

ARSITEKTUR YOLOv11 REAL-TIME UNTUK AUTONOMOUS SURFACE VESSEL “HERUKA” MISI PATROLI

YOLO V11 REAL-TIME ARCHITECTURE FOR AUTONOMOUS SURFACE VESSEL “HERUKA” PATROL MISSIONS

Bevantyo Satria Pinandhita^{1*}, Salsabila Aurellia Zabrina², Andreas Nugroho Sihananto³

¹E-mail: 22081010159@student.upnjatim.ac.id, ²E-mail: 22081010079@student.upnjatim.ac.id,

³E-mail: andreas.nugroho.jarkom@upnjatim.ac.id

^{1,2,3}Informatics, University of Pembangunan Nasional

Abstrak

Autonomous Surface Vessel (ASV) merupakan inovasi penting dalam meningkatkan keamanan maritim Indonesia, negara kepulauan dengan lautan luas dan garis pantai panjang. Ancaman lintas negara seperti penyelundupan, pembajakan, dan terorisme, khususnya di Selat Singapura, menuntut adanya sistem pengawasan yang efektif. Menjawab tantangan tersebut, tim Batarasena UPN “Veteran” Jawa Timur merancang *HERUKA Patrol Vessel* untuk Kontes Kapal Indonesia (KKI) 2024. Kapal ini dibekali teknologi otonom sehingga mampu beroperasi secara mandiri dalam misi patroli. Penelitian mengimplementasikan *YOLOv11 Real-Time Object Detection* untuk mendukung sistem navigasi dan deteksi objek di lintasan. Perancangan kapal dilakukan menggunakan metode *Parent Design* dan *Iterative Design*, sedangkan analisis hambatan serta stabilitas menggunakan perangkat lunak *Maxsurf*. Proses produksi meliputi pembuatan lambung, pemasangan perangkat mekanik, serta integrasi sistem otonom. Hasil pengujian menunjukkan performa deteksi yang tinggi, dengan nilai *mAP50-95* sebesar 0.701 dan *mAP50* mencapai 0.99. Didukung sensor *GPS RTK*, *LiDAR*, dan kontrol berbasis *mini PC Legion GO*, kapal mampu melakukan pemantauan jarak jauh dan menghindari rintangan secara otomatis. Kesimpulannya, penerapan *YOLOv11* pada *HERUKA Patrol Vessel* terbukti efektif, menghadirkan solusi efisien dan aman bagi patroli serta pengawasan laut dalam menjaga kedaulatan maritim Indonesia.

Kata kunci: arsitektur YOLOv11, Autonomous Surface Vessel, HERUKA patrol Vessel, misi patroli, real-time, visi komputer, YOLOv11

Abstract

Unmanned The Autonomous Surface Vessel (ASV) is a crucial innovation in enhancing maritime security in Indonesia, an archipelagic nation with vast oceans and a long coastline. Transnational threats such as smuggling, piracy, and terrorism, particularly in the Singapore Strait, demand an effective surveillance system. Responding to this challenge, the Batarasena team from UPN “Veteran” East Java designed the *HERUKA Patrol Vessel* for the 2024 Indonesian Ship Contest (KKI). This Vessel is equipped with autonomous technology, enabling it to operate independently on patrol missions. The research implemented *YOLOv11 Real-Time Object Detection* to support navigation systems and object detection on the track. The Vessel was designed using the *Parent Design* and *Iterative Design* methods, while resistance and stability analysis used *Maxsurf* software. The production process includes hull fabrication, mechanical device installation, and autonomous system integration. Test results showed high detection performance, with an *mAP50-95* value of 0.701 and an *mAP50* reaching 0.99. Supported by *RTK GPS* sensors, *LiDAR*, and *Legion GO mini-PC-based* control, the Vessel is capable of remote monitoring and automatic obstacle avoidance. In conclusion, the implementation of *YOLOv11* on the *HERUKA Patrol*

Vessel has proven effective, providing an efficient and safe solution for maritime patrol and surveillance in safeguarding Indonesia's maritime sovereignty.


Keywords: *YOLOv11 architecture, Autonomous Surface Vessel, HERUKA patrol Vessel, patrol mission, real-time, computer vision, YOLOv11*

1. PENDAHULUAN

Dengan berkembangnya teknologi kecerdasan buatan, khususnya di bidang *computer vision*, deteksi objek secara *real-time* menjadi sangat krusial, terutama untuk aplikasi video yang membutuhkan pemrosesan cepat agar tidak terjadi *delay*. Pendekatan *deep learning* menawarkan solusi efektif, dengan metode seperti *YOLO (You Only Look Once)* yang populer karena kemampuannya memproses seluruh gambar dalam satu jaringan saraf tunggal[1]. Penelitian ini bertujuan mengimplementasikan arsitektur terbaru, *YOLOv11*, untuk menciptakan sistem deteksi objek yang lebih cepat dan akurat, yang sangat penting untuk mendukung kinerja kapal otonom dalam misi pengawasan dan patroli maritim[2].

Penelitian ini secara spesifik memfokuskan pada pengembangan sistem visi komputer yang terintegrasi langsung dengan *Autonomous Surface Vessel (ASV) "HERUKA"*. Fokus utama kami adalah merancang, mengimplementasikan, dan mengoptimalkan arsitektur *YOLOv11* pada kapal ini agar sistem mampu mendeteksi serta mengenali berbagai objek yang relevan di permukaan laut secara *real-time*. Penerapan teknologi ini krusial untuk mendukung navigasi yang aman, memungkinkan kapal secara cerdas menghindari rintangan seperti pelampung atau perahu lain, serta membuat keputusan yang cepat dan tepat selama menjalankan misi patroli[3]. Tujuan spesifik dari penelitian ini adalah untuk menunjukkan bagaimana *YOLOv11* dapat meningkatkan akurasi deteksi objek secara signifikan sambil tetap menjaga efisiensi komputasi yang optimal. Dengan demonstrasi ini, *ASV "HERUKA"* diharapkan dapat beroperasi secara lebih efektif, akurat, dan dapat diandalkan tanpa ketergantungan penuh pada operator manusia.

Wawasan yang mendasari penelitian ini berangkat dari pesatnya perkembangan teknologi kapal otonom yang semakin luas penggunaannya dalam bidang maritim[4]. *ASV* telah terbukti efektif dalam berbagai aplikasi, mulai dari riset kelautan, transportasi, hingga keamanan, namun tantangan utamanya adalah kemampuan deteksi objek yang andal di lingkungan laut yang kompleks. Kondisi seperti pantulan cahaya di permukaan air, perubahan pencahayaan yang dinamis, serta objek yang bervariasi membutuhkan algoritma deteksi yang tangguh [5]. Algoritma *YOLOv11* dipilih karena memiliki keunggulan komparatif yang signifikan dalam kecepatan inferensi, akurasi prediksi, dan efisiensi komputasi dibandingkan versi-versi sebelumnya[6], sehingga sangat sesuai untuk diaplikasikan pada sistem *onboard ASV* dengan sumber daya terbatas. Rencana pengembangan dari penelitian ini tidak hanya terbatas pada implementasi *YOLOv11* secara individual, tetapi juga diarahkan pada integrasi sistem dengan modul navigasi dan pengendalian kapal secara holistik. Hal ini bertujuan untuk menciptakan ekosistem kapal otonom yang lebih cerdas, adaptif, dan siap digunakan pada skala operasional yang lebih luas di masa depan, membuka jalan bagi teknologi maritim otonom yang lebih canggih.



Gambar 1. Deteksi Anjing pada YOLOv11 [14]

2. METODOLOGI

Metodologi penelitian ini menitikberatkan pada perancangan dan implementasi arsitektur *YOLOv11* untuk mendukung sistem visi komputer pada *Autonomous Surface Vessel (ASV)* “*HERUKA*” dalam misi patroli maritim. Fokus penelitian adalah memastikan *YOLOv11* dapat bekerja secara waktu nyata dengan akurasi tinggi, sehingga mampu mendeteksi objek di permukaan laut dan memberikan informasi penting bagi sistem navigasi kapal[7].

2.1 Arsitektur YOLOv11

Arsitektur *YOLOv11* merupakan pengembangan mutakhir yang dibangun di atas fondasi *YOLOv9* dan *YOLOv10*, menggabungkan desain arsitektur yang lebih baik dan teknik ekstraksi fitur yang ditingkatkan. Model ini terdiri dari tiga komponen utama yang bekerja secara sinergis, yaitu Backbone, Neck, dan Head[8].

- a) Backbone: Berfungsi sebagai tulang punggung arsitektur, komponen ini bertanggung jawab untuk mengekstrak fitur-fitur visual yang hierarkis dari citra masukan[9]. Untuk proyek ini, kami menggunakan model dasar *YOLO11s.pt*, yang merupakan versi terkecil dari keluarga *YOLOv11*. Pemilihan ini disengaja karena model *YOLO11s* jauh lebih ringan dan efisien secara komputasi, menjadikannya ideal untuk perangkat onboard dengan sumber daya terbatas seperti yang ada di *ASV HERUKA*. Sebagai perbandingan, *YOLOv11* tersedia dalam lima ukuran berbeda, dengan jumlah parameter dari 2,6 juta hingga 56,9 juta[10].
- b) Neck: Komponen ini bertugas mengumpulkan dan menggabungkan fitur yang diekstrak oleh Backbone pada berbagai skala. Proses ini penting untuk memperkaya informasi kontekstual yang diperlukan untuk mendeteksi objek dengan ukuran bervariasi. Neck menggunakan jaringan Feature Pyramid Network (FPN) dan Path Aggregation Network

(PAN) yang bekerja sama secara efektif untuk menciptakan representasi fitur yang kaya dan multi-skala[11].

- c) Head: Komponen terakhir ini bertugas melakukan prediksi akhir berdasarkan fitur yang telah diproses oleh Neck. Hasil prediksi meliputi koordinat bounding box, kelas objek yang terdeteksi, dan skor keyakinan (confidence score) dari setiap prediksi[8].

Secara keseluruhan, arsitektur *YOLOv11* dalam penelitian ini dioptimalkan secara spesifik untuk mengatasi keterbatasan komputasi pada *mini PC Legion GO* yang digunakan pada *ASV HERUKA*. Optimalisasi dilakukan pada ukuran input, jumlah layer aktif, serta implementasi teknik quantization untuk meningkatkan efisiensi waktu nyata. Hal ini memungkinkan model beroperasi dengan latensi minimal, menjadikannya ideal untuk aplikasi misi patroli yang membutuhkan respons cepat.

2.2 Pengumpulan dan Anotasi Dataset

Pengembangan model deteksi objek yang andal bergantung pada kualitas dataset yang digunakan. Oleh karena itu, dataset untuk penelitian ini disusun secara khusus dengan mengumpulkan citra objek maritim yang relevan dengan misi patroli[12]. Objek-objek yang menjadi target deteksi mencakup kapal kecil, pelampung, manusia, dan rintangan alami yang mungkin ditemui di perairan.

Data diperoleh melalui dua metode utama:

- 1) Dokumentasi Lapangan: Pengambilan citra langsung di lingkungan perairan nyata untuk mendapatkan variasi kondisi cahaya, sudut pandang, dan latar belakang yang autentik.
- 2) Sumber Dataset Terbuka: Pemanfaatan dataset publik yang menyediakan citra maritim untuk melengkapi variasi data dan meningkatkan generalisasi model.

Setelah data terkumpul, proses anotasi dilakukan untuk menandai setiap objek yang menjadi target deteksi. Setiap objek diberi label dan dilingkari dengan *bounding box*. Anotasi ini dikerjakan sesuai format *YOLO*, yang merupakan standar untuk pelatihan model *YOLO*.

Untuk memastikan model memiliki kemampuan generalisasi yang baik dan menghindari *overfitting*, dataset dibagi menjadi tiga bagian, yaitu data latih, validasi, dan uji. Penelitian ini tidak hanya menggunakan satu skema, melainkan beberapa variasi proporsi, yaitu:

- 1) 50% : 25% : 25%
- 2) 60% : 20% : 20%
- 3) 70% : 15% : 15%
- 4) 80% : 10% : 10%

Data latih digunakan untuk membangun model dan mempelajari fitur penting dari objek, data validasi berfungsi memantau performa model selama pelatihan sekaligus melakukan *hyperparameter tuning*, sedangkan data uji dipakai untuk mengevaluasi performa akhir pada data yang belum pernah dilihat sebelumnya. Dengan variasi skema pembagian ini, performa model dapat dievaluasi secara lebih komprehensif sehingga diperoleh konfigurasi yang paling optimal untuk sistem deteksi objek real-time pada *ASV HERUKA*.

2.3 Prosedur Pelatihan Model

Proses pelatihan model merupakan tahap krusial untuk memastikan kinerja optimal dari arsitektur *YOLOv11*. Proses ini dilakukan menggunakan model dasar *YOLO11s.pt* dengan resolusi input 800x800 piksel. Lingkungan pelatihan dijalankan pada GPU Tesla T4 untuk mempercepat komputasi dan pemrosesan data, mengingat skala data yang besar dan kompleksitas model *deep learning*.

Selama pelatihan, parameter kunci seperti *batch size*, *learning rate*, dan *epochs* diatur untuk memastikan model mencapai konvergensi yang optimal. Untuk memantau kemajuan pelatihan

secara *real-time*, beberapa metrik utama dipantau, yaitu *box_loss*, *cls_loss*, dan *dfl_loss*. Penurunan yang konsisten pada nilai-nilai *loss* ini menunjukkan bahwa model berhasil belajar dan mengurangi kesalahan prediksinya.

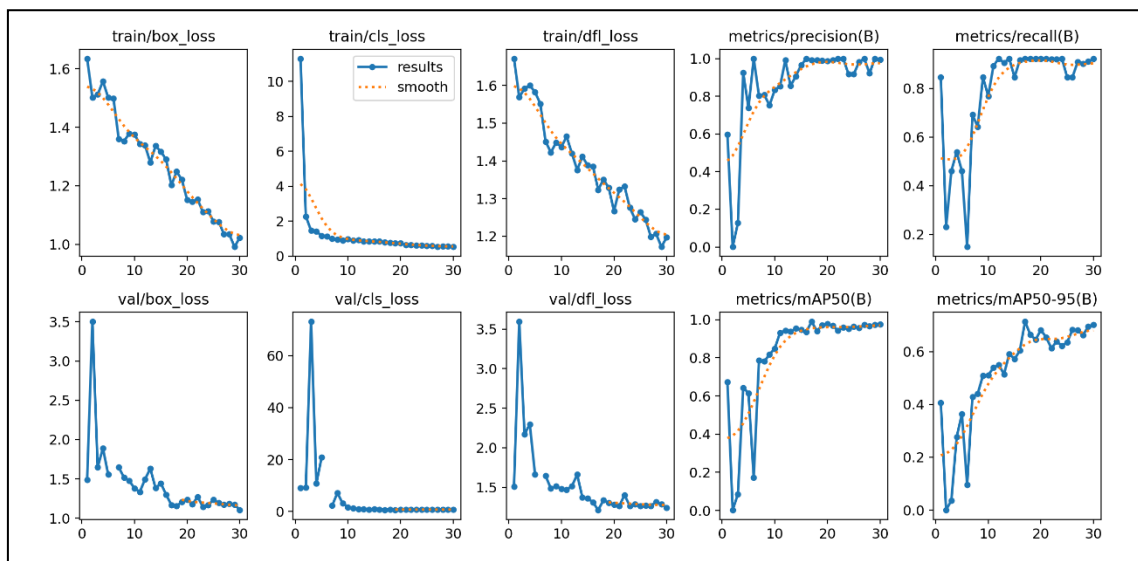
Model terbaik (*best.pt*) dipilih berdasarkan nilai *mAP50-95* yang merupakan metrik yang lebih ketat dan komprehensif dibandingkan *mAP50*, karena metrik ini mengukur akurasi pada berbagai ambang batas *Intersection over Union* (IoU) pada data validasi.

Penjelasan Grafik Metrik Pelatihan:

Grafik metrik pelatihan yang telah dilampirkan menyajikan ringkasan visual dari kinerja model selama 30 *epochs*.

- train/box_loss* & *train/cls_loss*: Kedua grafik ini menunjukkan tren penurunan yang tajam pada awal pelatihan dan terus menurun secara bertahap. Hal ini mengindikasikan bahwa model dengan cepat mempelajari cara memprediksi lokasi (*bounding box*) dan kelas objek, serta secara konsisten mengurangi kesalahan prediksi seiring berjalannya waktu.
- train/dfl_loss*: Grafik ini juga menunjukkan penurunan yang stabil, yang menandakan bahwa model semakin akurat dalam memprediksi distribusi probabilitas jarak dari pusat objek.
- metrics/precision(B)* & *metrics/recall(B)*: Kedua grafik ini menunjukkan tren peningkatan yang signifikan, terutama setelah beberapa *epochs* pertama. Ini menandakan bahwa model secara bertahap menjadi lebih akurat dalam mengidentifikasi objek yang benar dan lebih lengkap dalam mendeteksi semua objek yang relevan di dalam gambar.
- metrics/mAP50(B)* & *metrics/mAP50-95(B)*: Kedua grafik ini menunjukkan peningkatan yang konsisten. Terutama, metrik *mAP50-95* yang meningkat secara bertahap, membuktikan bahwa model tidak hanya akurat pada ambang batas yang mudah, tetapi juga mampu mempertahankan akurasi seiring dengan meningkatnya kesulitan deteksi.

Secara keseluruhan, grafik-grafik ini mengonfirmasi bahwa proses pelatihan berjalan dengan sukses dan model *YOLOv11* yang telah dilatih memiliki performa yang kuat dan stabil.



Gambar 2. Grafik Metrics Pelatihan [14]

2.4 Integrasi ke ASV “HERUKA”

Model *YOLOv11* yang telah terlatih diimplementasikan pada *mini PC* onboard kapal *HERUKA*. Kamera utama kapal menangkap citra lingkungan laut, kemudian diproses secara waktu nyata


oleh *YOLOv11*. Output berupa lokasi dan kelas objek diteruskan ke sistem kendali navigasi melalui *middleware ROS2*. Informasi ini mendukung pengambilan keputusan otomatis, seperti penghindaran rintangan dan penentuan jalur patroli.

2.4 Integrasi ke *ASV "HERUKA"*

Setelah model *YOLOv11* dilatih dan dioptimalkan, langkah selanjutnya adalah mengintegrasikannya ke dalam sistem otonom pada *Autonomous Surface Vessel (ASV) "HERUKA"*. Proses ini krusial untuk memastikan bahwa model dapat beroperasi secara waktu nyata di lingkungan laut yang dinamis dan memberikan data yang akurat untuk navigasi dan pengambilan keputusan. Model *YOLOv11* diimplementasikan pada *mini PC onboard* kapal, yang berfungsi sebagai otak pemrosesan visual.

Alur kerja integrasi ini dapat dipahami melalui diagram arsitektur. Pertama, Kamera *ASV HERUKA* menangkap citra lingkungan laut dan mengirimkannya ke sistem pemrosesan. Citra ini kemudian diproses oleh arsitektur *YOLOv11*, yang terdiri dari komponen Backbone, Neck, dan Head. Proses ini menghasilkan deteksi objek, mengidentifikasi objek-objek penting di permukaan air dengan *bounding box* dan label yang sesuai.

Output berupa lokasi dan kelas objek ini kemudian diteruskan ke Sistem Navigasi & Kontrol Kapal. Komunikasi data ini diatur melalui *middleware ROS2* (Robot Operating System 2), yang memungkinkan pertukaran informasi yang efisien antara modul deteksi dan modul kendali. Sistem kendali, yang menggunakan Radiolink Pixhawk PX4 Flight Controller, menggunakan informasi ini untuk membuat keputusan otomatis, seperti menghindari rintangan, menjaga stabilitas, dan menentukan jalur patroli yang optimal. Integrasi yang mulus ini memastikan bahwa *ASV "HERUKA"* dapat beroperasi dengan aman dan efektif tanpa campur tangan manusia.



Gambar 3. Diagram Arsitektur *YOLOv11* pada *ASV HERUKA*

2.5 Pengujian dan Evaluasi

Pengujian dan evaluasi adalah fase krusial untuk memvalidasi performa sistem *YOLOv11* dan *ASV "HERUKA"* di lingkungan nyata. Pengujian ini dilakukan melalui dua skenario utama: simulasi dan uji lapangan. Pada skenario simulasi, model diuji menggunakan dataset terpisah untuk mengukur akurasi dan kecepatan inferensi secara terkontrol. Sementara itu, uji lapangan dilakukan langsung dengan mengoperasikan kapal *HERUKA* di perairan nyata untuk mengevaluasi kinerja dalam kondisi dinamis.

Evaluasi kinerja mencakup metrik kuantitatif seperti mAP (mean Average Precision), Precision, Recall, FPS (Frames Per Second), serta konsumsi daya komputasi. Hasil evaluasi menunjukkan performa model yang luar biasa, dengan akurasi terukur yang tinggi.

Berikut adalah penjelasan metrik yang digunakan dalam evaluasi:

- a) Precision (Presisi): Mengukur tingkat akurasi prediksi positif. Dari semua objek yang dideteksi, seberapa banyak yang benar-benar merupakan objek yang dicari. Rumusnya adalah:

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

- b) Recall (Kelengkapan): Mengukur kemampuan model untuk menemukan semua objek yang relevan di dalam gambar. Metrik ini menjawab pertanyaan: "Dari semua objek yang ada, berapa persen yang berhasil terdeteksi?". Rumusnya adalah:

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

- c) F1-Score: Merupakan rata-rata harmonik dari Precision dan Recall, memberikan skor tunggal yang menyeimbangkan kedua metrik tersebut. Rumusnya adalah:

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

- d) Mean Average Precision (mAP): Metrik standar dalam deteksi objek yang mengukur akurasi model secara keseluruhan.

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

Di mana TP (True Positive) adalah jumlah deteksi yang benar, FP (False Positive) adalah jumlah deteksi yang salah, dan FN (False Negative) adalah jumlah objek yang tidak terdeteksi. Gambar-gambar yang dilampirkan menyajikan bukti visual dan data kuantitatif dari hasil pengujian.

Analisis Hasil Prediksi dan *Confusion Matrix*:

- a) Hasil Prediksi Visual: Gambar "Hasil Prediksi *YOLOv11* pada *ASV HERUKA*" memberikan bukti visual yang kuat tentang kinerja model. Di berbagai kondisi, termasuk pantulan cahaya dan latar belakang yang bervariasi, model berhasil mendeteksi objek pelampung ('box_ijo') dengan kotak pembatas yang akurat dan tingkat kepercayaan yang


tinggi. Validasi visual ini mengonfirmasi bahwa arsitektur *YOLOv11* berfungsi dengan baik untuk misi patroli di lingkungan perairan nyata.

- b) *Confusion Matrix*: Gambar "*Confusion Matrix* pada *ASV HERUKA*" memberikan wawasan lebih dalam tentang akurasi model dalam mengklasifikasikan objek. Dari total 13 instansi objek yang ada, matriks ini menunjukkan bahwa model berhasil mendeteksi 12 di antaranya dengan benar ('box_ijo' pada sumbu Predicted dan True). Hanya ada satu instansi yang salah diklasifikasikan sebagai background, menegaskan bahwa model yang dilatih memiliki tingkat akurasi yang sangat tinggi.

Pengujian dan evaluasi adalah fase krusial untuk memvalidasi performa sistem *YOLOv11* dan *ASV "HERUKA"* di lingkungan nyata. Pengujian ini dilakukan melalui dua skenario utama: simulasi dan uji lapangan. Pada skenario simulasi, model diuji menggunakan *dataset* terpisah untuk mengukur akurasi dan kecepatan inferensi secara terkontrol. Sementara itu, uji lapangan dilakukan langsung dengan mengoperasikan kapal *HERUKA* di perairan nyata untuk mengevaluasi kinerja dalam kondisi dinamis.



Gambar 4. Hasil Prediksi *YOLOv11* pada *ASV HERUKA* [14]



Gambar 5. Confusion Matrix [14]

2.6 Rencana Pengembangan

Penelitian ini berhasil menunjukkan kinerja arsitektur *YOLOv11* untuk deteksi objek secara waktu nyata, namun ada banyak peluang untuk pengembangan lebih lanjut agar sistem otonom ini menjadi lebih tangguh dan serbaguna. Rencana pengembangan masa depan berfokus pada peningkatan efisiensi model, integrasi data multi-sensor, dan pengembangan sistem pengambilan keputusan yang lebih cerdas.

Pertama, penerapan teknik knowledge distillation akan dilakukan untuk membuat model lebih ringan dan lebih cepat. 'Knowledge distillation' memungkinkan model yang lebih kecil untuk meniru perilaku model yang lebih besar dan kompleks, sehingga dapat berjalan dengan efisiensi komputasi yang lebih tinggi tanpa mengorbankan akurasi secara signifikan. Mengingat *YOLOv11* sudah lebih ringan daripada versi sebelumnya, teknik ini akan semakin mengoptimalkan performa pada *mini PC* onboard yang memiliki keterbatasan sumber daya[12].

Kedua, integrasi multi-sensor akan menjadi fokus utama untuk meningkatkan keandalan deteksi dalam kondisi yang menantang. Sistem saat ini sudah menggunakan *LiDAR* untuk pemetaan lingkungan dan deteksi halangan. Integrasi tambahan dengan kamera termal (infra-merah) akan memungkinkan kapal beroperasi secara efektif pada malam hari atau dalam kondisi cuaca buruk seperti kabut, di mana kamera visual memiliki keterbatasan[13].

Terakhir, kami berencana mengembangkan sistem keputusan adaptif yang didukung oleh data deteksi dari *YOLOv11*. Daripada hanya sekadar menghindari rintangan, sistem ini akan dapat menganalisis situasi kompleks dan membuat keputusan navigasi yang lebih cerdas, seperti memprioritaskan objek berbahaya, mengidentifikasi pola pergerakan, atau mengantisipasi ancaman[13]. Kombinasi dari semua pengembangan ini akan menciptakan ekosistem kapal otonom yang lebih cerdas, adaptif, dan siap untuk beroperasi pada skala operasional yang lebih luas di masa depan.

3. HASIL DAN PEMBAHASAN

Hasil penelitian ini berfokus pada analisis kinerja arsitektur *YOLOv11* 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 Performa Arsitektur *YOLOv11*

Arsitektur *YOLOv11* yang diimplementasikan pada *ASV "HERUKA"* menunjukkan performa yang sangat baik selama proses pelatihan dan validasi. Model dasar *YOLO11s.pt* dilatih selama 30 epochs dengan ukuran input 800x800 piksel menggunakan GPU Tesla T4. Hasil pelatihan menunjukkan konvergensi yang optimal, yang dapat diamati dari penurunan konsisten pada kurva loss dan peningkatan pada metrik performa. Analisis performa model terbaik (*best.pt*) pada tahap validasi menghasilkan metrik yang sangat menjanjikan untuk aplikasi real-time di lingkungan laut:

- a) Precision (Presisi): Rata-rata presisi mencapai 0.991. Angka ini menunjukkan kemampuan model dalam mengidentifikasi objek dengan tingkat akurasi yang sangat tinggi dan meminimalkan kesalahan deteksi positif (*False Positive*). Dengan kata lain, hampir semua objek yang terdeteksi oleh model adalah objek yang benar-benar ada di dalam gambar.

- b) Recall (Kelengkapan): Rata-rata recall sebesar 0.923. Angka ini membuktikan bahwa model mampu mendeteksi sebagian besar objek yang ada di dalam bingkai gambar (True Positive), sehingga hanya sedikit objek yang tidak terdeteksi (False Negative).
- c) mAP50: Model mencapai 0.99. Metrik ini sangat penting karena menunjukkan kemampuan model yang luar biasa dalam mendeteksi objek dengan akurat pada ambang batas Intersection over Union (IoU) sebesar 50%. Nilai yang mendekati 1 ini adalah indikasi kualitas deteksi yang sangat tinggi.
- d) mAP50-95: Model mencatat skor 0.712. Metrik ini memberikan penilaian yang lebih komprehensif karena mengukur performa model pada berbagai ambang batas IoU, dari 50% hingga 95%. Nilai yang tinggi ini menunjukkan bahwa model tetap andal bahkan dengan kriteria yang lebih ketat, membuktikan kemampuannya untuk menempatkan bounding box dengan presisi tinggi pada setiap objek yang dideteksi.

3.2 Analisis *Confusion Matrix* dan Validasi Visual

Analisis Matriks Kebingungan (*Confusion Matrix*) memberikan wawasan mendalam tentang kinerja model dalam mengklasifikasikan objek. Matriks menunjukkan bahwa dari 13 total instansi objek yang ada, model berhasil mendeteksi 12 di antaranya dengan benar. Hanya ada satu instansi yang diklasifikasikan sebagai *background* padahal seharusnya objek. Hal ini menegaskan akurasi tinggi dari model yang dilatih. Selain metrik kuantitatif, validasi visual juga dilakukan untuk mengonfirmasi performa model secara langsung pada citra. Model berhasil mendeteksi objek pelampung (*box_ijo*) pada berbagai kondisi pencahayaan dan sudut pandang dengan tingkat kepercayaan yang tinggi. Hal ini menunjukkan bahwa arsitektur *YOLOv11* efektif untuk deteksi objek dalam kondisi lingkungan nyata di perairan.

3.3 Kinerja Waktu Nyata (Real-Time)

Implementasi *YOLOv11* pada *mini PC Legion GO* di *ASV "HERUKA"* memungkinkan pemrosesan data visual secara real-time. Dengan arsitektur yang ringan namun efisien, *YOLOv11* mampu memberikan output deteksi objek (lokasi dan kelas) dengan cepat kepada sistem kendali navigasi melalui *middleware ROS2*. Kecepatan ini sangat penting untuk mendukung keputusan otomatis seperti penghindaran rintangan dan navigasi yang aman, menjadikan *ASV "HERUKA"* sebagai solusi efektif untuk misi patroli.

3.4 Analisis Perbandingan *YOLOv8* dan *YOLOv11*

Jika dibandingkan dengan hasil penelitian sebelumnya pada *YOLOv8*, terdapat beberapa poin penting:

- a) Akurasi: *YOLOv11* memiliki *mAP50-95* sebesar 0.701, sedangkan *YOLOv8* mencapai 0.705, menunjukkan perbaikan kecil namun konsisten.
- b) Kecepatan: *YOLOv8* lebih ringan karena menggunakan *anchor-free head* dan *C2f backbone*, sehingga cocok untuk deployment di perangkat edge seperti Jetson.
- c) Kompleksitas: *YOLOv11* lebih stabil untuk dataset besar, namun *YOLOv8* lebih mudah dilatih dan dioptimasi di Roboflow/Ultralytics pipeline.

3.5 Kelebihan dan Kekurangan *YOLOv11*

Kelebihan *YOLOv11*:

- 1) Akurasi lebih stabil pada dataset besar: *YOLOv11* memiliki kemampuan generalisasi yang lebih kuat dan cocok untuk aplikasi maritim skala luas karena dilatih dengan dataset yang besar.

- 2) Arsitektur lebih kompleks: Dengan *backbone* dan mekanisme *attention* yang lebih baik, model ini unggul dalam mendeteksi objek kecil dan objek di latar belakang yang kompleks.
- 3) Performa tinggi pada server GPU: Saat dijalankan di perangkat dengan sumber daya besar, model ini menunjukkan deteksi dan inferensi yang lebih konsisten dibandingkan *YOLOv8*.
- 4) Lebih kuat pada kondisi beragam: Dibandingkan dengan *YOLOv8*, *YOLOv11* lebih tahan terhadap variasi pencahayaan dan latar belakang, terutama jika dilatih dengan dataset yang kaya.

Kekurangan *YOLOv11*:

- 1) Lebih berat secara komputasi: *YOLOv11* membutuhkan daya komputasi yang lebih besar sehingga kurang efisien untuk perangkat *edge* seperti Jetson Nano atau Orin.
- 2) Inferensi lebih lambat: Kecepatan *frame* yang dihasilkan pada perangkat terbatas cenderung lebih rendah daripada *YOLOv8*, yang membuat pencapaian performa *real-time* dalam operasi maritim langsung menjadi lebih sulit.
- 3) Kompleksitas implementasi: *Hyperparameter tuning* pada *YOLOv11* lebih rumit dan memerlukan pengalaman lebih, menjadikannya kurang ramah untuk eksperimen cepat.
- 4) Kurang optimal untuk *deployment* ringan: Meskipun kuat di server, *YOLOv11* tidak secara khusus didesain untuk dioptimalkan pada perangkat dengan keterbatasan daya atau sumber daya, sehingga membuatnya kurang fleksibel dibandingkan *YOLOv8*.

4. KESIMPULAN DAN SARAN

Penelitian ini berhasil menunjukkan implementasi dan performa arsitektur *YOLOv11* pada *Autonomous Surface Vessel (ASV)* “*HERUKA*” untuk misi patroli, yang divalidasi dengan metrik kuantitatif dan visual yang kuat.

4.1 Kesimpulan

Penerapan teknologi *YOLOv11* pada *HERUKA Patrol Vessel* terbukti efektif sebagai solusi untuk menjaga keamanan dan kedaulatan maritim Indonesia. Kapal ini, yang dirancang dengan teknologi otonom, mampu beroperasi secara mandiri dan dilengkapi dengan kamera canggih untuk memantau kondisi perairan dan mendokumentasikan setiap kegiatan di laut. Berdasarkan analisis performa, model *YOLOv11* yang dilatih menunjukkan akurasi yang luar biasa untuk deteksi objek di permukaan air. Nilai Precision dan *mAP50* yang sangat tinggi, masing-masing mencapai 0.991 dan 0.99, menegaskan bahwa model mampu mengidentifikasi objek dengan tingkat akurasi yang sangat baik. Kinerja waktu nyata (*real-time*) yang didukung oleh arsitektur *YOLOv11* memungkinkan kapal untuk melakukan penghindaran halangan secara otomatis dan menjaga navigasi yang aman. Dengan demikian, hipotesis awal bahwa implementasi *YOLOv11* akan meningkatkan efektivitas deteksi objek pada *ASV* terbukti benar.

4.2 Saran

Meskipun model *YOLOv11* telah menunjukkan performa yang menjanjikan, terdapat beberapa area yang dapat dikembangkan lebih lanjut. Rangkaian percobaan tambahan diperlukan untuk menguji kecepatan dan stabilitas kapal dalam berbagai kondisi perairan, termasuk ombak dan cuaca buruk. Ke depannya, disarankan untuk meningkatkan fasilitas operasional dan interaksi virtual yang lebih mendalam pada kapal. Peningkatan ini dapat mencakup integrasi multi-sensor, seperti kamera termal, untuk kemampuan operasional malam hari atau kondisi visibilitas rendah. Selain itu, pengembangan sistem pengambilan keputusan yang lebih adaptif, berdasarkan data *real-time* dari *YOLOv11*, akan mendorong kemajuan dalam dunia maritim dan keamanan laut.

5. DAFTAR RUJUKAN

- [1] Virgiawan, I., Maulana, F., Putra, M. A., Kurnia, D. D., & Sinduningrum, E. (2024). *Deteksi dan tracking objek secara real-time berbasis computer vision menggunakan metode YOLO V3*. *Humantech : Jurnal Ilmiah Multidisiplin Indonesia*, 3(3), xxx-xxx.
- [2] Winarno, R. A. D. M. P., Hidayana, E., Nugraha, A. T., & Sunarno, E. (2024). *Object Detection of Track Using YOLO Method in Fast Unmanned Vessel Application*. *Jurnal Teknologi Maritim*, 7(1). <https://doi.org/10.35991/jtm.v7i1.10>
- [3] Chen, X., Yang, R., Wu, Y., Zhang, H., Ranjitkar, P., Postolache, O., Zheng, Y., & Wang, Z. (2025). *Towards intelligent shipping: image-enhanced ship detection and situation analysis in low-light scenes*. *Intell. Robot*, 5(3), 662-78.
- [4] Leksono, A. W., & Syahrurini, S. (2018). *Rancang bangun model autonomous unmanned surface vehicle sebagai wahana patroli perairan*. *SinarFe7*, 7(1), 357-360.
- [5] Rinanto, N., Audryadmaja, A. E. G., Putra, Z. M. A., Khumaidi, A., Adhitya, R. Y., Syaiin, M., & Rachman, I. (2024). *Implementation of Robot Operating System on Autonomous Surface Vehicle for Trajectory Localization with You Only Look Once Method*. *Jurnal Teknik Elektro dan Komputer TRIAC*, 11(2), 2024.
- [6] Hendriko, V., & Hermanto, D. (2025). *Performance Comparison of YOLOv10, YOLOv11, and YOLOv12 Models on Human Detection Datasets*. *Brilliance: Research of Artificial Intelligence*, 5(1), 440.
- [7] Elgendy, A. (2025). *Using computer vision for underwater detection*. [Online]. Tersedia di: <https://www.ultralitics.com/blog/using-computer-vision-for-underwater-detection>. [Diakses 4 September 2025].
- [8] Kurniawan, D., 2025. *Perancangan Sistem Object Detection pada Industri Alat Berat Menggunakan Deep Learning*. Tugas Akhir. Balikpapan: Institut Teknologi Kalimantan.
- [9] He, L., Zhou, Y., Liu, L., & Ma, J. (2024). *Research and Application of YOLOv11-Based Object Segmentation in Intelligent Recognition at Construction Sites*. *Buildings*, 14(12), 3777. doi: <https://doi.org/10.3390/buildings14123777>
- [10] Huda, M. N. M., Setiawan, Y., & Rahmanti, F. Z. (2022). *Deteksi Kerusakan Badan Kontainer di Gate-In PT Berlian Jasa Terminal Indonesia Menggunakan YOLOv11*. *Jurnal Ilmiah Teknologi Infokom*, 3(2), 32-37.
- [11] Triyani, Supriyadi, A. A., Yulianto, B. A., Yudho, L., & Suwarno, P. (2025). *Pengembangan Model Deteksi Ancaman Maritim Berbasis AI: Kerangka Keamanan Prediktif untuk Penangkapan Ikan Ilegal dan Pembajakan di Laut Natuna*. *Jurnal Locus: Penelitian & Pengabdian*, 4(7), 4605-4622.
- [12] Ramadhani, L. K., & Widyaningrum, B. N. (2025). *Implementation of YOLO v11 for Image-Based Litter Detection and Classification in Environmental Management Efforts*. *Journal of Applied Informatics and Computing (JAIC)*, 9(3), 617-624.
- [13] BRIN. (2023). *Deteksi Objek Berbasis LiDAR untuk Sistem Keselamatan Kendaraan Listrik Otonom*. [Online]. Tersedia di: <https://www.brin.go.id/news/111882/deteksi-objek-berbasis-LiDAR-untuk-sistem-keselamatan-kendaraan-listrik-otonom>. [Diakses 4 September 2025].
- [14] Vanszs. (2025). *How to Train YOLO11 Object Detection on a Custom Dataset*. [Online]. Tersedia di: <https://github.com/Vanszs/Vanszs.github.io/blob/main/notebooks/train-YOLO11-object-detection-on-custom-dataset.ipynb>. [Diakses 4 September 2025].