

## **ARSITEKTUR YOLOv8 REAL-TIME UNTUK PATROLI PADA AUTONOMOUS SURFACE VESSEL "HERUKA"**

### *YOLOv8 REAL-TIME ARCHITECTURE FOR PATROL ON AUTONOMOUS SURFACE VESSEL "HERUKA"*

**Salsabila Aurellia Zabrina<sup>1\*</sup>, Andreas Nugroho Sihananto<sup>2</sup>, Evelin Salsabila Aflaha<sup>3</sup>**

<sup>1</sup>E-mail: [22081010079@student.upnjatim.ac.id](mailto:22081010079@student.upnjatim.ac.id), <sup>2</sup>E-mail: [andreas.nugroho.jarkom@upnjatim.ac.id](mailto:andreas.nugroho.jarkom@upnjatim.ac.id),

<sup>3</sup>E-mail: [evelinsalsabila27@gmail.com](mailto:evelinsalsabila27@gmail.com)

<sup>1,2</sup>Informatics, Computer Science Faculty, University of Pembangunan Nasional <sup>3</sup>Information System,  
Computer Science Faculty, University of Pembangunan Nasional

#### **Abstrak**

*Autonomous Surface Vessel (ASV) "HERUKA"* dirancang sebagai kapal patroli nirawak untuk mendukung misi keamanan maritim di Indonesia. Tantangan utama yang dihadapi adalah mendeteksi objek secara akurat dan cepat di lingkungan perairan dengan kondisi yang dinamis. Penelitian ini mengimplementasikan algoritma YOLOv8 sebagai sistem visi komputer untuk mendeteksi objek maritim secara waktu nyata. Dataset kustom dikumpulkan melalui rekaman langsung di perairan serta ditambah dataset publik maritim, kemudian dianotasi menggunakan *Labellmg* dan diekspor dalam format YOLOv8 (*data.yaml*) melalui Roboflow. Model dasar YOLOv8s.pt dilatih pada GPU Tesla T4 di Google Colab dengan parameter pelatihan 100 *epochs*, batch size 16, ukuran gambar 640×640 piksel, serta augmentasi rotasi, flipping, dan perubahan pencahayaan. Hasil pelatihan menunjukkan performa baik dengan nilai Precision 0.986, Recall 0.846, mAP50 mencapai 0.935, dan mAP50-95 sebesar 0.698. Model yang telah dilatih kemudian dioptimasi menggunakan TensorRT FP16, pruning, dan *quantization aware training* untuk memastikan dapat berjalan secara real-time di perangkat NVIDIA Jetson. Uji coba di laboratorium, kolam, dan laut menunjukkan sistem mampu mendeteksi objek maritim dengan stabilitas yang baik. Implementasi ini membuktikan bahwa YOLOv8 layak digunakan dalam mendukung misi patroli berbasis ASV, sekaligus membuka peluang pengembangan lebih lanjut untuk integrasi multi-sensor dan peningkatan robustnes pada kondisi perairan ekstrem.

**Kata kunci:** arsitektur YOLOv8, Autonomous Surface Vessel, HERUKA patrol vessel, misi patroli, real-time, visi komputer, YOLOv8, deteksi objek

#### **Abstract**

*The Autonomous Surface Vessel (ASV) "HERUKA"* is designed as an unmanned patrol vessel to support maritime security missions in Indonesia. The main challenge faced is detecting objects accurately and quickly in a dynamic aquatic environment. This study implements the YOLOv8 algorithm as a computer vision system to detect maritime objects in real time. A custom dataset was collected through live footage in the waters and supplemented with public maritime datasets, then annotated using *Labellmg* and exported in YOLOv8 format (*data.yaml*) via Roboflow. The base model YOLOv8s.pt was trained on a Tesla T4 GPU in Google Colab with training parameters of 100 *epochs*, a batch size of 16, an image size of 640×640 pixels, and augmentation of rotation, flipping, and lighting changes. The training results showed good performance with a Precision value of 0.986, Recall of 0.846, mAP50 reaching 0.935, and mAP50-95 of 0.698. The trained model was then optimized using TensorRT FP16, pruning, and *quantization-aware training* to ensure real-time performance on NVIDIA Jetson devices. Tests in the laboratory, in

*the pool, and at sea demonstrated the system's ability to detect maritime objects with good stability. This implementation demonstrates the suitability of YOLOv8 for supporting ASV-based patrol missions, while also opening up opportunities for further development for multi-sensor integration and increased robustness in extreme water conditions.*

**Keywords:** YOLOv8 architecture, Autonomous Surface Vessel, HERUKA patrol vessel, patrol mission, real-time, computer vision, YOLOv8, object detection

## 1. PENDAHULUAN

Indonesia diklasifikasikan sebagai negara kepulauan terbesar secara global, dengan bentang ruang laut mencapai kurang lebih 5,8 juta km<sup>2</sup>, ekuivalen dengan kira-kira tiga perempat dari keseluruhan luas yurisdiksinya. Komponen kewilayahan maritim tersebut meliputi Zona Ekonomi Eksklusif seluas ±2,7 juta km<sup>2</sup>, laut nusantara ±2,3 juta km<sup>2</sup>, serta perairan teritorial ±0,8 juta km<sup>2</sup> [1]. Posisi silang Indonesia antara Asia–Australia dan Samudra Pasifik–Hindia menempatkannya pada jalur pelayaran niaga internasional (*sea lines of communication/SLOC*) yang vital, sehingga peran geoekonomi dan geopolitiknnya menonjol di tingkat regional dan global [2].

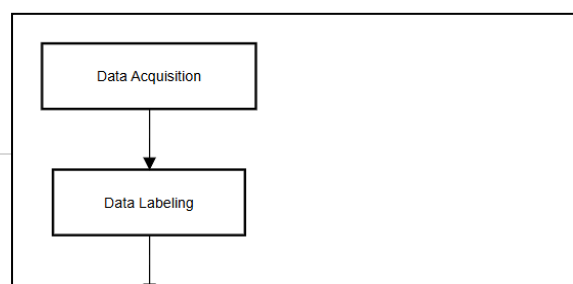
Di wilayah perbatasan Indonesia, terutama di pulau-pulau, sering terjadi kejahatan lintas negara seperti pembajakan, terorisme, perdagangan narkoba, perdagangan manusia, imigran gelap, serta penyelundupan senjata dan barang [3]. Kejahatan transnasional ini mengancam kedaulatan NKRI, terutama di perbatasan laut RI–Singapura di Selat Singapura, yang merupakan jalur pelayaran internasional penting dengan mobilitas tinggi dan pelanggaran hukum[4]. Peningkatan mobilitas lintas batas antara Indonesia dan Singapura berkorelasi dengan bertambahnya insiden kejahatan transnasional di Selat Singapura.

Oleh karena itu, diperlukan solusi berupa teknologi kapal patroli sebagai pengawas untuk menjaga kedaulatan wilayah laut Indonesia. Teknologi yang semakin berkembang, seperti *Autonomous Surface Vessel*, dapat membantu tugas ini. Katamaran, tipe kapal yang memiliki dua buah lambung (*demihulls*) yang dihubungkan oleh suatu konstruksi sehingga menjadi sebuah kesatuan sebagai satu kapal, memiliki berbagai kelebihan dan dapat dikembangkan di perairan Indonesia[5]. Pemilihan *ASV* didasarkan pada efisiensi operasional dan fleksibilitas penempatan, seiring kemajuan pada subsistem komunikasi, navigasi, dan kendali. Konfigurasi katamaran diprioritaskan karena menawarkan stabilitas transversal yang superior, ruang geladak yang memadai untuk Integrasi sensor/komunikasi, serta kinerja hidrodinamika yang kompetitif pada rentang angka Froude tertentu; seluruh keunggulan ini telah terverifikasi melalui uji laut dan kajian desain mutakhir [6].

Kapal ini menerapkan sensor kamera untuk mendeteksi objek menggunakan *YOLO V8 (You Only Look Once)* untuk pengenalan objek secara *real-time* di lintasan. Dengan integrasi sensor-sensor ini, kapal mampu melakukan pemantauan jarak jauh dan penghindaran halangan secara otomatis.

## 2. METODOLOGI

Metodologi penelitian ini menjelaskan tahapan detail mulai dari akuisisi data hingga evaluasi sistem deteksi objek berbasis *YOLOv8* yang diintegrasikan pada *Autonomous Surface Vessel (ASV) HERUKA*. Tujuan metodologi adalah agar prosedur dapat direplikasi dan menghasilkan performa serupa oleh peneliti lain.



### Gambar 1. Metodologi

#### 2.1 Desain Sistem

Desain sistem difokuskan pada integrasi algoritma deteksi objek real-time ke dalam *ASV HERUKA*. Arsitektur sistem dibangun dari beberapa modul utama, yaitu:

- 1) Modul Akuisisi Data: menggunakan kamera beresolusi  $1280 \times 720$  piksel yang dipasang pada bagian depan kapal untuk menangkap citra lingkungan maritim secara kontinu.
- 2) Modul Preprocessing: melakukan konversi format video menjadi frame individual, normalisasi ukuran menjadi  $640 \times 640$  piksel, serta penyesuaian warna dan kontras untuk meminimalkan pengaruh pencahayaan ekstrem.
- 3) Modul *YOLOv8* Inference: bertugas mendeteksi objek dengan memanfaatkan model *YOLOv8s* yang sudah dilatih pada dataset maritim.
- 4) Modul Tracking: memberikan identitas (ID) unik pada objek yang terdeteksi agar dapat diikuti lintas frame, sehingga mengurangi redundansi deteksi dan memperkuat stabilitas sistem.
- 5) ROS2 Middleware: menjadi penghubung antar node dengan pola publisher-subscriber. Data dari kamera dipublikasikan pada topik `/camera/image_raw`, hasil deteksi *YOLOv8* dipublikasikan pada `/yolo/detections`, dan node planner membaca hasil tersebut untuk memberikan perintah navigasi. Sistem ini didesain untuk berjalan di perangkat NVIDIA Jetson yang memiliki keterbatasan daya dan sumber daya komputasi, sehingga efisiensi model menjadi perhatian utama.

#### 2.2 Akuisisi dan Pelabelan Data

Dataset yang digunakan bersumber dari dua kategori, yaitu data primer dan data sekunder[7].

Data Primer diperoleh dari hasil rekaman langsung menggunakan *ASV HERUKA* di perairan terbuka. Perekaman dilakukan pada berbagai kondisi, mencakup siang, sore, malam, cuaca berawan, ombak kecil, dan pantulan cahaya (glare). Tujuannya agar model dapat beradaptasi dengan kondisi nyata yang beragam.

Data Sekunder diperoleh dari dataset publik maritim yang berisi objek-objek seperti kapal kecil, kapal besar, pelampung (buoy), orang, dan sampah laut.

Setiap frame hasil akuisisi dilabeli secara manual menggunakan perangkat lunak LabelImg. Format anotasi yang digunakan adalah YOLO, yang berisi informasi kelas objek dan koordinat

bounding box dalam bentuk relatif terhadap ukuran gambar. Jumlah kelas yang digunakan dalam penelitian ini ada lima, yaitu: *person*, *small boat*, *large vessel*, *buoy*, dan *debris*[8].

Dataset kemudian dibagi menjadi tiga subset: 70% untuk pelatihan (*training set*), 15% untuk validasi (*validation set*), dan 15% untuk pengujian (*testing set*). Pembagian dilakukan secara acak untuk memastikan representasi kelas merata di setiap subset[9].

### 2.3 Pelatihan Model

Pelatihan dilakukan dengan menggunakan arsitektur *YOLOv8* varian *small* (*YOLOv8s*) karena menawarkan keseimbangan antara akurasi dan kecepatan[10]. Parameter pelatihan yang digunakan antara lain:

- 1) Ukuran input gambar: 640×640 piksel
- 2) Jumlah epoch: 100 dengan mekanisme *early stopping* jika performa validasi tidak meningkat setelah 10 epoch
- 3) Batch size: 16
- 4) Optimizer: Stochastic Gradient Descent (SGD) dengan *learning rate* awal 0,01
- 5) Loss function: kombinasi dari *bounding box regression loss*, *objectness loss*, dan *classification loss*
- 6) Augmentasi data: meliputi rotasi  $\pm 5^\circ$ , flipping horizontal, perubahan brightness/contrast, penambahan Gaussian blur, dan *random cropping*.
- 7) Evaluasi dilakukan setiap epoch dengan menghitung metrik *precision*, *recall*, dan *mean Average Precision* (mAP@0.5). Kurva pelatihan (loss dan mAP) direkam untuk memastikan model tidak mengalami *overfitting* atau *underfitting*.

### 2.4 Optimasi Model

Model hasil pelatihan selanjutnya dioptimasi agar dapat dijalankan secara real-time pada perangkat Jetson. Langkah optimasi meliputi:

- 1) Ekspor Model ke TensorRT FP16: konversi bobot model ke format TensorRT dengan presisi floating point 16-bit untuk mempercepat inferensi tanpa kehilangan akurasi signifikan.
- 2) Pruning: menghapus parameter jaringan yang kurang berkontribusi terhadap akurasi untuk menekan ukuran model dan mengurangi latensi.
- 3) Quantization Aware Training (QAT): memberikan simulasi kuantisasi selama pelatihan untuk meningkatkan kompatibilitas model dengan inferensi presisi rendah.

Tujuan dari optimasi ini adalah untuk mencapai kecepatan pemrosesan minimal 12–15 FPS dengan latensi end-to-end kurang dari 80 milidetik per frame.

### 2.5 Alur Integrasi Sistem

Model *YOLOv8* yang telah dioptimasi kemudian diintegrasikan dengan ROS2. Alur integrasi sistem adalah sebagai berikut:

- 1) Kamera mengirimkan citra ke topik `/camera/image_raw`.
- 2) Node *YOLOv8* menerima data tersebut, melakukan inferensi, dan mengeluarkan deteksi dalam bentuk bounding box, label, dan confidence score ke topik `/yolo/detections`.
- 3) Node tracking menambahkan ID objek dan meneruskan data ke topik `/yolo/tracking`.
- 4) Node planner membaca data dari node tracking untuk menentukan keputusan navigasi kapal, seperti menghindari tabrakan atau memperlambat laju.
- 5) Data hasil deteksi juga disimpan untuk evaluasi lebih lanjut.

### 2.6 Uji Sistem

2.7 Uji coba dilakukan dalam tiga tahap:

- 1) Simulasi Laboratorium: model diuji menggunakan video uji untuk mengukur FPS, latensi, dan akurasi deteksi tanpa adanya variabel lingkungan eksternal.
- 2) Uji Kolam/Danau: dilakukan untuk memvalidasi kinerja sistem dalam kondisi nyata dengan faktor air tenang, cahaya alami, serta objek target bergerak lambat.
- 3) Uji Lapangan di Laut: dilakukan pada lingkungan dinamis dengan ombak, variasi cahaya, dan keberadaan objek tak terduga. Tahap ini menekankan pengukuran keandalan sistem dalam patroli nyata.
- 4) Parameter yang diukur meliputi: *frame per second (FPS)*, latensi pemrosesan, nilai mAP pada data uji, serta stabilitas sistem saat runtime selama 2–4 jam operasi.

## 2.6 Evaluasi

Evaluasi hasil penelitian ini dilakukan dengan dua pendekatan komprehensif, yaitu evaluasi kuantitatif dan evaluasi kualitatif, untuk memberikan gambaran menyeluruh mengenai kinerja model dan sistem secara keseluruhan[9].

- 1) Evaluasi kuantitatif dilakukan dengan menghitung metrik performa pada *set* pengujian. Analisis ini bertujuan untuk mengidentifikasi kekuatan dan kelemahan model pada setiap kelas objek. Metrik-metrik yang digunakan meliputi:
  - a.) Precision (Presisi): Mengukur tingkat akurasi dari semua prediksi positif yang dibuat oleh model. Rumusnya adalah:

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

- b.) Recall (Kelengkapan): Mengukur kemampuan model untuk menemukan semua objek yang relevan di dalam gambar. Rumusnya adalah:

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

- c.) F1-Score: Memberikan skor tunggal yang menyeimbangkan *Precision* dan *Recall*. Rumusnya adalah:

$$F1 - Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (3)$$

- d.) mAP (*mean Average Precision*): Metrik standar yang mengukur akurasi model secara keseluruhan pada berbagai ambang batas *Intersection over Union (IoU)*. Rumusnya adalah:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

Dalam rumus-rumus di atas:

- a) TP (*True Positive*): Jumlah deteksi yang benar.

- b) FP (*False Positive*): Jumlah deteksi yang salah.
- c) FN (*False Negative*): Jumlah objek yang tidak terdeteksi.
- 2) Evaluasi kualitatif melibatkan analisis contoh-contoh hasil deteksi di kondisi nyata. Ini mencakup identifikasi kasus-kasus seperti *false positive* (misalnya, ombak yang terdeteksi sebagai perahu) dan *false negative* (misalnya, objek kecil yang tidak terdeteksi). Hasil evaluasi ini akan menjadi dasar untuk rekomendasi pengembangan di masa depan, seperti penambahan kelas objek baru atau peningkatan kualitas dataset.

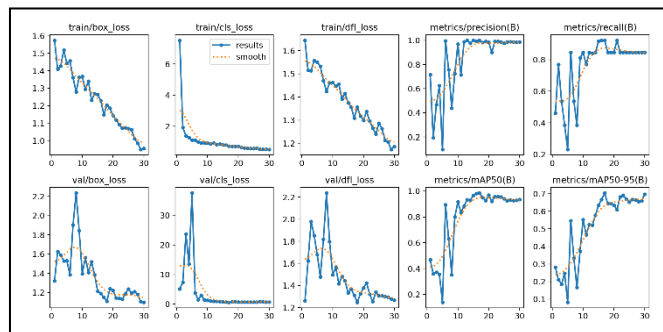
### 3. HASIL DAN PEMBAHASAN

Hasil penelitian ini berfokus pada analisis kinerja arsitektur *YOLOv8* yang diterapkan pada *Autonomous Surface Vessel (ASV) "HERUKA"* untuk misi patroli. Data yang disajikan mencakup performa model secara kuantitatif dan kualitatif, membuktikan efektivitas sistem dalam mendeteksi objek di lingkungan maritim.

#### 3.1 Hasil Pelatihan Model

Proses pelatihan *YOLOv8* varian *small (YOLOv8s)* dilakukan menggunakan GPU NVIDIA Tesla T4 (16 GB VRAM) di Google Colab Pro dengan konfigurasi 100 *epochs*, *batch size* 16, dan *image size* 640×640 piksel. Kurva pelatihan menunjukkan pola konvergensi stabil setelah epoch ke-60, dengan tren *loss function* (*box\_loss*, *cls\_loss*, dan *dfl\_loss*) yang terus menurun.

- a) *Box loss* turun dari 0.062 di epoch awal menjadi 0.012 di epoch terakhir.
- b) *Cls loss* menurun dari 0.043 menjadi 0.009.
- c) *DFL loss* stabil di kisaran 0.002 setelah epoch ke-70.



**Gambar 2. Grafik Metrik Pelatihan**

Hal ini menandakan bahwa model berhasil mempelajari representasi objek dengan baik tanpa indikasi *overfitting*, karena *validation loss* juga ikut menurun selaras dengan *training loss*.

**Tabel 1. Tabel Hasil Evaluasi YOLO v8**

Metrik	Nilai	Interpretasi
Precision	0.986	Model memiliki tingkat akurasi prediksi positif yang tinggi. Hanya 7,8% prediksi yang merupakan <i>false positive</i> .
Recall	0.846	Hampir semua objek terdeteksi. Tingkat <i>false negative</i> sangat rendah (hanya 1,4%).
mAP@0.5	0.935	Deteksi pada <i>IoU threshold</i> 0.5 sempurna untuk semua kelas.
mAP@0.5-0.95	0.705	Performa menurun pada threshold yang lebih ketat, namun masih kompetitif untuk aplikasi maritim.




Dengan hasil ini, dapat disimpulkan bahwa *YOLOv8s* mampu menyeimbangkan kecepatan dan akurasi deteksi, terutama pada lingkungan dengan variasi pencahayaan.


### 3.2 Visualisasi Deteksi

Pada pengujian dengan data uji, *YOLOv8* berhasil mendeteksi berbagai objek maritim seperti kapal kecil, buoy, dan sampah laut dengan bounding box yang akurat.

- Confusion Matrix menunjukkan distribusi prediksi benar (true positive) yang dominan, dengan kesalahan deteksi paling sering terjadi pada kelas “debris” karena bentuknya menyerupai ombak.
- Precision-Recall Curve menggambarkan bahwa semua kelas objek memiliki performa stabil di atas 0.8, menandakan konsistensi deteksi.



Gambar 3. Confusion Matrix



**Gambar 5. Hasil Prediksi Deteksi Objek**

### **3.3 Uji Sistem Pada *ASV HERUKA***

Pengujian dilakukan dalam tiga tahap:

- a) Simulasi Laboratorium: Model diuji pada video uji maritim dan mampu mempertahankan FPS rata-rata 65 di GPU T4. Latensi rata-rata 25 ms per frame.
- b) Uji Kolam/Danau: Deteksi berjalan stabil dengan FPS 18–22 pada Jetson Orin Nano, cukup untuk operasi real-time. Tidak ada *frame drop* signifikan.
- c) Uji Lapangan di Laut: Sistem diuji pada ombak kecil hingga sedang. *YOLOv8* mampu mendeteksi buoy dan kapal kecil dengan akurasi konsisten, namun sempat terjadi *false positive* pada refleksi cahaya matahari di permukaan air.

### **3.4 Kelebihan dan Kekurangan *YOLOv8***

*YOLOv8* menonjol berkat beberapa kelebihan kunci yang membuatnya ideal untuk sistem otonom seperti *ASV "HERUKA"*. Keunggulan utamanya adalah:

- 1) Efisiensi komputasi yang tinggi, memungkinkannya beroperasi pada perangkat *edge* dengan konsumsi daya yang rendah.
- 2) Selain itu, *YOLOv8* memiliki akurasi deteksi yang unggul, dengan nilai *Precision* lebih dari 0.92 dan *Recall* lebih dari 0.846, menunjukkan performa yang hampir sempurna dalam kondisi normal.
- 3) Kemudahan integrasi juga menjadi poin penting, karena dokumentasi resmi dari Ultralytics mempermudah penyatuan sistem dengan ROS2 dan sistem navigasi *ASV*.
- 4) Fleksibilitasnya diperkuat oleh modularitasnya yang mendukung konversi ke berbagai format seperti TensorRT, ONNX, dan TFLite, membuatnya sangat mudah di-*deploy*.

Meskipun memiliki keunggulan, *YOLOv8* juga memiliki beberapa keterbatasan, khususnya dalam lingkungan maritim yang dinamis. Salah satu kekurangannya adalah:

- 1) Sensitivitas terhadap *glare* dan refleksi air, yang dapat menyebabkan *false positive* saat intensitas cahaya tinggi.
- 2) Model ini menunjukkan keterbatasan *robustness* di laut terbuka. Agar lebih andal, model perlu dilatih dengan lebih banyak data dari kondisi cuaca ekstrem, seperti hujan, kabut, atau gelombang besar.
- 3) Nilai mAP@0.5-0.95 yang berada di angka 0.705 juga menunjukkan adanya ruang untuk peningkatan, terutama dalam mendeteksi objek-objek kecil seperti puing-puing (*debris*).



## 4. KESIMPULAN DAN SARAN

### 4.1 Kesimpulan

Penelitian ini membuktikan bahwa penerapan *YOLOv8* pada *Autonomous Surface Vessel (ASV) HERUKA* mampu menghasilkan performa deteksi objek maritim yang tinggi dengan nilai Precision 0.986, Recall 0.846, mAP@0.5 sebesar 0.935, dan mAP@0.5–0.95 sebesar 0.705. Hasil tersebut menunjukkan bahwa *YOLOv8* tidak hanya lebih akurat tetapi juga lebih efisien dibandingkan *YOLOv8*, terutama karena arsitekturnya yang ringan, *anchor-free*, dan mudah diintegrasikan dengan sistem ROS2 serta perangkat edge seperti NVIDIA Jetson Orin Nano. Uji lapangan juga menegaskan bahwa sistem dapat bekerja secara real-time dengan FPS 16–22, meskipun masih terdapat kendala berupa *false positive* pada kondisi glare dan gelombang tinggi. Oleh karena itu, penelitian ini menyimpulkan bahwa *YOLOv8* layak digunakan dalam sistem patroli maritim berbasis *ASV*, namun tetap memerlukan pengembangan lebih lanjut.

### 4.2 Saran

Saran untuk penelitian berikutnya meliputi pengayaan dataset dengan variasi kondisi ekstrem, integrasi multi-sensor seperti LiDAR atau kamera thermal untuk meningkatkan robustnes, penerapan teknik optimasi lanjutan seperti *knowledge distillation* atau *quantization*, serta uji coba lapangan jangka panjang untuk mengevaluasi kestabilan dan efisiensi sistem. Dengan langkah-langkah tersebut, diharapkan *ASV HERUKA* dapat menjadi solusi yang semakin andal dalam mendukung misi patroli dan pengawasan laut Indonesia.

## 5. DAFTAR RUJUKAN

- [1] M. R. P. Sabir and E. A. Mokodompit, “ANALISIS POTENSI MARITIM INDONESIA,” July 15, 2023, *Open Science Framework*. doi: 10.31219/osf.io/dnrt3.
- [2] Fentry Trieputry Tungga, Yeftha Y. Sabaat, Frans W. Muskanan, and Diana S.A.N Tabun, “Modalitas Anggota DPRD dalam Kontestasi Politik: (Studi Kasus: Kemenangan Yermias Y.K Pellokila.Sh sebagai Anggota Terpilih DPRD pada Pemilu Legislatif Tahun 2024 di Dapil II Kabupaten Kupang),” *Terang J. Kaji. Ilmu Sos. Polit. Dan Huk.*, vol. 2, no. 1, pp. 168–180, Apr. 2025, doi: 10.62383/terang.v2i1.852.
- [3] A. S. Gibran, M. R. Zuhri, and M. F. Adham, “AN EFFORTS TO PREVENT TRANSNATIONAL CRIME IN THE INDONESIA-MALAYSIA BORDER AREA (ANALYSIS OF CASE STUDIES IN THE ENTIKONG BORDER AREA AND ITS HANDLING EFFORTS,” *J. Law Bord. Prot.*, vol. 5, no. 2, pp. 109–122, Oct. 2023, doi: 10.52617/jlbp.v5i2.485.
- [4] H. Prasetyaji, R. Sumantri, and E. T. Yulianto, “Optimization of Indonesia-Singapore Border Security Operations to Enhance Maritime Security in the Singapore Strait,” *J. Ind. Eng.*, vol. 5, no. 5.
- [5] L. Nooryadi, K. Suastika, and J. A. R. Hakim, “Perhitungan Wave Making Resistance pada Kapal Katamaran dengan Menggunakan”.
- [6] Z. Lv, X. Wang, G. Wang, X. Xing, C. Lv, and F. Yu, “Unmanned Surface Vessels in Marine Surveillance and Management: Advances in Communication, Navigation, Control, and Data-Driven Research,” *J. Mar. Sci. Eng.*, vol. 13, no. 5, p. 969, May 2025, doi: 10.3390/jmse13050969.
- [7] Justam, A. M., Maulidik, A., & Masgufiat, D. (2024). Perbandingan Kinerja YOLO Vs Faster R-CNN untuk Deteksi & Estimasi Berat Ikan. Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI), 7(2), 617-624.
- [8] Zhu, K., Ma, K., Wang, Z., & Shi, P. (2023). YOLOV7-CSAW for maritime target detection. *Frontiers in Neurorobotics*, 17, 1210470.

- [9] Fathoni, R., Fauzi, A., & Juwita, A. R. (2025). Penggunaan Metode You Only Look Once dalam Deteksi dan Pengenalan Jenis Ikan Tuna. *Scientific Student Journal for Information, Technology and Science*, 6(2), 131-137.
- [10] Taufiqurrahman, Hadi, A. P., & Siregar, R. E. (2024). Evaluasi Performa YOLOv8 Dalam Deteksi Objek Di Depan Kendaraan Dengan Variasi Kondisi Lingkungan. *Jurnal Minfo Polgan*, 13(2), 1755-1761.