



ISSN : 2339 - 1871

## BETRIK BESEMAH TEKNOLOGI INFORMASI & KOMPUTER

Editor Office : Pusat Penelitian & Pengabdian Pada Masyarakat  
(PPPM) ITPA

Phone : 0857-9716-9578

email : [betrikitpa@itpa.ac.id](mailto:betrikitpa@itpa.ac.id)

### Pengaruh Konfigurasi *Hyperparameter* Pada Kinerja YOLOv11 Dalam Deteksi Objek Pohon Kelapa Sawit

Fernandi Indi Nizar G<sup>1</sup>, Eka Puji Widiyanto<sup>2</sup>

Fakultas Ilmu Komputer dan Rekayasa, Program Studi Informatika, Universitas Multi Data  
Palembang, Palembang, Indonesia<sup>1</sup>

Fakultas Ilmu Komputer dan Rekayasa, Program Studi Elektro, Universitas Multi Data  
Palembang, Palembang, Indonesia<sup>2</sup>

Sur-el :\* [fernandiindinizar@mhs.mdp.ac.id](mailto:fernandiindinizar@mhs.mdp.ac.id)<sup>1</sup>, [ekapujiw2002@mdp.ac.id](mailto:ekapujiw2002@mdp.ac.id)<sup>2</sup>

Penulis Korespondensi: Fernandi Indi Nizar G, [fernandiindinizar@mhs.mdp.ac.id](mailto:fernandiindinizar@mhs.mdp.ac.id)

**Abstrak:** Kelapa sawit (*Elaeis guineensis*) merupakan komoditas strategis bagi perekonomian Indonesia, namun proses pendataan jumlah pohon pada area perkebunan masih banyak dilakukan secara manual. Metode tersebut tidak hanya memerlukan waktu panjang dan biaya tinggi, tetapi juga memiliki risiko kesalahan yang cukup besar. Kondisi ini menunjukkan perlunya sistem otomatis yang mampu melakukan deteksi pohon secara cepat dan akurat. Penelitian ini bertujuan menganalisis pengaruh variasi *hyperparameter* pada algoritma YOLOv11 terhadap kualitas model dalam mendeteksi pohon kelapa sawit berbasis citra UAV. Empat *hyperparameter* utama diuji, yaitu *batch size* (16 dan 32), jumlah *epoch* (100 dan 150), *learning rate* (0,01 dan 0,001), serta *optimizer* (SGD dan AdamW), sehingga menghasilkan 16 kombinasi pelatihan. Dataset diperoleh dari Roboflow dan diproses melalui tahapan anotasi, augmentasi, dan *preprocessing* sebelum digunakan dalam pelatihan model. Evaluasi performa dilakukan menggunakan *precision*, *recall*, dan *mean Average Precision* (mAP), serta pengujian lanjutan pada *confidence threshold* dan *IoU threshold*. Hasil analisis menunjukkan bahwa kombinasi *batch size* 16, *epoch* 100, *learning rate* 0,001, dan *optimizer* SGD menghasilkan performa terbaik dengan mAP50 sebesar 98,3%, *precision* 95,3%, dan *recall* 94,1%. Selain itu, model menunjukkan stabilitas deteksi yang baik pada rentang *confidence* 0,5 dan *IoU* 0,5. Temuan ini menunjukkan bahwa penyetelan *hyperparameter* memiliki pengaruh signifikan terhadap kualitas deteksi YOLOv11. Penelitian ini berkontribusi dalam pengembangan sistem deteksi objek otomatis di sektor perkebunan dan mendukung efisiensi operasional melalui percepatan proses perhitungan pohon kelapa sawit.

**Kata kunci :** Citra UAV, Dataset, Hyperparameter, Kelapa Sawit, YOLOv11

**Abstract** Oil palm (*Elaeis guineensis*) is a strategic commodity for Indonesia's economy, however, tree inventory processes in plantation areas are still predominantly manual, requiring considerable time and cost, and posing a high risk of human error. This study analyzes the effect of hyperparameter variations on the performance of the YOLOv11 algorithm for automated oil palm tree detection using UAV imagery. Four key hyperparameters batch size (16 and 32), number of epochs (100 and 150), learning rate (0.01 and 0.001), and optimizer (SGD and AdamW) were evaluated, resulting in 16 training configurations. The dataset, obtained from Roboflow, underwent annotation, augmentation, and preprocessing prior to model training. Model performance was assessed using precision, recall, and mean Average Precision (mAP), followed by additional evaluation at varying confidence and Intersection over Union (IoU) thresholds. Experimental results show that the optimal configuration batch size 16, 100 epochs, a learning rate of 0.001, and the SGD

Received: 21-11-2025 | Accepted: 25-11-2025 | Published Online: 30-12-2025

All author: Fernandi Indi Nizar G, Eka Puji Widiyanto

*optimizer achieved an mAP50 of 98.3%, with precision and recall values of 95.3% and 94.1%, respectively. The model also demonstrated stable detection performance at a confidence threshold of 0.5 and an IoU threshold of 0.5. These findings highlight the significant effect of hyperparameter tuning on YOLOv11 detection performance and offer insights for enhancing automated tree-counting systems in the plantation sector, enabling more efficient and accurate operational workflows.*

**Keywords:** Dataset, Hyperparameters, Oil Palm, UAV Imagery, YOLOv11

## 1. PENDAHULUAN

Kelapa sawit (*elaeis guineensis*) merupakan komoditas strategis bagi perekonomian Indonesia yang memiliki areal perkebunan sangat luas, yaitu 14,62 juta hektar pada tahun 2021 dan meningkat menjadi 15,93 juta hektar pada tahun 2023 [1] [2] [3]. Skala lahan yang besar ini menjadikan pendataan jumlah pohon kelapa sawit sebagai aktivitas yang penting namun kompleks, terutama karena proses pendataan masih dilakukan secara manual di lapangan. Metode konvensional tersebut membutuhkan waktu yang lama, biaya tinggi, serta berisiko menghasilkan kesalahan pencatatan [4]. Kondisi ini menunjukkan perlunya pendekatan otomatis untuk mempercepat dan meningkatkan akurasi proses pendataan pohon.

Kemajuan teknologi komputer, khususnya algoritma deteksi objek berbasis *deep learning*, memberikan peluang untuk melakukan pendataan secara otomatis menggunakan citra UAV. Salah satu model yang banyak digunakan adalah YOLO (*You Only Look Once*), yang dikenal karena kemampuannya melakukan deteksi objek secara cepat dan akurat [5] [6]. Versi terbarunya, YOLOv11, menghadirkan sejumlah peningkatan pada arsitektur *backbone*, *neck*, dan *head*, serta menggunakan modul C3K2, C2PSA, dan SPPF yang lebih efisien sehingga mampu mendeteksi objek kecil maupun besar dengan lebih baik [7].

Performa model *deep learning*, termasuk YOLOv11, sangat dipengaruhi oleh konfigurasi *hyperparameter*. *Hyperparameter* seperti *learning rate*, *batch size*, jumlah *epoch*, dan *optimizer* tidak dipelajari oleh model, tetapi harus ditentukan sebelum pelatihan dimulai, dan perubahan kecil pada nilai tersebut dapat berdampak signifikan terhadap hasil deteksi [8]. Berbagai penelitian sebelumnya telah mengkaji optimasi *hyperparameter* untuk meningkatkan performa deteksi. Penelitian [9] berfokus pada optimasi *learning rate* YOLOv4-tiny menggunakan algoritma genetika untuk mendeteksi kematangan tandan buah segar kelapa sawit, yang berhasil meningkatkan mAP dari 99,60% menjadi 99,70%. Studi lain oleh [10] menganalisis dampak *tuning* pada *learning rate*, *momentum*, dan *batch size* serta membandingkan *optimizer* (SGD, Adam, dan AdamW) untuk deteksi pohon secara umum, dan menemukan bahwa YOLOv11 dengan SGD mampu mencapai mAP sebesar 95,2%. Selain itu, penelitian [11] juga secara spesifik mengoptimalkan *hyperparameter* seperti *batch size* dan *learning rate* pada YOLOv11m untuk deteksi penyakit daun tomat, dan berhasil mencapai mAP sebesar 0,992.

Meskipun sejumlah penelitian sebelumnya telah mengevaluasi pengaruh *hyperparameter* terhadap performa model YOLO, kebanyakan studi tersebut masih terbatas pada optimasi satu atau dua *hyperparameter* secara individual. Pendekatan parsial ini belum mampu menggambarkan interaksi antar-*hyperparameter* yang berpotensi memberikan dampak signifikan terhadap stabilitas pembelajaran dan kualitas deteksi. Selain itu, belum ditemukan penelitian yang secara komprehensif menguji kombinasi *batch*

*size*, *epoch*, *learning rate*, dan *optimizer* secara bersamaan pada YOLOv11 untuk kasus deteksi pohon kelapa sawit. Keterbatasan kajian terdahulu tersebut membentuk suatu celah penelitian yang penting untuk diinvestigasi secara lebih mendalam.

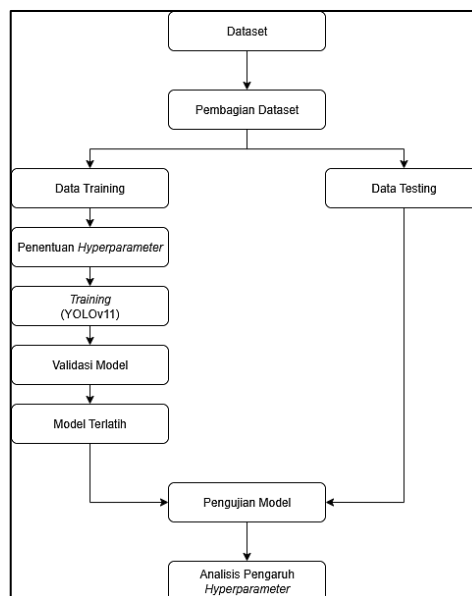
Sejalan dengan itu, penelitian ini dilaksanakan melalui serangkaian proses pemodelan yang terstruktur, mulai dari pembacaan dan pra-pemrosesan dataset citra UAV, pembagian data ke dalam *train*, *validation*, dan *test*, serta pelatihan model YOLOv11s menggunakan berbagai kombinasi *hyperparameter*. Selanjutnya, model dievaluasi melalui *precision*, *recall*, dan *mean Average Precision* (mAP) untuk memperoleh gambaran performa yang objektif. Pendekatan tersebut dirancang untuk memastikan bahwa proses pemodelan dilakukan secara sistematis dan memungkinkan identifikasi konfigurasi *hyperparameter* yang paling optimal.

Berdasarkan kajian literatur, penelitian terdahulu terkait optimasi *hyperparameter* YOLO umumnya masih terbatas pada analisis satu atau dua *hyperparameter* secara terpisah. Pendekatan parsial ini belum mampu menangkap interaksi antar-*hyperparameter* yang dapat memengaruhi stabilitas pembelajaran maupun akurasi deteksi secara signifikan. Selain itu, belum ditemukan penelitian yang secara komprehensif mengevaluasi kombinasi empat *hyperparameter* utama yaitu *batch size*, *epoch*, *learning rate*, dan *optimizer* pada arsitektur YOLOv11 untuk kasus deteksi pohon kelapa sawit berbasis citra UAV. Keterbatasan ini membentuk suatu celah penelitian yang penting untuk diinvestigasi secara metodologis. Oleh karena itu, penelitian ini bertujuan untuk menemukan kombinasi *hyperparameter* yang paling optimal dalam meningkatkan performa deteksi model YOLOv11 pada identifikasi pohon kelapa sawit berbasis citra UAV.

## 2. METODOLOGI PENELITIAN

### 2.1 Alur Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan untuk memperoleh model deteksi pohon kelapa sawit yang optimal menggunakan YOLOv11. Alur penelitian secara lengkap ditampilkan pada Gambar 1.



Gambar 1. Alur Penelitian

Tahapan dimulai dari pengumpulan dataset citra pohon kelapa sawit, kemudian dataset dibagi menjadi dua bagian yaitu data *training* dan data *testing*. Data *training* digunakan pada proses penentuan konfigurasi *hyperparameter* dan pelatihan model YOLOv11, dilanjutkan dengan proses validasi untuk memastikan model tidak mengalami *overfitting* dan layak digunakan. Model yang telah terlatih kemudian diuji menggunakan data *testing* guna mengukur tingkat akurasi deteksi pohon kelapa sawit. Selanjutnya dilakukan analisis pengaruh *hyperparameter* berdasarkan hasil pengujian untuk menentukan konfigurasi terbaik.

## 2.2 Dataset Penelitian

Penelitian ini menggunakan dataset citra pohon kelapa sawit yang telah diberi anotasi bounding box dan diunggah ke platform Roboflow (<https://universe.roboflow.com/sawit-rv9qo/sawit-h0mew>) untuk keperluan pemformatan data dan pelatihan model deteksi objek. Dataset terdiri dari 1.247 citra dengan total 20.503 anotasi pada satu kelas objek yaitu pohon kelapa sawit (palm tree). Seluruh citra memiliki resolusi 640×640 piksel dan telah dilengkapi anotasi secara lengkap (0 *missing annotations*) tanpa citra kosong (0 *null examples*), sehingga dataset dapat langsung digunakan pada tahap pelatihan model.

Setelah diproses pada Roboflow, dataset dibagi menjadi tiga bagian, yaitu data pelatihan sebesar 70%, data validasi sebesar 20%, dan data pengujian sebesar 10%. Pembagian ini bertujuan agar model memperoleh data yang cukup untuk proses pembelajaran sekaligus tetap memiliki data khusus untuk mengevaluasi kemampuan generalisasi model. Contoh dataset dapat dilihat pada Gambar 2.

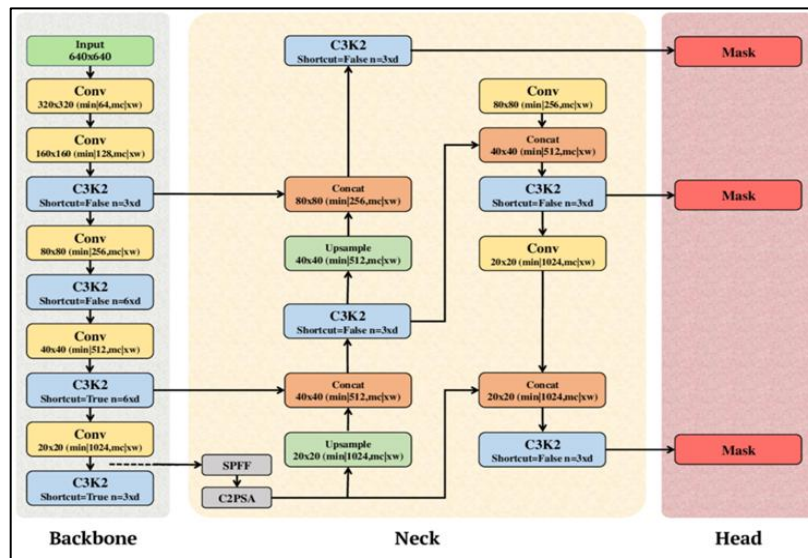


Gambar 2. Dataset Citra Pohon Kelapa Sawit

## 2.3 YOLOv11

YOLOv11 merupakan pengembangan terkini dari keluarga algoritma You Only Look Once yang dirancang untuk memberikan kinerja deteksi objek yang lebih cepat dan lebih akurat. Versi ini hadir dengan penyempurnaan pada struktur backbone, neck, dan head sehingga mampu menangani objek berukuran kecil maupun besar dengan lebih efektif [12]. Pada bagian backbone, YOLOv11 memanfaatkan blok C3K2 yang dapat mengekstraksi fitur visual secara lebih padat dan efisien [13]. Modul SPPF dan C2PSA yang

ditempatkan pada neck membantu menggabungkan fitur dari berbagai skala dan menyoroti area penting pada citra, sehingga meningkatkan ketelitian model dalam kondisi visual yang beragam [14]. Bagian head menggunakan tiga blok deteksi yang mampu menghasilkan prediksi bounding box pada berbagai ukuran objek [14]. Selain itu, penggunaan Distribution Focal Loss dan MPDIoU membuat proses regresi koordinat bounding box menjadi lebih stabil dan akurat [15]. Dengan seluruh peningkatan tersebut, YOLOv11 menjadi pilihan yang sangat sesuai untuk penelitian ini, terutama karena kemampuannya menangani data citra UAV yang kompleks dan memiliki variasi objek yang beragam seperti pohon kelapa sawit.



Gambar 3. Arsitektur YOLOv11 (Khan & Jensen, 2024)

Gambar 2 menunjukkan arsitektur YOLOv11 terdiri atas tiga komponen utama, yaitu backbone, neck, dan head, yang masing-masing memiliki fungsi penting dalam proses deteksi objek [12]. Pada bagian backbone, model ini dimulai dari proses input citra 640×640 dan dilanjutkan dengan blok convolutional untuk mengekstraksi fitur dasar, sebelum kemudian diperkaya menggunakan blok C3K2 yang dirancang untuk menjaga kestabilan gradien serta efisiensi aliran informasi melalui kombinasi layer konvolusi dan shortcut connection [14]. Neck YOLOv11 terdiri dari modul SPPF yang berfungsi menggabungkan fitur multi-skala agar model mampu menangkap objek dalam berbagai ukuran, serta modul C2PSA yang memberikan perhatian khusus pada area penting dalam citra sehingga akurasi deteksi semakin meningkat, terutama pada objek kecil atau yang posisinya tidak jelas [14]. Bagian terakhir adalah head, yang terdiri dari tiga blok deteksi yang masing-masing menghasilkan bounding box, kelas objek, serta confidence score untuk objek kecil, sedang, dan besar, sekaligus didukung oleh penggunaan Distribution Focal Loss dan MPDIoU guna meningkatkan ketepatan regresi dan kualitas lokalisasi objek [14].

#### 2.4 Tuning Hyperparameter

Tahap ini dilakukan untuk menganalisis pengaruh konfigurasi hyperparameter terhadap kualitas model YOLOv11s dalam mendeteksi pohon kelapa sawit. *Hyperparameter* yang divariasikan meliputi *batch size*, jumlah *epoch*, nilai *learning rate*, dan jenis *optimizer*. Variasi nilai untuk setiap *hyperparameter* adalah

*batch size* (16, 32), *epoch* (100, 150), *learning rate* (0,01, 0,001), dan *optimizer* (SGD, AdamW). Kombinasi dari keempat hyperparameter tersebut menghasilkan 16 konfigurasi pelatihan yang dijalankan secara terpisah. Setiap konfigurasi menghasilkan satu model yang tersimpan dan selanjutnya dievaluasi menggunakan data validasi untuk menentukan konfigurasi yang memberikan performa terbaik. Variasi *hyperparameter* yang digunakan dalam proses pelatihan model YOLOv11s ditunjukkan pada Tabel 1.

Tabel 1. Variasi *Hyperparameter*

No.	Batch	Epoch	Learning Rate	Optimizer
1.	16	100	0.01	SGD
2.	16	100	0.01	AdamW
3.	16	100	0.001	SGD
4.	16	100	0.001	AdamW
5.	16	150	0.01	SGD
6.	16	150	0.01	AdamW
7.	16	150	0.001	SGD
8.	16	150	0.001	AdamW
9.	32	100	0.01	SGD
10.	32	100	0.01	AdamW
11.	32	100	0.001	SGD
12.	32	100	0.001	AdamW
13.	32	150	0.01	SGD
14.	32	150	0.01	AdamW
15.	32	150	0.001	SGD
16.	32	150	0.001	AdamW

## 2.5 Evaluasi

Dari hasil beberapa pelatihan, model akan diuji tingkat keakuratan deteksinya menggunakan *mean average precision* (mAP). mAP digunakan untuk mengukur tingkat performa deteksi objek dari hasil training data model tersebut [16]. Sebelum menghitung nilai mAP, harus melakukan penyesuaian nilai *threshold* pada IoU untuk validasi objek yang dideteksi [17]. *Threshold* adalah nilai pembatas yang digunakan untuk menyaring hasil data yang tidak sempurna. Dalam konteks deteksi objek, nilai *threshold confidence* digunakan untuk menentukan apakah hasil prediksi objek akan ditampilkan atau diabaikan. Nilai IoU (*Intersection over Union*), yang mencerminkan seberapa cocok kotak prediksi yang dihasilkan dengan kotak sebenarnya yang mengelilingi objek tersebut. Kedua konsep ini sangat penting dalam mengevaluasi kinerja model deteksi objek. Untuk mendapatkan mAP dibutuhkan nilai AP yang didapatkan dari nilai *Recall* dan *Precision*. Rumus dari mAP, *Recall*, dan *Precision* dapat dilihat pada Persamaan (1), (2), dan (3).

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

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

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

Keterangan rumus:

n : Jumlah AP

- AP : *Average Precision*
- TP : *True Positive* yaitu jumlah data positif yang terklasifikasi benar
- TN : *True Negative* yaitu jumlah data negatif yang terklasifikasi benar
- FP : *False Positive* yaitu jumlah data positif yang terklasifikasi salah
- FN : *False Negative* yaitu jumlah data negatif yang terklasifikasi

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil

Diawali dengan persiapan dataset yang kemudian dibagi menjadi tiga bagian yaitu 70% data *training*, 20% data validasi, dan 10% data *testing*. Model yang digunakan yolov11s dipilih karena ringan, cepat, dan sesuai dengan keterbatasan sumber daya komputasi, namun tetap memberikan hasil deteksi yang akurat [18]. Dilakukan pengujian terhadap 16 kombinasi *hyperparameter* untuk menganalisis pengaruh variasi konfigurasi terhadap kualitas model YOLOv11 dalam mendeteksi pohon kelapa sawit. Pengujian dilakukan dengan empat parameter utama, yaitu *batch size* (16 dan 32), *epoch* (100 dan 150), *learning rate* (0,01 dan 0,001), serta *optimizer* (SGD dan AdamW). Tabel 2 menunjukkan hasil skema pengujian *tuning hyperparameter*.

Tabel 2. Hasil Skema Pengujian

No.	Batch	Epoch	Learning Rate	Optimizer	Precision	Recall	mAP50
1.	16	100	0.01	SGD	0.946	0.95	0.981
2.	16	100	0.01	AdamW	0.949	0.949	0.981
3.	16	100	0.001	SGD	0.953	0.941	0.983
4.	16	100	0.001	AdamW	0.959	0.94	0.981
5.	16	150	0.01	SGD	0.942	0.942	0.98
6.	16	150	0.01	AdamW	0.945	0.947	0.979
7.	16	150	0.001	SGD	0.949	0.942	0.982
8.	16	150	0.001	AdamW	0.95	0.948	0.981
9.	32	100	0.01	SGD	0.952	0.945	0.981
10.	32	100	0.01	AdamW	0.949	0.95	0.981
11.	32	100	0.001	SGD	0.954	0.938	0.981
12.	32	100	0.001	AdamW	0.945	0.944	0.98
13.	32	150	0.01	SGD	0.948	0.943	0.978
14.	32	150	0.01	AdamW	0.954	0.946	0.981
15.	32	150	0.001	SGD	0.957	0.934	0.981
16.	32	150	0.001	AdamW	0.944	0.945	0.978

### 3.2 Pembahasan

Tahap awal penelitian dimulai dengan pembacaan dataset yang terdiri dari 1.247 citra pohon kelapa sawit lengkap dengan anotasi *bounding box*. Dataset ini diimpor melalui platform Roboflow dan kemudian diproses melalui tahapan pra-pemrosesan, seperti verifikasi anotasi untuk memastikan tidak terdapat citra kosong maupun anotasi yang hilang. Tahapan ini bertujuan meningkatkan kualitas representasi visual yang diberikan kepada model sehingga proses pembelajaran dapat berlangsung lebih optimal.

Setelah pra-pemrosesan selesai, dataset dibagi menjadi tiga subset yaitu 70% untuk data pelatihan, 20% untuk data validasi, dan 10% untuk data pengujian. Pembagian ini mengikuti praktik standar dalam pemodelan deep learning guna meminimalkan bias dan memastikan bahwa model dievaluasi menggunakan data yang benar-benar baru. Data validasi digunakan untuk memantau performa model selama proses pelatihan, sedangkan data pengujian digunakan untuk mengukur kemampuan generalisasi model pada tahap akhir.


Proses pelatihan dilakukan menggunakan model YOLOv11s dengan 16 konfigurasi hyperparameter yang berbeda. Kombinasi tersebut meliputi *batch size* 16 dan 32, jumlah *epoch* 100 dan 150, nilai *learning rate* 0,01 dan 0,001, serta penggunaan dua jenis *optimizer* yaitu SGD dan AdamW. Setiap konfigurasi dijalankan secara independen sehingga menghasilkan total 16 model untuk dianalisis. Langkah ini memungkinkan penilaian komprehensif terhadap pengaruh setiap *hyperparameter* dan interaksinya terhadap stabilitas pembelajaran maupun akurasi deteksi objek.

Evaluasi model dilakukan menggunakan tiga metrik utama, yaitu *precision*, *recall*, dan *mean Average Precision* (mAP50). Selain itu, model juga diuji menggunakan berbagai nilai *threshold confidence* dan IoU untuk menilai konsistensi performa dalam kondisi pembatas yang berbeda. Berdasarkan hasil evaluasi, konfigurasi dengan *batch size* 16, *epoch* 100, *learning rate* 0,001, dan *optimizer* SGD menunjukkan performa paling optimal dengan nilai mAP50 sebesar 98,3%, *precision* sebesar 95,3%, dan *recall* sebesar 94,1%. Kombinasi tersebut memberikan keseimbangan terbaik antara ketepatan dan sensitivitas deteksi.

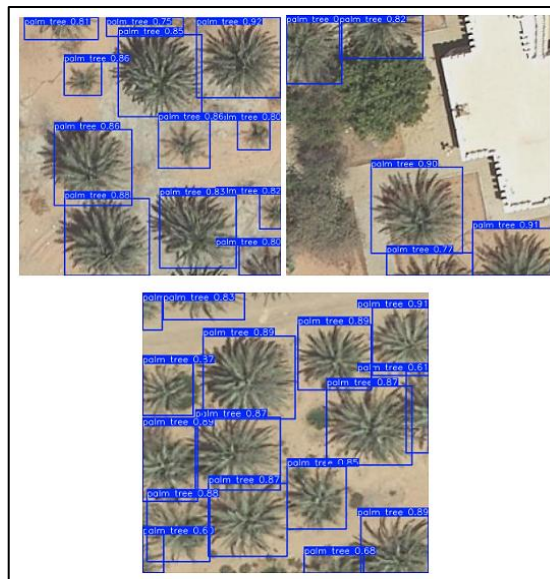
Hasil analisis lebih lanjut menunjukkan bahwa *learning rate* merupakan *hyperparameter* yang memiliki pengaruh paling signifikan terhadap performa model. *Learning rate* kecil yaitu 0,001 memberikan pembaruan bobot yang lebih halus sehingga proses pembelajaran lebih stabil. *Batch size* besar memang meningkatkan stabilitas gradien, namun tidak selalu menghasilkan akurasi tertinggi. Sementara itu, meskipun *optimizer* AdamW cenderung memberikan stabilitas yang baik, dalam penelitian ini justru kombinasi tertentu dengan *optimizer* SGD menghasilkan performa terbaik. Temuan tersebut mengindikasikan bahwa interaksi antar-*hyperparameter* memiliki dampak yang kompleks dan tidak dapat dievaluasi secara terpisah.

Validasi visual melalui hasil prediksi *bounding box* menunjukkan bahwa model terbaik mampu mengidentifikasi pohon kelapa sawit secara presisi, termasuk pada area dengan kanopi rapat dan objek yang saling berdekatan. Konsistensi *bounding box* pada citra uji membuktikan bahwa model tidak hanya unggul secara kuantitatif, tetapi juga memiliki kemampuan generalisasi yang baik terhadap variasi kondisi visual pada citra UAV. Hal ini menguatkan hasil evaluasi sebelumnya bahwa konfigurasi hyperparameter terbaik

benar-benar meningkatkan kinerja YOLOv11 dalam mendeteksi objek pohon kelapa sawit. Hasil *confusion matrix* pada pengujian model yang ditunjukkan pada Gambar 4, dan untuk hasil pengujian deteksi menggunakan model terbaik dapat dilihat pada Gambar 5.



Gambar 4. *Confusion Matrix* Pengujian Model



Gambar 5. Hasil Deteksi Dari Pengujian Model Terbaik

#### 4. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa variasi *hyperparameter* memiliki pengaruh signifikan terhadap performa YOLOv11 dalam mendeteksi pohon kelapa sawit pada citra UAV. Dari 16 kombinasi pengujian, konfigurasi *batch size* 16, *epoch* 100, *learning rate* 0,001, dan *optimizer* SGD menghasilkan performa terbaik dengan nilai *precision* 95,3%, *recall* 94,1%, dan *mAP50* 98,3%, sehingga ditetapkan sebagai model paling optimal dalam penelitian ini.

Pengujian lanjutan menggunakan *confidence threshold* 0,5 dan IoU 0,5 menunjukkan bahwa model ini mampu memberikan deteksi visual yang stabil dan akurat. *Bounding box* yang dihasilkan berada tepat pada objek pohon, termasuk pada area dengan kanopi yang rapat maupun objek yang berdekatan satu sama lain. Hasil visual ini memperkuat evaluasi kuantitatif bahwa memiliki model dengan kemampuan generalisasi yang baik terhadap variasi bentuk kanopi, sudut pandang, serta kondisi latar belakang citra UAV.

Secara keseluruhan, penelitian ini menegaskan bahwa pemilihan *hyperparameter* yang tepat sangat menentukan kualitas deteksi YOLOv11. Temuan ini dapat menjadi acuan dalam pengembangan deteksi otomatis berbasis UAV untuk pendataan pohon kelapa sawit. Penelitian selanjutnya dapat memperluas pengujian pada tipe model YOLOv11 lainnya, menambah variasi data lapangan, atau menerapkan teknik otomatisasi *tuning* untuk mendapatkan konfigurasi yang lebih optimal.

## DAFTAR RUJUKAN

- [1] M. R. N. Ariyadi, M. R. Pribadi, dan E. P. Widiyanto, "Unmanned Aerial Vehicle for Remote Sensing Detection of Oil Palm Trees Using You Only Look Once and Convolutional Neural Network," dalam *2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, IEEE, Sep 2023, hlm. 226–230. doi: 10.1109/EECSI59885.2023.10295670.
- [2] Badan Pusat Statistik, "Statistik Kelapa Sawit Indonesia 2021."
- [3] Badan Pusat Statistik, "Statistik Kelapa Sawit Indonesia 2023."
- [4] P. N. Chowdhury, P. Shivakumara, L. Nandanwar, F. Samiron, U. Pal, dan T. Lu, "Oil palm tree counting in drone images," *Pattern Recognit Lett*, vol. 153, hlm. 1–9, Jan 2022, doi: 10.1016/j.patrec.2021.11.016.
- [5] S. Armalivia, M. A. Rahmat, T. T. F. Manguma, dan Rahmawati, "Analisis Kinerja Algoritma YOLO dalam Penghitungan Benih Udang," *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI)*, vol. 7, no. 1, hlm. 161–169, Apr 2024, doi: 10.57093/jisti.v7i1.202.
- [6] N. Khairunisa, Carudin, dan A. Jamaludin, "Analisis Perbandingan Algoritma Cnn Dan Yolo Dalam Mengidentifikasi Kerusakan Jalan," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Agu 2024, doi: 10.23960/jitet.v12i3.4434.
- [7] R. Khanam dan M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," Okt 2024, [Daring]. Tersedia pada: <http://arxiv.org/abs/2410.17725>
- [8] D. Hafidzulahman, "Perbandingan Algoritma You Only Look Once (YOLO) versi 5 dan versi 8 sebagai Object Detection pada Pendeteksian Hilal," 2024.
- [9] E. Salim dan Suharjito, "Hyperparameter optimization of YOLOv4 tiny for palm oil fresh fruit bunches maturity detection using genetics algorithms," *Smart Agricultural Technology*, vol. 6, hlm. 100364, Des 2023, doi: 10.1016/j.atech.2023.100364.
- [10] A. M. Moraes, L. F. Pugliese, R. F. dos Santos, G. B. Vitor, R. A. da S. Braga, dan F. R. da Silva, "Effectiveness of YOLO Architectures in Tree Detection: Impact of Hyperparameter Tuning and SGD, Adam, and AdamW Optimizers," *Standards*, vol. 5, no. 1, hlm. 9, Mar 2025, doi: 10.3390/standards5010009.
- [11] Y.-S. Lee, M. P. Patil, J. G. Kim, Y. B. Seo, D.-H. Ahn, dan G.-D. Kim, "Hyperparameter Optimization for Tomato Leaf Disease Recognition Based on YOLOv11m," *Plants*, vol. 14, no. 5, hlm. 653, Feb 2025, doi: 10.3390/plants14050653.
- [12] M. H. Iqbal, M. J. Iqbal, dan T. Saleem, "Road layer detection and volume calculation using UAV Technologies and Artificial Intelligence," *Engineering Research Express*, vol. 7, no. 1, hlm. 015111, Mar 2025, doi: 10.1088/2631-8695/adaca9.

- [13] L. He, Y. Zhou, L. Liu, dan J. Ma, “Research and Application of YOLOv11-Based Object Segmentation in Intelligent Recognition at Construction Sites,” *Buildings*, vol. 14, no. 12, hlm. 3777, Nov 2024, doi: 10.3390/buildings14123777.
- [14] P. Hidayatullah, N. Syakrani, M. R. Sholahuddin, T. Gelar, dan R. Tubagus, “YOLOv8 to YOLO11: A Comprehensive Architecture In-depth Comparative Review A PREPRINT,” Jan 2025.
- [15] Q. Wang, Z. Pu, L. Luo, L. Wang, dan J. Gao, “A Study on Tree Species Recognition in UAV Remote Sensing Imagery Based on an Improved YOLOv11 Model,” *Applied Sciences*, vol. 15, no. 16, hlm. 8779, Agu 2025, doi: 10.3390/app15168779.
- [16] A. F. Fandisyah, N. Iriawan, dan W. S. Winahju, “Deteksi Kapal di Laut Indonesia Menggunakan YOLOv3,” *Jurnal Sains dan Seni ITS*, vol. 10, no. 1, Agu 2021, doi: 10.12962/j23373520.v10i1.59312.
- [17] T. A. A. H. Kusuma, K. Usman, dan S. Saidah, “People Counting For Public Transportations Using You Only Look Once Method,” *Jurnal Teknik Informatika (Jutif)*, vol. 2, no. 1, hlm. 57–66, Feb 2021, doi: 10.20884/1.jutif.2021.2.2.77.
- [18] S. S. Saleh, M. H. Koniyo, dan M. Polin, “Deteksi Dini Hama dan Penyakit Tanaman Padi dengan Metode YOLO,” vol. 5, no. 2, 2025.