

ANALISIS PERBANDINGAN KINERJA YOLOV8 DAN YOLOV11 UNTUK DETEKSI UAV MILITER SECARA REALTIME

Comparative Performance Analysis of YOLOv8 and YOLOv11 for Real-Time Military UAV Detection

Nesha Roswanda Sakhdiah, nesha.sakhdiah@mipa.idu.ac.id¹, dan Khazali Fahmi,
khazali.fahmi@idu.ac.id^{2,*}

¹Fisika /Departemen MIPAM, Universitas Pertahanan Republik Indonesia

Diterima 10 Juni 2026 / Disetujui 25 Juni 2026

ABSTRACT

The rapid development of Unmanned Aerial Vehicle (UAV) technology has increased the demand for object detection systems capable of accurately identifying aerial targets in real time. One of the most widely adopted approaches is deep learning-based object detection using the You Only Look Once (YOLO) family of algorithms. This study aims to compare the performance of two recent object detection architectures, YOLOv8 and YOLOv11, for UAV detection using a custom dataset. Both models were trained under identical conditions for 100 epochs to ensure a fair comparison. Performance evaluation was conducted using mean Average Precision (mAP@0.5), Precision, Recall, F1-score, Precision-Recall Curve, and Confusion Matrix metrics. The experimental results indicate that YOLOv8 outperformed YOLOv11 across most evaluation metrics. YOLOv8 achieved an mAP@0.5 of 88.1% with a maximum F1-score of 0.86 at a confidence threshold of 0.373, while YOLOv11 achieved an mAP@0.5 of 85.5% with a maximum F1-score of 0.83 at a confidence threshold of 0.359. Confusion Matrix analysis revealed True Positive rates of 89% and 88% for YOLOv8 and YOLOv11, respectively. Furthermore, the Precision-Recall curves demonstrated that both models possessed strong generalization capabilities for detecting small UAV targets under varying image conditions. Based on the obtained results, it can be concluded that YOLOv8 provides slightly superior detection accuracy compared to YOLOv11 on the evaluated UAV dataset. These findings suggest that YOLOv8 remains a competitive choice for real-time UAV detection applications requiring high detection accuracy.

Keywords: *Unmanned Aerial Vehicle (UAV), Drone Detection, YOLOv8, YOLOv11, Computer Vision.*

ABSTRAK

Perkembangan pesat teknologi Unmanned Aerial Vehicle (UAV) telah meningkatkan kebutuhan akan sistem deteksi objek yang mampu mengidentifikasi target udara secara akurat dan real-time. Salah satu pendekatan yang banyak digunakan adalah algoritma deteksi objek berbasis deep learning dari keluarga You Only Look Once (YOLO). Penelitian ini bertujuan untuk membandingkan performa dua arsitektur deteksi objek terkini, yaitu YOLOv8 dan YOLOv11, dalam mendeteksi UAV menggunakan dataset kustom. Kedua model dilatih menggunakan dataset yang sama selama 100 epoch untuk memastikan perbandingan yang objektif. Evaluasi dilakukan menggunakan metrik mean Average Precision (mAP@0.5), Precision, Recall, F1-score, Precision-Recall Curve, serta Confusion Matrix. Hasil penelitian menunjukkan bahwa YOLOv8 memperoleh performa deteksi yang lebih baik dibandingkan YOLOv11 pada sebagian besar metrik evaluasi. YOLOv8 mencapai nilai mAP@0.5 sebesar 88,1% dengan F1-score maksimum sebesar 0,86 pada confidence threshold 0,373, sedangkan YOLOv11 memperoleh mAP@0.5 sebesar 85,5% dan F1-score maksimum sebesar 0,83 pada confidence threshold 0,359. Analisis Confusion Matrix menunjukkan tingkat True Positive sebesar 89% pada YOLOv8 dan 88% pada YOLOv11. Selain itu, kurva Precision-Recall mengindikasikan bahwa kedua model memiliki kemampuan generalisasi yang baik dalam mendeteksi target UAV berukuran kecil pada berbagai kondisi citra. Berdasarkan hasil evaluasi, dapat disimpulkan bahwa YOLOv8 memberikan akurasi deteksi yang sedikit lebih unggul dibandingkan YOLOv11 pada dataset UAV yang digunakan. Temuan ini menunjukkan bahwa YOLOv8 masih menjadi pilihan yang kompetitif untuk aplikasi deteksi UAV secara real-time yang membutuhkan tingkat akurasi tinggi.

Kata Kunci: Unmanned Aerial Vehicle (UAV), Deteksi Drone, YOLOv8, YOLOv11, Computer Vision.

*Korespondensi Penulis:

E-mail: khazali.fahmi@idu.ac.id

PENDAHULUAN

Pemanfaatan UAV yang dilengkapi kamera terus meningkat pada berbagai sektor, mulai dari pertanian dan pemetaan hingga keamanan dan pengawasan. Peningkatan penggunaan UAV tersebut menghasilkan volume data visual yang sangat besar sehingga diperlukan metode analisis otomatis berbasis computer vision. Meskipun berbagai algoritma deteksi dan pelacakan objek telah menunjukkan performa yang baik pada citra konvensional, penerapannya pada citra UAV masih menghadapi tantangan yang signifikan. Perubahan sudut pandang, variasi ukuran objek akibat perbedaan ketinggian terbang, serta kompleksitas latar belakang sering kali menyebabkan penurunan akurasi deteksi objek[1]. Variasi skala objek, kualitas citra yang rendah, dan latar belakang yang kompleks masih menjadi kendala utama dalam deteksi objek kecil pada citra UAV[2]. Perkembangan teknologi mendorong integrasi berbagai disiplin ilmu untuk menghasilkan solusi yang lebih efektif dan efisien. Deteksi objek berkembang dari metode tradisional berbasis fitur manual menjadi metode *deep learning* yang lebih akurat dan efektif[3]. Yang banyak dikembangkan saat ini adalah **Unmanned Aerial Vehicle (UAV)** yang dikombinasikan dengan kecerdasan buatan untuk mendukung berbagai aplikasi modern[4].

a. Latar Belakang

Deteksi objek UAV masih terkendala oleh objek kecil, latar belakang yang kompleks, dan keterbatasan sumber daya komputasi[5]. Akurasi deteksi dan stabilitas pelatihan masih menjadi tantangan, terutama karena keterbatasan sumber daya komputasi pada platform UAV[6]. Algoritma YOLO banyak diterapkan pada sistem UAV karena memiliki keseimbangan yang baik antara akurasi dan efisiensi komputasi. Namun, deteksi objek kecil pada citra udara masih menjadi tantangan akibat ukuran target yang terbatas, variasi skala, dan kompleksitas latar belakang[7].

Penerapan algoritma YOLO pada UAV meningkatkan kemampuan otomatisasi dan memperluas pemanfaatan drone di berbagai bidang[4]. Berbagai generasi YOLO telah dikembangkan untuk meningkatkan performa deteksi objek pada berbagai kondisi, YOLOv8 merupakan pengembangan dari versi YOLO sebelumnya yang menawarkan peningkatan akurasi, kecepatan, dan fleksibilitas[8]. Meskipun YOLOv8 memiliki kemampuan deteksi multi-skala yang baik, proses *downsampling* dapat mengurangi informasi fitur objek kecil sehingga performa deteksi target mikro pada citra UAV masih perlu ditingkatkan[8]. Sementara itu YOLOv11 merupakan versi terbaru dari keluarga algoritma YOLO yang dirancang untuk meningkatkan kemampuan deteksi objek real-time melalui berbagai optimalisasi pada arsitektur jaringan dan proses pelatihan model. Diperkenalkan pada tahun 2024, YOLOv11 dikembangkan dengan tujuan meningkatkan akurasi deteksi sekaligus mempertahankan efisiensi komputasi dan kecepatan inferensi. Berbagai penyempurnaan yang diterapkan menjadikan YOLOv11 sebagai salah satu model deteksi objek modern yang layak dievaluasi dan dibandingkan dengan generasi sebelumnya, termasuk YOLOv8, dalam berbagai skenario aplikasi[9].

Secara arsitektural, YOLOv8 dan YOLOv11 memiliki beberapa perbedaan yang berpotensi memengaruhi kemampuan deteksi objek berukuran kecil. YOLOv8 menggunakan modul C2f (Cross Stage Partial with Feature Fusion) pada backbone dan neck untuk meningkatkan aliran informasi fitur serta mempertahankan efisiensi komputasi. Namun, pada proses ekstraksi fitur bertingkat, sebagian informasi spasial objek kecil masih dapat berkurang akibat proses *downsampling*. YOLOv11 memperkenalkan modul C3k2 sebagai pengganti C2f yang dirancang untuk meningkatkan representasi fitur spasial dengan jumlah parameter yang lebih efisien. Selain itu, YOLOv11 menambahkan modul C2PSA (Cross Stage Partial Spatial Attention) yang memungkinkan model memberikan perhatian lebih pada area penting dalam citra sehingga detail objek berukuran kecil dapat dipertahankan dengan lebih baik. Kombinasi kedua modul tersebut meningkatkan kemampuan ekstraksi fitur dan fusi informasi multi-skala, sehingga YOLOv11 berpotensi memberikan performa yang lebih baik dalam mendeteksi target UAV berukuran kecil dibandingkan YOLOv8[9].

Beberapa penelitian terdahulu telah mengembangkan berbagai modifikasi YOLO untuk meningkatkan kemampuan deteksi objek pada citra udara. Penelitian MSCM-YOLO menunjukkan bahwa deteksi objek kecil pada citra UAV masih menjadi tantangan utama karena sebagian besar objek memiliki ukuran kurang dari 32×32 piksel sehingga informasi visual yang tersedia sangat terbatas [10]. Penelitian TOE-YOLO juga menjelaskan bahwa objek pada citra udara sering muncul dalam berbagai orientasi dan skala yang berbeda sehingga menyulitkan proses ekstraksi fitur oleh model deteksi konvensional [11]. Untuk mengatasi permasalahan tersebut, berbagai penelitian mengusulkan modifikasi arsitektur YOLO guna meningkatkan kemampuan deteksi objek kecil dan objek yang mengalami rotasi. Namun demikian, sebagian besar penelitian berfokus pada pengembangan model baru, sementara kajian yang secara khusus membandingkan performa YOLOv8 dan YOLOv11 pada tugas deteksi UAV menggunakan dataset kustom masih relatif terbatas.

Berdasarkan kondisi tersebut, penelitian ini dilakukan untuk membandingkan performa YOLOv8 dan YOLOv11 dalam mendeteksi UAV menggunakan dataset kustom yang dikumpulkan dan dianotasi secara khusus untuk kebutuhan penelitian. Evaluasi dilakukan menggunakan parameter Precision, Recall, F1-Score, mean Average Precision (mAP@0.5), serta Confusion Matrix [12]. Hasil penelitian diharapkan dapat memberikan informasi yang objektif mengenai performa kedua model sehingga dapat menjadi referensi dalam pengembangan sistem deteksi UAV secara real-time pada bidang pertahanan dan keamanan.

b. Identifikasi Masalah

Berdasarkan latar belakang yang telah diuraikan, permasalahan yang dapat diidentifikasi dalam penelitian ini adalah sebagai berikut:

1. UAV berukuran kecil memiliki karakteristik yang sulit dideteksi secara akurat karena ukuran objek yang kecil, variasi orientasi yang tinggi, serta kompleksitas latar belakang pada citra udara.
2. Perkembangan berbagai versi algoritma YOLO menghasilkan perbedaan karakteristik arsitektur yang dapat memengaruhi performa deteksi objek pada skenario UAV.
3. Belum terdapat informasi yang memadai mengenai perbandingan performa YOLOv8 dan YOLOv11 dalam mendeteksi UAV menggunakan dataset kustom yang sama.
4. Diperlukan evaluasi kuantitatif menggunakan metrik standar seperti Precision, Recall, F1-Score, mAP@0.5, dan Confusion Matrix untuk menentukan model yang paling sesuai diterapkan pada sistem deteksi UAV secara real-time.

c. Tujuan dan Manfaat Penelitian

Penelitian ini bertujuan untuk melakukan analisis perbandingan performa dua model deteksi objek berbasis deep learning, yaitu YOLOv8 dan YOLOv11, dalam mendeteksi Unmanned Aerial Vehicle (UAV) menggunakan dataset kustom. Evaluasi dilakukan berdasarkan beberapa metrik yang umum digunakan dalam bidang computer vision, meliputi Precision, Recall, F1-Score, mean Average Precision (mAP@0.5), dan Confusion Matrix. Melalui evaluasi tersebut, penelitian ini diharapkan dapat memberikan gambaran yang objektif mengenai kemampuan masing-masing model dalam mendeteksi objek UAV secara real-time serta menentukan model yang memiliki performa terbaik pada dataset yang digunakan.

Manfaat penelitian ini adalah memberikan kontribusi terhadap pengembangan ilmu pengetahuan di bidang computer vision dan object detection, khususnya yang berkaitan dengan deteksi UAV menggunakan algoritma YOLO. Penelitian ini juga dapat menjadi referensi bagi peneliti selanjutnya yang ingin melakukan pengembangan atau perbandingan model deteksi objek pada citra udara. Dari sisi praktis, hasil penelitian diharapkan dapat membantu pengembang sistem kecerdasan buatan dalam menentukan model yang paling sesuai untuk diterapkan pada sistem deteksi UAV secara


real-time. Selain itu, penelitian ini berpotensi mendukung pengembangan teknologi pengawasan wilayah, keamanan, dan pertahanan yang membutuhkan kemampuan identifikasi target udara secara cepat, akurat, dan efisien.

METODE PENELITIAN

a. Metodologi Penelitian

Penelitian ini menggunakan metode eksperimen kuantitatif dengan pendekatan komparatif untuk mengevaluasi dan membandingkan performa dua model deteksi objek berbasis deep learning, yaitu YOLOv8 dan YOLOv11, dalam mendeteksi Unmanned Aerial Vehicle (UAV). Pendekatan komparatif dipilih karena penelitian berfokus pada analisis perbedaan performa kedua model berdasarkan parameter evaluasi yang sama. Seluruh proses penelitian dilakukan secara sistematis mulai dari pengumpulan dataset, anotasi data, pelatihan model, pengujian model, hingga analisis hasil deteksi.

Tahapan penelitian diawali dengan pengumpulan citra UAV yang diperoleh dari hasil perekaman video menggunakan kamera laptop dan kamera smartphone. Data yang diperoleh kemudian diproses menjadi kumpulan citra statis dan dilakukan anotasi menggunakan format YOLO untuk menghasilkan koordinat bounding box pada setiap objek UAV. Dataset yang telah dianotasi selanjutnya dibagi menjadi data pelatihan (*training set*) dan data validasi (*validation set*). Data pelatihan digunakan untuk proses pembelajaran model, sedangkan data validasi digunakan untuk mengevaluasi performa model selama proses pelatihan dan memantau kemampuan generalisasi model. Setelah proses persiapan data selesai, model YOLOv8 dan YOLOv11 dilatih menggunakan dataset yang sama dengan parameter pelatihan yang identik. Hasil pelatihan kemudian dievaluasi menggunakan beberapa metrik performa dan dibandingkan untuk menentukan model yang memiliki kemampuan deteksi UAV terbaik.



Gambar 1. Kerangka Eksperimen Penelitian untuk Analisis Perbandingan Performa YOLOv8 dan YOLOv11 pada Deteksi UAV

b. Dataset Penelitian

Dataset yang digunakan dalam penelitian ini merupakan dataset UAV kustom yang dikumpulkan secara mandiri dengan memanfaatkan dataset open source yang tersedia pada platform Roboflow. Dataset tersebut dipilih karena memiliki variasi citra UAV yang beragam serta telah dilengkapi dengan anotasi objek yang kompatibel dengan format pelatihan model YOLO. Citra yang digunakan berasal dari hasil ekstraksi frame video sehingga menghasilkan kumpulan citra digital yang merepresentasikan berbagai kondisi pengamatan UAV. Seluruh citra kemudian melalui proses anotasi

menggunakan perangkat lunak anotasi objek untuk memberikan label kelas dan koordinat bounding box pada setiap objek UAV yang terdeteksi. Dataset yang telah dianotasi terdiri atas 1.802 citra yang mencakup dua kategori UAV, yaitu fixed-wing dan quadcopter. Keberagaman kategori ini diharapkan mampu meningkatkan kemampuan model dalam mengenali karakteristik visual dari kedua jenis UAV tersebut.

Sebelum proses pelatihan, seluruh citra diubah ukurannya menjadi 640×640 piksel agar sesuai dengan kebutuhan masukan model YOLO. Dataset kemudian dibagi secara acak menjadi dua kelompok data, yaitu 1.441 citra sebagai data pelatihan (training set) dan 361 citra sebagai data validasi (validation set) dengan rasio pembagian sebesar 80% : 20%. Pembagian secara acak dilakukan untuk menjaga distribusi data yang seimbang serta mengurangi potensi bias selama proses pelatihan model. Data pelatihan digunakan untuk proses pembelajaran parameter model, sedangkan data validasi digunakan untuk mengevaluasi performa model selama proses pelatihan dan menentukan model terbaik berdasarkan metrik evaluasi yang digunakan. Pada penelitian ini tidak digunakan data pengujian (test set) yang terpisah. Sebagai gantinya, evaluasi akhir performa model dilakukan melalui pengujian implementasi secara real-time pada sistem drone interceptor. Pendekatan ini dipilih karena tujuan penelitian tidak hanya mengevaluasi kinerja model pada dataset statis, tetapi juga menilai kemampuan deteksi UAV pada kondisi operasional yang sebenarnya, termasuk variasi jarak, sudut pengamatan, pencahayaan, dan dinamika pergerakan objek.

c. Pelatihan Model YOLOv8 dan YOLOv11

Pada penelitian ini digunakan dua model deteksi objek, yaitu YOLOv8 dan YOLOv11. Kedua model dipilih karena merupakan arsitektur deteksi objek modern yang memiliki kemampuan deteksi real-time dengan tingkat akurasi yang tinggi. Untuk memperoleh perbandingan yang objektif, kedua model dilatih menggunakan dataset yang sama, jumlah epoch yang sama, ukuran citra yang sama, serta parameter pelatihan yang identik.

Proses pelatihan dilakukan menggunakan framework Ultralytics YOLO dengan jumlah pelatihan sebanyak 100 epoch. Selama proses pelatihan, model melakukan pembelajaran terhadap pola visual UAV berdasarkan data yang terdapat pada dataset pelatihan. Selanjutnya model divalidasi menggunakan data validasi untuk memantau kemampuan generalisasi model dan menghindari terjadinya overfitting. Hasil pelatihan setiap epoch direkam dalam bentuk kurva performa dan nilai evaluasi yang digunakan sebagai dasar analisis pada tahap berikutnya.

d. Teknik Evaluasi Model

Evaluasi model dilakukan untuk mengukur kemampuan YOLOv8 dan YOLOv11 dalam mendeteksi objek UAV secara akurat. Pengujian dilakukan menggunakan data pengujian yang tidak digunakan selama proses pelatihan. Kinerja model dianalisis menggunakan beberapa metrik evaluasi yang umum digunakan pada penelitian deteksi objek, yaitu Precision, Recall, F1-Score, mean Average Precision (mAP@0.5), dan Confusion Matrix.

Precision digunakan untuk mengukur kemampuan model dalam menghasilkan prediksi positif yang benar terhadap seluruh prediksi positif yang diberikan model. Nilai Precision dihitung menggunakan Persamaan (1).

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

dengan TP merupakan jumlah True Positive dan FP merupakan jumlah False Positive.

Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh objek UAV yang terdapat pada data pengujian. Nilai Recall dihitung menggunakan Persamaan (2).

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

dengan FN merupakan jumlah False Negative.

Untuk memperoleh keseimbangan antara Precision dan Recall digunakan metrik F1-Score yang dihitung menggunakan Persamaan (3).

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

Selain itu, penelitian ini juga menggunakan Intersection over Union (IoU) sebagai parameter untuk menentukan tingkat kesesuaian antara bounding box hasil prediksi dan bounding box sebenarnya. Nilai IoU dihitung menggunakan Persamaan (4).

$$IoU = \frac{Area(B_{pred} \cap B_{gt})}{Area(B_{pred} \cup B_{gt})} \quad (4)$$

di mana (B_{pred}) merupakan bounding box hasil prediksi model dan (B_{gt}) merupakan bounding box ground truth.

Performa keseluruhan model kemudian diukur menggunakan mean Average Precision (mAP@0.5) yang merupakan rata-rata nilai Average Precision pada seluruh kelas objek. Nilai mAP dihitung menggunakan Persamaan (5).

$$mAP = \sum \frac{AP_i}{N} \quad (5)$$

dengan (AP_i) merupakan Average Precision pada kelas ke-i dan (N) merupakan jumlah kelas objek yang digunakan pada penelitian.

Selain evaluasi numerik, penelitian ini juga menggunakan Confusion Matrix untuk menganalisis distribusi prediksi model terhadap masing-masing kelas UAV. Analisis ini digunakan untuk mengetahui tingkat keberhasilan klasifikasi, kesalahan deteksi, serta pola kesalahan yang terjadi pada masing-masing model.

e. Teknik Analisis Data


Data hasil pelatihan dan pengujian dianalisis secara deskriptif komparatif dengan membandingkan nilai Precision, Recall, F1-Score, mAP@0.5, serta Confusion Matrix yang diperoleh dari YOLOv8 dan YOLOv11. Selain itu, kurva Precision, Recall, F1-Score, dan Loss Function yang dihasilkan selama proses pelatihan juga dianalisis untuk melihat tingkat konvergensi model dan kemampuan generalisasi masing-masing arsitektur.

Hasil evaluasi yang diperoleh kemudian disajikan dalam bentuk tabel, grafik, dan visualisasi hasil deteksi untuk memberikan gambaran yang lebih komprehensif mengenai performa kedua model. Model dengan nilai mAP@0.5, Precision, Recall, dan F1-Score yang lebih tinggi akan dianggap memiliki performa deteksi UAV yang lebih baik pada dataset yang digunakan dalam penelitian ini.


HASIL DAN PEMBAHASAN

a. Hasil Penelitian Model

Penelitian ini melakukan pelatihan model YOLOv8 dan YOLOv11 menggunakan dataset UAV kustom yang terdiri atas dua kelas objek, yaitu fixed-wing dan quadcopter. Kedua model dilatih menggunakan konfigurasi yang sama dengan jumlah pelatihan sebanyak 100 epoch sehingga hasil yang diperoleh dapat dibandingkan secara objektif.



Gambar 2. Kurva Loss YOLOv8




Gambar 3. Kurva Loss YOLOv11

Selama proses pelatihan, kedua model menunjukkan tren konvergensi yang baik yang ditandai dengan penurunan nilai loss secara bertahap pada data pelatihan maupun data validasi. Kurva pelatihan menunjukkan bahwa model mulai mencapai kondisi stabil pada epoch akhir sehingga model dianggap telah mempelajari karakteristik objek UAV yang terdapat pada dataset.

b. Analisis Precision dan Recall

Precision digunakan untuk mengukur kemampuan model dalam menghasilkan prediksi yang benar terhadap seluruh prediksi positif yang dihasilkan, sedangkan Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh objek UAV yang terdapat pada dataset pengujian.

Berdasarkan hasil evaluasi, kedua model menunjukkan nilai Precision dan Recall yang tinggi. Kurva Precision–Recall memperlihatkan bahwa YOLOv8 mempertahankan keseimbangan antara Precision dan Recall yang lebih baik dibandingkan YOLOv11 pada berbagai confidence threshold.




Gambar 4. Kurva Precision dan Recall YOLOv8 dan YOLOv11

Hasil tersebut menunjukkan bahwa YOLOv8 memiliki kemampuan yang lebih baik dalam mengurangi kesalahan deteksi (False Positive) sekaligus mempertahankan tingkat keberhasilan identifikasi objek UAV (True Positive).

c. Analisis F1-Score

F1-Score digunakan untuk mengukur keseimbangan antara Precision dan Recall. Nilai F1 yang tinggi menunjukkan bahwa model mampu memberikan performa deteksi yang baik secara keseluruhan. Berdasarkan hasil pengujian, YOLOv8 memperoleh nilai F1-score maksimum sebesar 0,86 pada

confidence threshold 0,373, sedangkan YOLOv11 memperoleh nilai F1-score maksimum sebesar 0,83 pada confidence threshold 0,359.



Gambar 5. Kurva F1-Score YOLOv8 dan YOLOv11

Hasil tersebut menunjukkan bahwa YOLOv8 memiliki keseimbangan Precision dan Recall yang lebih baik dibandingkan YOLOv11 pada dataset UAV yang digunakan.

d. Analisis mAP@0.5

Mean Average Precision (mAP@0.5) merupakan indikator utama yang digunakan untuk mengevaluasi performa model deteksi objek. Nilai ini menggambarkan kemampuan model dalam mendeteksi objek secara akurat berdasarkan Intersection over Union (IoU) sebesar 0,5.

Tabel 1. Perbandingan Nilai mAP@0.5

Model	mAP@0.5 (%)
YOLOv8	88,1
YOLOv11	85,5

Berdasarkan Tabel 1, YOLOv8 memperoleh nilai mAP@0.5 sebesar 88,1%, sedangkan YOLOv11 memperoleh nilai 85,5%. Selisih sebesar 2,6% menunjukkan bahwa YOLOv8 mampu memberikan akurasi deteksi yang lebih tinggi pada dataset UAV yang digunakan. Hasil ini menunjukkan bahwa peningkatan arsitektur pada YOLOv11 tidak selalu menghasilkan performa yang lebih baik pada seluruh dataset. Karakteristik dataset UAV yang relatif kecil dan spesifik memungkinkan YOLOv8 melakukan generalisasi yang lebih baik dibandingkan YOLOv11.


e. Analisis Confusion Matriks

Confusion Matrix digunakan untuk mengevaluasi distribusi prediksi model terhadap setiap kelas objek. Analisis ini memberikan informasi mengenai jumlah prediksi benar (True Positive), prediksi salah (False Positive), dan objek yang gagal dideteksi (False Negative).

Tabel 2. Ringkasan Hasil Confusion Matriks

Model	True Positive (%)
YOLOv8	89
YOLOv11	88

Hasil evaluasi menunjukkan bahwa YOLOv8 memiliki tingkat True Positive sebesar 89%, sedangkan YOLOv11 mencapai 88%. Perbedaan tersebut menunjukkan bahwa kedua model memiliki kemampuan deteksi yang baik, namun YOLOv8 masih menunjukkan performa yang sedikit lebih unggul.



Gambar 6. Confussion Matriks YOLOv8 dan YOLOv11

SIMPULAN

Penelitian ini telah melakukan analisis perbandingan performa antara YOLOv8 dan YOLOv11 untuk mendeteksi Unmanned Aerial Vehicle (UAV) secara real-time menggunakan dataset kustom yang terdiri atas objek fixed-wing dan quadcopter. Kedua model dilatih menggunakan dataset dan parameter pelatihan yang sama sehingga perbedaan performa yang diperoleh dapat mencerminkan karakteristik masing-masing arsitektur secara objektif. Berdasarkan hasil evaluasi menggunakan metrik Precision, Recall, F1-Score, mean Average Precision (mAP@0.5), dan Confusion Matrix, diperoleh bahwa YOLOv8 menunjukkan performa yang lebih baik dibandingkan YOLOv11 pada dataset yang digunakan dalam penelitian ini. YOLOv8 memperoleh nilai mAP@0.5 sebesar 88,1% dan F1-Score maksimum sebesar 0,86, sedangkan YOLOv11 memperoleh nilai mAP@0.5 sebesar 85,5% dan F1-Score maksimum sebesar 0,83. Analisis Confusion Matrix juga menunjukkan bahwa YOLOv8 memiliki tingkat True Positive sebesar 89%, sedikit lebih tinggi dibandingkan YOLOv11 yang mencapai 88%.

Hasil penelitian ini menunjukkan bahwa penggunaan model yang lebih baru tidak selalu menghasilkan performa deteksi yang lebih baik pada seluruh dataset dan skenario aplikasi. Pada dataset UAV yang digunakan, YOLOv8 mampu memberikan keseimbangan yang lebih baik antara akurasi deteksi dan kemampuan generalisasi dibandingkan YOLOv11. Dengan demikian, berdasarkan hasil pengujian yang dilakukan, YOLOv8 dapat direkomendasikan sebagai model yang lebih sesuai untuk aplikasi deteksi UAV secara real-time pada kondisi penelitian ini.

DAFTAR PUSTAKA

- [1] P. Zhu, L. Wen, X. Bian, H. Ling, and Q. Hu, "Vision Meets Drones: A Challenge," Apr. 2018, [Online]. Available: <http://arxiv.org/abs/1804.07437>
- [2] L. Lanča, M. Mališa, K. Jakac, and S. Ivić, "Optimal Flight Speed and Height Parameters for Computer Vision Detection in UAV Search," *Drones*, vol. 9, no. 9, Sep. 2025, doi: 10.3390/drones9090595.

- [3] S. Bumbaca and E. Borgogno-Mondino, "On the Minimum Dataset Requirements for Fine-Tuning an Object Detector for Arable Crop Plant Counting: A Case Study on Maize Seedlings," *Remote Sens. (Basel)*, vol. 17, no. 13, Jul. 2025, doi: 10.3390/rs17132190.
- [4] C. Chen *et al.*, "YOLO-Based UAV Technology: A Review of the Research and Its Applications," Mar. 01, 2023, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/drones7030190.
- [5] L. Liu, L. Meng, X. Li, J. Liu, and J. Bi, "WCD-YOLOv11: A lightweight YOLOv11 model for the real-time image processing in UAV," *Alexandria Engineering Journal*, vol. 133, pp. 73–88, Dec. 2025, doi: 10.1016/j.aej.2025.10.045.
- [6] P. Gao, H. T. Li, and F. Wang, "Enhanced YOLO11 for tiny object detection based on multi-scale information interaction and fusion in UAV aerial images," *J. Comput. Des. Eng.*, vol. 13, no. 4, pp. 97–113, Apr. 2026, doi: 10.1093/jcde/qwag028.
- [7] Z. Sun, G. Zhang, Y. Xing, and Y. Liu, "A Scale-Adaptive Aggregation and Multi-Domain Feature Fusion Architecture for Small-Target Detection in UAV Aerial Imagery," *Sensors*, vol. 26, no. 5, Mar. 2026, doi: 10.3390/s26051610.
- [8] X. Zhai, Z. Huang, T. Li, H. Liu, and S. Wang, "YOLO-Drone: An Optimized YOLOv8 Network for Tiny UAV Object Detection," *Electronics (Switzerland)*, vol. 12, no. 17, Sep. 2023, doi: 10.3390/electronics12173664.
- [9] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," Oct. 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>
- [10] Z. Sun, G. Zhang, Y. Xing, and Y. Liu, "A Scale-Adaptive Aggregation and Multi-Domain Feature Fusion Architecture for Small-Target Detection in UAV Aerial Imagery," *Sensors*, vol. 26, no. 5, Mar. 2026, doi: 10.3390/s26051610.
- [11] H. Yan, X. Kong, T. Shimada, and H. Tomiyama, "TOE-YOLO: accurate and efficient detection of tiny objects in UAV imagery," *J. Real. Time. Image Process.*, vol. 22, no. 6, Dec. 2025, doi: 10.1007/s11554-025-01770-3.
- [12] N. Fadillah, Y. Putra, A. Kurniawardhani, S. Si, and M. Kom, "Evaluasi Dampak Keterbatasan Anotasi terhadap Kinerja YOLOv11 dalam Deteksi Multi-Objek Buah," Yogyakarta, 2025.