



Analisis komparatif model YOLOv8n dan YOLOv8s untuk deteksi objek berdasarkan metrik evaluasi dan *confidence score*

Doms Upuy^{*1}, Mozart W. Talakua² Venn Y. I. Ilwaru³, Abdul M. Balami⁴, Arlene H. Hiariey⁵
Email: ¹domsupuy@gmail.com

¹Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Pattimura

^{2,3}Matematika, Fakultas Sains dan Teknologi, Universitas Pattimura

^{4,5}Statistika, Fakultas Sains dan Teknologi, Universitas Pattimura

Diterima: 07 Maret 2026 | Direvisi: 23 April 2026 | Disetujui: 25 April 2026

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Pemanfaatan deep learning dalam sistem deteksi objek telah mengalami kemajuan signifikan, khususnya melalui implementasi algoritma You Only Look Once (YOLO) yang dikenal unggul dalam pemrosesan real-time. Riset ini difokuskan pada analisis komparatif antara dua varian model terbaru, yaitu YOLOv8n dan YOLOv8s, guna mengevaluasi performanya berdasarkan metrik standar dan nilai *confidence score*. Eksperimen dilakukan menggunakan dataset berjumlah 5.000 citra dengan komposisi pembagian data sebesar 70% training, 20% validation, dan 10% testing. Parameter evaluasi yang digunakan mencakup mean Average Precision (mAP), recall, dan precision, serta tinjauan khusus pada durasi komputasi dan stabilitas prediksi model. Temuan penelitian menunjukkan bahwa varian YOLOv8n mencatatkan nilai precision 0.9313, sementara YOLOv8s unggul tipis pada aspek recall (0.8415) dan mAP@0.5 (0.9055). Dalam hal efisiensi, YOLOv8n memerlukan waktu pelatihan yang jauh lebih singkat yakni 2670 detik, dibandingkan YOLOv8s yang mencapai 4477 detik. Namun, YOLOv8s memberikan keunggulan pada *confidence score* yang lebih tinggi, mengindikasikan tingkat kepastian deteksi yang lebih kuat. Secara keseluruhan, YOLOv8n direkomendasikan untuk kebutuhan efisiensi tinggi, sedangkan YOLOv8s lebih tepat untuk akurasi yang lebih stabil.

Kata kunci: Deteksi objek, YOLOv8, skor kepercayaan, deep learning, computer vision

A Comparative analysis of the YOLOv8n and YOLOv8s models for object detection based on evaluation metrics and confidence scores

Abstract

The use of deep learning in object detection systems has seen significant advancements, particularly through the implementation of the You Only Look Once (YOLO) algorithm, which is known for its excellence in real-time processing. This research focuses on a comparative analysis of two of the latest model variants, YOLOv8n and YOLOv8s, to evaluate their performance based on standard metrics and confidence scores. Experiments were conducted using a dataset of 5,000 images with a data split of 70% for training, 20% for validation, and 10% for testing. The evaluation metrics used included mean Average Precision (mAP), recall, and precision, as well as a specific review of computational duration and model prediction stability. The research findings show that the YOLOv8n variant recorded a precision value of 0.9313, while YOLOv8s had a slight edge in recall (0.8415) and mAP@0.5 (0.9055). In terms of efficiency, YOLOv8n requires significantly less training time 2,670 seconds compared to YOLOv8s, which takes 4,477 seconds. However, YOLOv8s offers the advantage of a higher confidence score, indicating a stronger level of detection certainty. Overall, YOLOv8n is recommended for high-efficiency needs, while YOLOv8s is more suitable for more stable accuracy.

Keywords: object detection, YOLOv8, confidence score, deep learning, computer vision

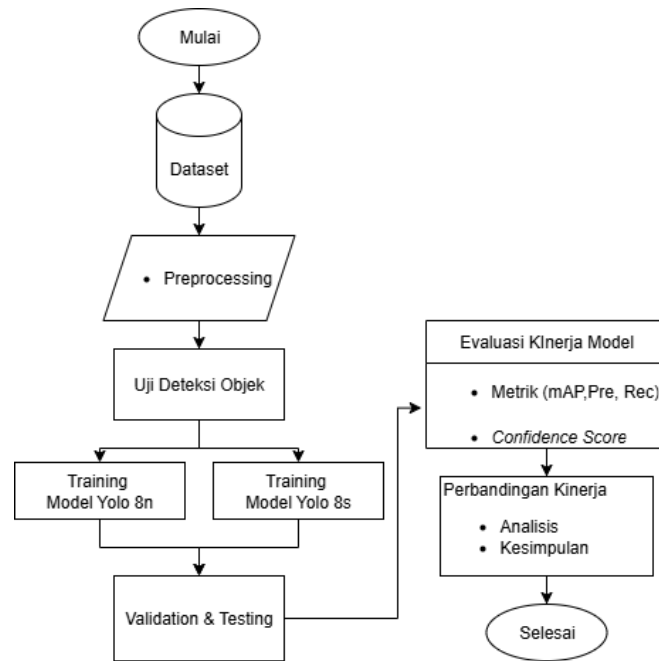
1. PENDAHULUAN

Integrasi teknologi kecerdasan buatan, deep learning, serta computer vision telah menjadi pilar utama dalam kemajuan berbagai disiplin ilmu, khususnya pada aspek deteksi objek secara otomatis dan pengolahan citra digital [1]. Pemanfaatan pendekatan deep learning memungkinkan perangkat komputer untuk mengidentifikasi sekaligus mengenali objek di dalam gambar dengan tingkat presisi dan kecepatan yang optimal. Dalam ranah deteksi objek, algoritma You Only Look Once (YOLO) muncul sebagai salah satu teknik yang paling dominan karena keunggulannya dalam melakukan pemrosesan data secara real-time dengan performa yang sangat kompetitif [2][3]. Secara teknis, YOLO merupakan arsitektur deteksi objek yang berbasis pada Convolutional Neural Network (CNN) yang memiliki kemampuan unik dalam mengeksekusi proses lokalisasi dan klasifikasi objek hanya dalam satu tahapan pemrosesan citra tunggal [4]. Karakteristik ini memungkinkan prediksi bounding box serta probabilitas kelas objek dilakukan secara simultan, sehingga durasi deteksi menjadi jauh lebih efisien dibandingkan metode tradisional. Berkat kelebihan tersebut, YOLO banyak diadopsi dalam berbagai solusi computer vision, mulai dari sistem pengawasan keamanan, pemantauan sektor pertanian, diagnosa medis, hingga otomasi pada sektor industri [5]. Seiring dengan akselerasi riset di bidang deep learning, kerangka kerja YOLO terus bertransformasi melalui rangkaian versi pengembangan untuk mencapai performa yang lebih unggul [6]. Versi terbaru, yaitu YOLOv8 yang dirilis oleh Ultralytics, memperkenalkan inovasi signifikan dalam hal efisiensi sumber daya komputasi serta akurasi deteksi. Melalui implementasi arsitektur jaringan yang lebih ringkas dan pendekatan anchor-free detection, YOLOv8 terbukti mampu meningkatkan keandalan model saat dihadapkan pada kondisi visual yang penuh tantangan atau kompleks [7]. Pada domain kesehatan, performa YOLOv8 telah divalidasi melalui keberhasilannya dalam mendeteksi penyakit kanker kulit dengan nilai precision mencapai 0.975 dan recall sebesar 0.969, yang menegaskan efektivitas algoritma ini pada data citra medis [8]. Selain itu, studi lain melaporkan bahwa YOLOv8 mampu menghasilkan nilai mean Average Precision (mAP) sebesar 89.9% dan F1-score mencapai 86.5% dalam tugas klasifikasi objek visual, yang memperkuat posisinya sebagai model dengan kapabilitas tinggi pada dataset yang variatif [9]. Walaupun memiliki performa yang tangguh, YOLOv8 hadir dalam beberapa varian seperti YOLOv8n (nano), YOLOv8s (small), YOLOv8m (medium), YOLOv8l (large), dan YOLOv8x (extra-large), di mana masing-masing memiliki spesifikasi komputasi dan karakteristik yang berbeda. Perancangan varian ini bertujuan untuk memberikan opsi keseimbangan antara ketepatan deteksi dan kecepatan proses. Secara umum, model berskala kecil menawarkan waktu eksekusi yang lebih singkat namun dengan risiko akurasi yang lebih rendah, sementara model berskala besar cenderung memberikan akurasi maksimal dengan konsekuensi beban komputasi yang lebih berat [7]. Sejumlah riset terdahulu telah mengeksplorasi analisis kinerja pada berbagai variasi YOLO untuk menemukan konfigurasi sistem yang paling ideal. Berdasarkan latar belakang tersebut, penelitian ini dilaksanakan dengan judul Analisis Komparatif Model YOLOv8n dan YOLOv8s untuk Deteksi Objek Berdasarkan Metrik Evaluasi dan Confidence Score. Parameter pengujian difokuskan pada metrik precision, recall, mean Average Precision (mAP), durasi komputasi, serta analisis confidence score. Kontribusi utama dari riset ini adalah penyajian studi banding yang mendalam antara dua varian YOLOv8 dengan tingkat kompleksitas berbeda, serta penambahan evaluasi pada skor kepercayaan untuk membedah tingkat keyakinan prediksi model. Studi ini diharapkan dapat menjadi panduan dalam menentukan model deteksi objek yang paling efisien dengan mempertimbangkan trade-off antara akurasi dan penggunaan sumber daya..

2. METODE PENELITIAN

Penelitian ini bertujuan untuk melakukan analisis perbandingan kinerja antara model YOLOv8n dan YOLOv8s dalam mendeteksi objek pada citra digital. Metodologi penelitian terdiri dari beberapa tahapan utama, yaitu pengumpulan dataset, preprocessing data, pelatihan model YOLO, serta evaluasi kinerja model menggunakan beberapa metrik evaluasi.

2.1. Desain Penelitian



Gambar 1. Diagram Alur Metodologi Penelitian

Dari Gambar 1 diatas menunjukkan bahwa penelitiannya dimulai dari pengumpulan dataset, preprocessing data, pelatihan model YOLO8n dan YOLO8s, hingga proses validation dan testing. Selanjutnya dilakukan evaluasi pada kinerja model dengan menggunakan metrik precision, metrik recall, mAP, dan *confidence score*. Hasil evaluasi tersebut kemudian dianalisis untuk membandingkan performa kedua model dalam mendeteksi objek

2.2. Dataset

Pada penelitian ini dataset yang digunakan merupakan dataset citra dari kelapa sawit yang didapat dari platform Roboflow. Jumlah dataset tersebut yaitu 5000 citra yang telah dianotasi dengan bounding box untuk menentukan lokasi objek pada setiap gambar. Untuk keperluan pelatihan dan evaluasi model, dataset dipetakan menjadi tiga bagian penting, yaitu data latih, validasi data set, dan data testing. Dataset dilakukan pembagian dengan proporsi 70% data pelatihan, 20% data validasi, serta 10% untuk pengujian.

2.3. Preprocessing

Pada tahapan preprocessing konfigurasi parameter yang dipakai untuk tahap proses pelatihan model dapat dilihat pada Tabel 1. Model YOLOv8 dilatih selama 100 epoch untuk memastikan model dapat mempelajari karakteristik objek pada dataset secara optimal. Parameter *batch size* yaitu 16 digunakan untuk menjaga keseimbangan antara penggunaan memori dan stabilitas proses pembelajaran. Seluruh citra pada dataset digunakan ukuran 640×640 piksel supaya sesuai dengan bagian ukuran input model. Proses pelatihan model dilakukan menggunakan perangkat GPU NVIDIA guna mempercepat proses komputasi selama pelatihan.

Tabel 1. Tabel Konfigurasi Training

Parameter	Nilai
Model	YOLO8
Epoch	100
Batch size	16
Image size	640
Device	GPU NVIDIA

2.4. Training YOLOv8

Pada penelitian ini dilakukan proses pelatihan terhadap dua varian dari model arsitektur YOLOv8, yakni YOLOv8n dan YOLOv8s. Kedua model tersebut dilatih dengan menggunakan dataset yang sama supaya dapat memastikan perbandingan kinerja yang objektif. YOLOv8 merupakan algoritma *single-stage* untuk *object detector* yang mampu melakukan deteksi objek pada satu tahap proses, yaitu secara simultan memprediksi lokasi objek dan mengklasifikasikan objek yang terdeteksi. Model dapat menghasilkan prediksi berupa koordinat *bounding box*, probabilitas keberadaan objek dan kelas untuk objek. Proses pada tahapan pelatihan dilakukan dengan iteratif melalui beberapa epoch hingga model mencapai konvergensi yang optimal. Dalam evaluasi deteksi objek, salah satu metrik penting yang digunakan yaitu *Intersection over Union* (IoU), yang dapat mengukur kesesuaian antara *bounding box* pada hasil prediksi model dengan *bounding box* pada *ground truth* dataset. Nilai IoU dihitung menggunakan Persamaan 1 berikut [10]:

$$IoU = \frac{Area_{overlap}}{Area_{union}} \quad (1)$$

di mana:

- $Area_{overlap}$ adalah luas area irisan antara *bounding box*
- $Area_{union}$ adalah luas total kedua *bounding box*
- Nilai IoU dengan nilai rentang 0 sampai dengan 1

Selain itu, YOLO juga menghasilkan *confidence score* untuk menunjukkan tingkat keyakinan pada model dari objek yang terdeteksi. Nilai *confidence score* dihitung berdasarkan probabilitas keberadaan objek dan tingkat kesesuaian *bounding box* pada *ground truth*, yang dapat dinyatakan pada persamaan 2.

$$C = P(object) \times IoU \quad (2)$$

di mana:

- C adalah *confidence score*
- $P(object)$ adalah probabilitas keberadaan objek pada *bounding box*

2.5 Evaluasi Model

Evaluasi model dapat dilakukan dengan mengukur kinerja model YOLOv8n dan YOLOv8s untuk mendeteksi objek pada dataset citra kelapa sawit. Proses evaluasi dilakukan dengan menggunakan metrik *Precision*, *Recall*, *mean Average Precision (mAP)*, dan *Confidence score*. Metrik *precision* dapat dipakai untuk mengukur tingkat kesesuaian model untuk mendeteksi objek yang dianggap benar, untuk nilai *precision* dihitung menggunakan persamaan 3 berikut [11]:

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

di mana:

- *True Positive (TP)* adalah jumlah pada objek yang terdeteksi dianggap benar
- *False Positive (FP)* adalah jumlah untuk objek yang terdeteksi keliru

Selanjutnya evaluasi *Recall* digunakan pada kemampuan model untuk mendeteksi seluruh objek yang sebenarnya terdapat pada citra. Nilai *recall* dapat diperoleh dengan menggunakan persamaan 4 sebagai berikut:

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

di mana:

- *False Negative (FN)* yaitu jumlah objek yang seharusnya terdeteksi tetapi tidak terdeteksi model

Sedangkan untuk *Mean Average Precision (mAP)* merupakan metrik untuk evaluasi yang umum dipakai pada sistem deteksi objek dalam mengukur performa model secara utuh. Nilai mAP diperoleh dari rata-rata nilai untuk *Average Precision (AP)* pada setiap kelas objek yang terdapat pada dataset, untuk nilai mAP dapat dinyatakan pada persamaan 5 sebagai:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \tag{5}$$

di mana:

- N adalah jumlah kelas objek
- AP_i yaitu nilai untuk *average precision* untuk kelas ke- i

Evaluasi *confidence score* dilakukan untuk menunjukkan tingkat keyakinan model terhadap objek yang terdeteksi. Nilai *confidence score* dihasilkan oleh model YOLO berdasarkan probabilitas keberadaan objek pada *bounding box* yang diprediksi. Nilai rata-rata *confidence score* dihitung menggunakan persamaan 6 berikut:

$$C_{mean} = \frac{1}{N} \sum_{i=1}^N C_i \tag{6}$$

di mana:

- C_i adalah *confidence score* pada deteksi ke- i
- N adalah jumlah deteksi objek

Penelitian ini juga menggunakan *Confidence Reliability Index* (CRI) untuk mengukur stabilitas *confidence score* berdasarkan nilai rata-rata *confidence* dan variasinya. Nilai CRI dapat dinyatakan pada persamaan 7 berikut [12]:

$$CRI = \frac{C_{mean}}{1 + \sigma} \tag{7}$$

di mana:

- CRI adalah *Confidence Reliability Index*
- C_{mean} adalah rata-rata *confidence score*
- σ adalah standar deviasi *confidence score*

Interpretasi terhadap nilai CRI yang diperoleh dalam penelitian ini dikategorikan berdasarkan kriteria yang dapat dilihat pada Tabel 2 berikut.

Tabel 2. Kategori Interpretasi Nilai CRI

Nilai CRI	Interpretasi
> 0,80	Sangat <i>reliabel</i>
0,70 – 0,80	Dianggap <i>Reliabel</i>
0,60 – 0,70	Cukup <i>reliabel</i>
< 0,60	Kurang <i>reliabel</i>

3. HASIL DAN PEMBAHASAN

3.1. Hasil *Training* Model YOLOv8n dan YOLOv8s

Hasil dari pelatihan model dengan 100 epoch dapat menunjukkan bahwa kedua model telah memiliki performa untuk deteksi yang baik. YOLOv8n memperoleh *precision* tertinggi sebesar 0.9313, dengan menunjukkan tingkat ketepatan yang tinggi dalam mengidentifikasi objek kelapa sawit. Sementara itu, YOLOv8s memiliki *recall* lebih tinggi yaitu 0.8415, yang dapat menunjukkan kemampuan lebih baik dalam mendeteksi seluruh objek pada citra. Pada metrik *mAP0.5*, YOLOv8s memperoleh nilai 0.9055, sedikit lebih tinggi dibandingkan YOLOv8n dengan nilai 0.9009, sehingga secara keseluruhan YOLOv8s menunjukkan performa deteksi yang lebih baik. Namun, pada *mAP0.5–0.95* kedua model memiliki kinerja yang hampir sama, yaitu 0.6560 pada YOLOv8n dan 0.6566 pada YOLOv8s. Ringkasan hasil pelatihan modelnya ditunjukkan pada Tabel 3.:

Tabel 3. Hasil *Training* Model Yolo8

Model	Epoch	Precision	Recall	mAP0.5	mAP0.5–0.95
YOLOv8n	100	0.9313	0.8187	0.9009	0.6560
YOLOv8s	100	0.9113	0.8415	0.9055	0.6566

3.2. Evaluasi Metrik Kinerja Model

Berdasarkan Tabel 4, model YOLOv8n menunjukkan efisiensi komputasi yang lebih baik dibandingkan YOLOv8s. YOLOv8n membutuhkan waktu pelatihan 2670 detik (26.7 detik per epoch), lebih cepat dibandingkan YOLOv8s yang memerlukan 4477 detik (44.8 detik per epoch). Pada tahap inferensi, YOLOv8n juga lebih cepat dengan waktu 0.79 ms per gambar, sedangkan YOLOv8s membutuhkan 0.92 ms per gambar. Perbedaan ini disebabkan oleh kompleksitas arsitektur YOLOv8s yang lebih besar. Namun demikian, YOLOv8s menghasilkan rata-rata *confidence score* yang lebih tinggi (0.82) dibandingkan YOLOv8n (0.78), yang menunjukkan tingkat keyakinan deteksi yang lebih baik.

Tabel 4. Perbandingan Waktu Komputasi dan Confidence Score Model

Model	Training Time (s)	Time/Epoch	Testing Time (ms/img)	Mean Confidence
YOLOv8n	2670	26.7 s	0.79	0.78
YOLOv8s	4477	44.8 s	0.92	0.82

3.3. Analisis Confidence Score dan CRI

Berdasarkan hasil pada Tabel 5, kedua model menunjukkan nilai Confidence Reliability Index (CRI) yang berada pada kategori reliabel. Model YOLOv8s peroleh nilai CRI yaitu 0.75, sedikit lebih dibandingkan YOLOv8n yang memiliki nilai 0.70. Hasil ini dapat menunjukkan bahwa YOLOv8s memiliki stabilitas prediksi yang lebih baik dalam menghasilkan *confidence score*. Dengan demikian, model YOLOv8s dapat dikatakan lebih konsisten dalam proses deteksi objek dibandingkan YOLOv8n.

Tabel 5. Analisis Confidence Score dan Confidence Reliability Indeks

Model	Mean Confidence	Std Dev	CRI	Interpretasi
YOLOv8n	0.78	0.12	0.70	Reliabel
YOLOv8s	0.82	0.10	0.75	Reliabel

3.4 Perbandingan Kinerja Model

Pada Tabel 6 menyajikan perbandingan kinerja antara model YOLOv8n dan YOLOv8s berdasarkan beberapa metrik evaluasi. Hasil menunjukkan bahwa YOLOv8n memiliki keunggulan pada efisiensi komputasi dengan waktu pelatihan lebih cepat. Sementara itu, YOLOv8s menunjukkan hasil dengan performa yang lebih baik pada metrik recall, mAP0.5, serta menghasilkan nilai confidence dan CRI yang lebih tinggi. Hal ini menunjukkan bahwa YOLOv8s memberikan hasil deteksi yang lebih stabil dan konsisten, sedangkan YOLOv8n lebih unggul dalam aspek efisiensi komputasi.

Tabel 6. Perbandingan Kinerja Model

Model	Precision	Recall	mAP0.5	Training Time	Mean Confidence	CRI
YOLOv8n	0.9313	0.8187	0.9009	2670 s	0.78	0.70
YOLOv8s	0.9113	0.8415	0.9055	4477 s	0.82	0.75

4. KESIMPULAN

Penelitian ini melakukan analisis perbandingan kinerja dua model dari YOLOv8, yaitu YOLOv8n dan YOLOv8s, untuk mendeteksi objek kelapa sawit pada dataset citra. Berdasarkan hasil evaluasi metrik deteksi objek, model YOLOv8n mempunyai hasil dengan nilai *precision* 0.9313, sedangkan YOLOv8s memperoleh nilai *recall* yaitu 0.8415 dan mAP0.5 yaitu 0.9055, yang sedikit lebih tinggi dibandingkan YOLOv8n dengan nilai mAP0.5 sebesar 0.9009. Dari sisi efisiensi komputasi, model YOLOv8n menunjukkan performa yang lebih cepat dengan waktu pelatihan sekitar 2670 detik, dibandingkan YOLOv8s yang membutuhkan waktu sekitar 4477 detik. Namun demikian, analisis confidence score menunjukkan bahwa YOLOv8s memiliki nilai rata-rata confidence sebesar 0.82, lebih jika dibandingkan dengan YOLOv8n yang memiliki nilai 0.78. Selain itu, nilai Confidence Reliability Index (CRI) pada YOLOv8s sebesar 0.75 juga lebih tinggi dibandingkan YOLOv8n sebesar 0.70, yang menghasilkan YOLOv8s memiliki stabilitas prediksi yang lebih baik. Secara keseluruhan untuk penelitian ini mempunyai luaran dimana YOLOv8n lebih unggul dalam efisiensi komputasi, sedangkan YOLOv8s memberikan performa deteksi yang lebih baik dan mempunyai tingkat kepercayaan prediksi yang lebih tinggi. Maka dari itu pemilihan model disesuaikan dengan kebutuhan aplikasi, baik yang mengutamakan kecepatan komputasi maupun akurasi deteksi objek.

DAFTAR PUSTAKA

- [1] B. Olivier, F. Guo, Y. Qian, and D. P. Connolly, "A Review of Computer Vision for Railways," *IEEE Trans. Intell. Transp. Syst.*, vol. 26, no. 7, pp. 11034–11065, 2025.
- [2] O. Alfiano and dan Santi Rahayu, "Implementasi Algoritma Deep Learning Yolo (You Only Look Once) Untuk Deteksi

- Kualitas Kentang Segar Dan Busuk Secara Real Time,” *JORAPI J. Res. Publ. Innov.*, vol. 2, no. 3, pp. 2470–2478, 2024.
- [3] D. F. Dava, Kamdan, and Z. Alamsyah, “Implementation of an IoT-Based Smart Cane Using YOLO V3 to Enhance the Mobility and Safety of Visually Impaired Individuals,” *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 6, no. 2, pp. 94–103, 2025.
- [4] M. A. Fathan, T. Sugiharto, and I. Lesmana, “Jurnal Computer Science and Information Technology (CoSciTech),” vol. 6, no. 2, pp. 140–147, 2025.
- [5] A. Rismayanti and R. Rahmadewi, “Deteksi Dan Klasifikasi Tingkat Kematangan Buah Mangga Harum Manis Menggunakan You Only Look Once (Yolo) V8,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, pp. 3645–3654, 2025.
- [6] D. J. Marcelleno, M. Pajar, K. Putra, C. Science, and U. T. Indonesia, “PERFORMANCE EVALUATION OF YOLOV8 IN REAL-TIME VEHICLE,” vol. 6, no. 1, pp. 269–279, 2025.
- [7] R. Wulanningrum, A. N. Handayani, and A. P. Wibawa, “Perbandingan Instance Segmentation Image Pada Yolo8,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 4, pp. 753–760, 2024.
- [8] Egga Naufal Daffa Tanadi, Dhian Satria Yudha Kartika, and Abdul Rezha Efrat Najaf, “Sistem Pendeteksi Penyakit Kanker Kulit Menggunakan Convolutional Neural Network Arsitektur YOLOv8 Berbasis Website,” *Repeater Publ. Tek. Inform. dan Jar.*, vol. 2, no. 3, pp. 166–177, 2024.
- [9] A. A. S. Mustofa, R. Wulanningrum, and J. Sahertian, “Deteksi dan Klasifikasi Kue Tradisional Indonesia Menggunakan YOLOv8,” *NERO (Networking Eng. Res. Oper.)*, vol. 10, no. 1, pp. 25–36, 2025.
- [10] F. Ramadhani, A. Satria, and S. Dewi, “Identifikasi Kendaraan Bermotor pada Dashcam Mobil Menggunakan Algoritma YOLO,” *Hello World J. Ilmu Komput.*, vol. 2, no. 4, pp. 199–206, 2024.
- [11] U. R. Nur Santoso and F. Gamar, “Deteksi Sampah Botol Plastik di Perairan Menggunakan YOLO v4-Tiny,” *J. Teknol. Dan Sist. Inf. Bisnis*, vol. 7, no. 1, pp. 91–98, 2025.
- [12] M. Ito, N. H. Kim, and N. Kogiso, “Conservative reliability index for epistemic uncertainty in reliability-based design optimization,” *Struct. Multidiscip. Optim.*, vol. 57, no. 5, pp. 1919–1935, 2018.