal Hasil Penelitian Dan Karya Ilmiah Dalam Bidang Teknik Industri*, 3(1), 46.
- Wu, G., & Li, Y. (2021). Non-maximum suppression for object detection based on the chaotic whale optimization algorithm. *Journal of Visual Communication and Image Representation*, 74(November 2020), 102985.
- Zheng, J., Li, W., Xia, M., Dong, R., Fu, H., & Yuan, S. (2019). LARGE-SCALE OIL PALM TREE DETECTION FROM HIGH-RESOLUTION REMOTE SENSING IMAGES USING FASTER-RCNN. *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, 1422–1425.
- Zhou, Q., Liu, H., Qiu, Y., & Zheng, W. (2023). Object Detection for Construction Waste Based on an Improved YOLOv5 Model. *Sustainability (Switzerland)*, 15(1).