

DETEKSI KERUSAKAN PERMUKAAN LAMBUNG KAPAL BERBASIS CITRA MENGGUNAKAN YOLOV8, FASTER R-CNN, DAN SSD

Choirul Mufit¹, Lilik Khoiriyah², Firly Irhamni Ahsan³, Aslikha Amalia⁴, Nakeyzatria Candra Suryana⁵, M Rizqi Mubarak⁶, Yulia Ayu Nastiti⁷, Vena Rizqi Pusparani⁸

^{1,4,5)},Jurusan Teknik Kelistrikan Kapal,Politeknik Perkapalan Negeri Surabaya, Surabaya, Indonesia

^{2,3,7)},Jurusan Teknik Bangunan Kapal,Politeknik Perkapalan Negeri Surabaya, Surabaya, Indonesia

^{6,8)},Jurusan Teknik Permesinan Kapal,Politeknik Perkapalan Negeri Surabaya, Surabaya, Indonesia

Email: choirul.mufit@ppns.ac.id, lilikkhoiriyah@ppns.ac.id, firlyahsan@ppns.ac.id, aslikhaamalia@ppns.ac.id, nakeyzatria.candra@student.ppns.ac.id, mmubarak@ppns.ac.id, yuliaayu@ppns.ac.id, venarizky@ppns.ac.id


Info Artikel

Histori Artikel:

Diterima Feb xx, 20xx

Direvisi Mar xx, 20xx


Disetujui Mar xx, 20xx



ABSTRACT

Corrosion on ship hull surfaces poses a critical challenge in the maritime industry, directly affecting structural safety, fuel efficiency, and maintenance costs. Conventional manual visual inspection at drydocks is time-consuming, expensive, and poses potential safety hazards to inspectors. This study aims to develop an image-based ship hull corrosion detection system and objectively compare the performance of three deep learning architectures, YOLOv8, Faster R-CNN, and SSD300, under identical experimental conditions. The dataset combines the Marine Vessel Corrosion Dry-Dock Dataset (MaVeCoDD) with self-collected hull images, yielding a total of 76 images. Data were split consistently into training, validation, and testing subsets. Each model was trained via transfer learning from COCO pretrained weights and evaluated using mAP50, Precision, Recall, and F1-Score on the identical test set. Experimental results demonstrate that YOLOv8n outperforms the other architectures, achieving an mAP50 of 0.131, Precision of 0.313, Recall of 0.226, and F1-Score of 0.263. Faster R-CNN attained the highest Precision (0.651) but suffered from a low Recall (0.088), whereas SSD300 yielded the lowest performance with an mAP50 of 0.003. In conclusion, YOLOv8 proves to be the most suitable architecture for ship hull corrosion detection due to its superior balance between Precision and Recall compared to Faster R-CNN and SSD300.

Keywords: Keywords: Corrosion Detection, Ship Hull, YOLOv8, Faster R-CNN, SSD300, Computer Vision.



ABSTRAK

Korosi pada permukaan lambung kapal merupakan permasalahan krusial dalam industri pelayaran yang berdampak langsung pada keselamatan struktural, efisiensi bahan bakar, dan pembengkakan biaya pemeliharaan. Inspeksi visual secara manual di drydock terbukti memakan waktu lama, berbiaya tinggi, serta memiliki risiko keselamatan bagi inspektur. Penelitian ini bertujuan mengembangkan sistem deteksi korosi lambung kapal berbasis citra dan membandingkan performa tiga arsitektur deep learning, YOLOv8, Faster R-CNN, dan SSD300, secara objektif di bawah kondisi eksperimen yang identik. Dataset yang digunakan merupakan gabungan dari Marine Vessel Corrosion Dry-Dock Dataset (MaVeCoDD) dan pengumpulan data mandiri, yang menghasilkan total 76 citra lambung kapal. Data dibagi secara konsisten ke dalam subset pelatihan, validasi, dan pengujian. Setiap model dilatih menggunakan teknik transfer learning dari bobot awal COCO, lalu dievaluasi berdasarkan metrik mAP50, Precision, Recall, dan F1-Score. Hasil eksperimen menunjukkan bahwa YOLOv8n menghasilkan performa terbaik secara keseluruhan dengan nilai mAP50 sebesar 0,131, Precision 0,313, Recall 0,226, dan F1-Score 0,263. Faster R-CNN mencatatkan Precision tertinggi (0,651) namun diiringi nilai Recall yang sangat rendah (0,088), sedangkan SSD300 menunjukkan kinerja terendah dengan mAP50 hanya 0,003. Dapat disimpulkan bahwa YOLOv8 merupakan arsitektur yang paling efektif untuk deteksi korosi lambung kapal karena menawarkan keseimbangan Precision-Recall yang lebih baik dibandingkan Faster R-CNN dan SSD300.

Kata Kunci: Deteksi Korosi, Lambung Kapal, YOLOv8, Faster R-CNN, SSD300, Computer Vision.

Korespondensi:

Choirul Mufit,

D4 Teknik Kelistrikan Kapal, Jurusan Teknik Kelistrikan Kapal,

Politeknik Perkapalan Negeri Surabaya,

Surabaya.

Email: choirul.mufit@ppns.ac.id



1. PENDAHULUAN

Kapal merupakan tulang punggung perdagangan internasional yang mengangkut lebih dari 80% volume perdagangan dunia [1]. Dalam pemeliharaan armada kapal, korosi pada permukaan lambung menjadi salah satu masalah paling krusial akibat paparan air laut, kelembapan atmosfer, dan reaksi elektrokimia yang terjadi terus-menerus selama kapal beroperasi [2]. Jika tidak terdeteksi sejak awal, korosi dapat memicu kerusakan struktural yang mengancam keselamatan pelayaran, memperbesar hambatan hidrodinamis yang berujung pada pemborosan bahan bakar, hingga membengkaknya biaya perbaikan jika dibandingkan dengan tindakan pencegahan [3].

Sejauh ini, inspeksi korosi lambung kapal masih mengandalkan cara konvensional, yaitu pemeriksaan visual oleh inspektur terlatih saat kapal menjalani proses drydock. Masalahnya, lambung kapal berukuran besar memiliki luas permukaan hingga ribuan meter persegi. Inspeksi manual seperti ini membutuhkan waktu lama, menelan biaya tinggi, dan hasilnya sangat bergantung pada sudut pandang serta pengalaman masing-masing inspektur. Di samping risiko keselamatan kerja saat inspektur harus menjangkau area-area tinggi atau sulit, dokumentasi perkembangan korosi secara berkala juga sulit dilakukan secara konsisten [4].

Penerapan kecerdasan buatan (Artificial Intelligence) berbasis *computer vision* menghadirkan solusi untuk mengotomatisasi proses inspeksi tersebut. Penelitian Yao et al.[4] menunjukkan bahwa model CNN berbasis AlexNet mampu mendeteksi korosi pada pelat lambung kapal hingga akurasi 98,9% menggunakan 330 citra resolusi tinggi. Sementara itu, Mursida et al.[5] membandingkan YOLOv8 dan Detectron2 untuk pemantauan korosi lambung kapal dan menyimpulkan bahwa augmentasi data berperan penting dalam meningkatkan ketangguhan model. Penelitian ini sendiri memanfaatkan dataset MaVeCoDD yang diperkenalkan oleh Kamzelis et al.[6] sebagai salah satu acuan utama untuk kasus inspeksi korosi di drydock. Selain itu, penggunaan deep learning untuk segmentasi korosi dan penilaian kondisi struktur baja dieksplorasi oleh Ameli et al.[7] menggunakan Mask R-CNN dan YOLOv8, sedangkan Chliveros et al.[8] mengembangkan metode klasifikasi korosi berbasis deep learning menggunakan modul *Eigen tree hierarchy* yang dikombinasikan dengan YOLOv8. Di sisi lain, literatur saat ini banyak menyoroti tiga arsitektur deteksi objek berbasis deep learning: YOLOv8 [9], Faster R-CNN [10], dan SSD[11]. YOLOv8 yang dikembangkan oleh Ultralytics

mengusung pendekatan anchor-free, backbone CSPDarknet yang ditingkatkan, head deteksi decoupled, serta ekosistem augmentasi yang kaya seperti mosaic, mixup, dan copy-paste[7]. Terven et al.[12] memberikan tinjauan komprehensif tentang perkembangan arsitektur YOLO dari YOLOv1 hingga YOLOv8. Selanjutnya, Faster R-CNN yang diusulkan oleh Ren et al.[10] merupakan arsitektur two-stage yang mengintegrasikan Region Proposal Network (RPN) dengan backbone ResNet50 dan Feature Pyramid Network (FPN)[13] untuk menghasilkan presisi lokalisasi tinggi. Sementara itu, SSD (Single Shot Detector) yang diusulkan Liu et al.[11] mengeksekusi deteksi langsung dari feature map multi-skala. Meskipun SSD dan YOLO dikenal memiliki keunggulan kecepatan dibanding Faster R-CNN sebagaimana dipelajari oleh Kim et al.[14], Zou et al.[15] dalam surveinya mencatat bahwa SSD secara konsisten menunjukkan keterbatasan dalam mendeteksi objek berukuran sangat kecil dibanding arsitektur berfitur piramida. Meski ketiga arsitektur tersebut populer, pengujian komparatif yang menyandingkan YOLOv8 [9], Faster R-CNN [10], dan SSD300 [11] secara langsung pada kasus korosi lambung kapal, dengan dataset dan protokol evaluasi yang benar-benar sama, masih sangat terbatas. Celah inilah yang menjadi latar belakang pengujian dalam penelitian ini. Berangkat dari masalah tersebut, penelitian ini menyumbang dua kontribusi utama. Pertama, mengembangkan sistem deteksi korosi lambung kapal berbasis citra dengan menggabungkan dataset publik MaVeCoDD [6] dan data lapangan yang dikumpulkan secara mandiri. Kedua, menyajikan evaluasi komparatif antara YOLOv8, Faster R-CNN, dan SSD300 dalam kondisi eksperimen yang identik, sehingga perbedaan hasil akhir murni mencerminkan kemampuan masing-masing arsitektur.

2. METODE PENELITIAN

2.1. Dataset

Dataset yang digunakan dalam penelitian ini merupakan gabungan dari dua sumber. Sumber pertama adalah Marine Vessel Corrosion Dry-Dock Dataset (MaVeCoDD) [6] yang dikembangkan oleh Kamzelis et al. dalam kerangka proyek WatchOver. Dataset publik berlisensi Creative Commons CC BY 4.0 ini menyediakan 63 pasang citra lambung kapal beresolusi tinggi yang dilengkapi mask segmentasi piksel untuk menandai area korosi secara presisi. Sumber kedua berasal dari dokumentasi lapangan yang dikumpulkan secara mandiri oleh tim peneliti. Dari penggabungan kedua sumber tersebut, diperoleh total 76 citra lambung

kapal. Seluruh data citra mencakup variasi kondisi permukaan lambung yang cukup kompleks, mulai dari tingkat keparahan korosi ringan hingga berat, keberagaman tekstur cat, kondisi pencahayaan yang tidak seragam, hingga sudut pengambilan gambar yang bervariasi. Keberagaman ini disengaja agar model yang dilatih memiliki daya generalisasi yang baik saat diuji pada kondisi inspeksi riil di lapangan.

2.2. Prapemrosesan DataSet

Mask segmentasi berwarna terlebih dahulu dikonversi ke format *bounding box* standar YOLO memanfaatkan algoritma deteksi kontur pada pustaka OpenCV. Kontur area korosi diekstraksi dari *mask grayscale* menggunakan fungsi *findContours*, lalu diaproksimasi menjadi poligon melalui algoritma *approxPolyDP*. Selanjutnya, koordinat minimum dan maksimum dari poligon tersebut diambil untuk menentukan *bounding box*. Format label akhir yang dihasilkan mengikuti konvensi YOLO: *class_id*, *x_center*, *y_center*, *width*, dan *height* yang seluruhnya telah dinormalisasi ke rentang 0–1 terhadap dimensi gambar.

Dataset kemudian dibagi menjadi tiga *subset* dengan rasio 75:15:10 (*train*: 58 gambar, *validation*: 11 gambar, *test*: 7 gambar) menggunakan *random seed* yang diseragamkan untuk ketiga model. Pada *test set*, terdapat total 784 objek korosi. Pembagian data secara identik ini menjadi syarat krusial untuk menjamin *fair comparison* antar-arsitektur, sehingga perbedaan performa di akhir eksperimen murni dipengaruhi oleh karakteristik model, bukan akibat ketimpangan distribusi data.

2.3. Implementasi Model

Ketiga model diimplementasikan menggunakan transfer learning dari bobot pretrained COCO. Konfigurasi training masing-masing model adalah sebagai berikut:

- YOLOv8n-Detection (Ultralytics 8.x, 3,0 juta parameter) dilatih selama 150 epoch dengan *imgsz* 960, *batch* 8, dan optimizer AdamW (learning rate 0,002, momentum 0,9). Early stopping diterapkan dengan *patience* 30 epoch.

Augmentasi mencakup rotasi $\pm 15^\circ$, flip horizontal dan vertikal 50%, mosaic, mixup 10%, dan copy-paste 10%.

- Faster R-CNN ResNet50-FPN (torchvision, ~41 juta parameter) dilatih selama 50 epoch dengan *batch* 4, optimizer SGD ($\text{lr}=0,005$, $\text{momentum}=0,9$, $\text{weight decay}=5 \times 10^{-4}$), dan StepLR scheduler ($\text{step}=15$, $\text{gamma}=0,5$). Early stopping dengan *patience* 15 epoch. Augmentasi: flip horizontal 50%.
- SSD300 VGG16 (torchvision, ~26 juta parameter) dilatih selama 50 epoch dengan *batch* 4, optimizer Adam ($\text{lr}=10^{-4}$, $\text{weight decay}=5 \times 10^{-4}$), dan Cosine Annealing scheduler. Early stopping dengan *patience* 15 epoch. Augmentasi: flip horizontal 50% dan color jitter (brightness, contrast, saturation $\pm 30\%$).

Seluruh eksperimen dilaksanakan pada GPU NVIDIA Tesla T4 (14 GB VRAM) menggunakan Google Colaboratory. PyTorch DataLoader kustom dikembangkan untuk Faster R-CNN dan SSD guna membaca format label YOLO secara langsung, memastikan konsistensi format data yang diterima ketiga model.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Penelitian

3.1.1. Evaluasi Kuantitatif Performa Model

Hasil evaluasi ketiga arsitektur deteksi objek pada *test set*, yang terdiri dari 76 citra dengan total 784 objek korosi, disajikan pada Tabel 1. Seluruh pengujian ini dilakukan menggunakan bobot model terbaik (*best.pt*) yang tersimpan berdasarkan performa puncak pada data validasi selama proses pelatihan. Berdasarkan Tabel 1, YOLOv8n-Detection secara konsisten mengungguli kedua model lainnya pada metrik mAP50 (0,131), mAP50-95 (0,046), *Recall* (0,226), dan F1-Score (0,263). *Faster R-CNN* memiliki *Precision* tertinggi (0,651) namun nilai *Recall* yang jauh lebih rendah (0,088). SSD300 menunjukkan nilai mAP50 terendah (0,003) meskipun *Precision*-nya tertinggi (0,750).

Tabel 1 Hasil Evaluasi Ketiga Model pada Test Set

Model	mAP50	mAP50-95	Precision	Recall	F1
YOLOv8n-Detection	0,131	0,046	0,313	0,226	0,263
Faster R-CNN	0,057	-	0,651	0,088	0,155
SSD300	0,003	-	0,750	0,004	0,008

3.1.2. Hasil `Evaluasi Kualitatif dan Visualisasi Deteksi

Gambar 1 menampilkan hasil deteksi ketiga model pada tiga citra uji yang berbeda (HiRes_hull007, HiRes_hull017, dan HiRes_hull024) untuk memvisualisasikan perbedaan karakteristik deteksi antar arsitektur secara langsung. Pada citra HiRes_hull007 yang memiliki area korosi paling luas dan bervariasi, YOLOv8n berhasil mengidentifikasi 74 area korosi dengan distribusi deteksi yang tersebar merata, mencakup bercak-bercak kecil di bagian atas lambung maupun area korosi parah di bagian bawah yang terendam air. *Faster R-CNN* menghasilkan 64 deteksi dengan kecenderungan menghasilkan *bounding box* yang lebih besar dan berfokus pada area korosi yang luas, melewati sebagian bercak korosi kecil yang berhasil ditangkap YOLOv8. SSD300 mendeteksi 68 area dengan karakteristik *bounding box* yang lebih longgar dan tersebar, namun dengan *confidence score* yang lebih rendah sehingga posisi dan ukuran *bounding box* kurang presisi dibanding dua model lainnya.

Pada citra HiRes_hull017, YOLOv8n menghasilkan 44 deteksi dengan *bounding box* yang relatif ketat mengikuti kontur area korosi. *Faster R-CNN* menghasilkan 54 deteksi namun dengan *bounding box* yang cenderung lebih besar dan kurang presisi pada area dengan korosi ringan. SSD300 menghasilkan 43 deteksi dengan pola deteksi yang lebih tersebar dan kurang konsisten dibanding dua model lainnya. Secara keseluruhan, analisis visual mengkonfirmasi beberapa temuan kuantitatif yang telah dipaparkan sebelumnya. YOLOv8 secara konsisten menghasilkan *bounding box* yang lebih ketat dan lebih representatif terhadap bentuk area korosi sebenarnya. *Faster R-CNN* cenderung menghasilkan *bounding box* yang lebih besar (overestimate) pada area korosi yang tersebar, namun lebih akurat pada area korosi yang jelas dan kontras tinggi.

SSD300 menunjukkan pola deteksi yang paling tidak konsisten dengan *bounding box* yang seringkali tidak proporsional terhadap ukuran area korosi sebenarnya. Perbedaan visual ini konsisten dengan nilai F1-Score yang diperoleh: YOLOv8n (0,263), *Faster R-CNN* (0,155), dan SSD300 (0,008), di mana keseimbangan *Precision-Recall* YOLOv8 yang lebih baik tercermin dari kualitas deteksi yang lebih merata pada berbagai ukuran dan tingkat keparahan korosi. Hasil eksperimen ini memperkuat temuan Zou et al. [15] yang menyebutkan bahwa penggunaan anchor berskala tunggal pada SSD sering kali menjadi *bottleneck* utama dalam mendeteksi objek berskala

mikroskopis atau sangat kecil. Rendahnya rentang nilai mAP50 secara keseluruhan (0,003 hingga 0,131) menggambarkan betapa kompleksnya tantangan deteksi korosi pada lambung kapal. Bercak korosi memiliki sebaran skala yang sangat lebar, mulai dari titik-titik kecil berdiameter beberapa milimeter hingga cakupan area korosi seluas beberapa meter persegi. Dalam satu lembar foto lambung kapal saja, dapat terdapat ratusan instance korosi dengan geometri dan pencahayaan yang saling bertolak belakang. Karakteristik visual yang sangat rapat dan heterogen ini secara inheren jauh lebih sulit ditangani dibanding dataset acuan umum seperti COCO, yang umumnya didominasi objek berukuran lebih besar dengan jumlah objek per citra yang jauh lebih sedikit.

3.2. Pembahasan Hasil Penelitian

3.2.1. Analisis Perbandingan Karakteristik Arsitektur

Keunggulan YOLOv8 dalam penelitian ini dapat dijelaskan melalui beberapa faktor teknis. Dari sisi arsitektur, pendekatan *anchor-free* pada YOLOv8 memberikan fleksibilitas yang lebih baik dalam menangani variasi ukuran dan bentuk objek yang tidak menentu, sebuah karakteristik yang cocok dengan bentuk bercak korosi di lapangan yang cenderung acak. Selain itu, ekosistem pelatihan *Ultralytics* menyediakan skema augmentasi data yang lebih bervariasi ketimbang implementasi standar *torchvision* pada *Faster R-CNN* dan SSD.


Teknik seperti *mosaic*, *mixup*, dan *copy-paste* terbukti efektif memperkaya variasi data sehingga meningkatkan daya generalisasi model [9]. Dari aspek skala model, YOLOv8n yang hanya berukuran 3,0 juta parameter terhitung jauh lebih ringkas dibanding *Faster R-CNN* (41 juta parameter) maupun SSD (26 juta parameter), sehingga risikonya terhadap *overfitting* relatif lebih kecil saat dilatih pada jumlah data terbatas.

Di sisi lain, pola *Precision* tinggi yang diiringi *Recall* sangat rendah pada *Faster R-CNN* ($P = 0,651$; $R = 0,088$) memperlihatkan sifat khas model *two-stage* yang terlampaui selektif dalam mengeluarkan prediksi. Komponen Region Proposal Network (RPN) pada *Faster R-CNN* cenderung menyaring kandidat proposal yang berfokus pada objek berukuran sedang hingga besar dengan kontur seragam. Akibatnya, bercak-bercak korosi berukuran kecil atau yang memiliki kontras rendah terhadap warna latar lambung kapal gagal teridentifikasi sebagai *Region of Interest* (RoI). Temuan serupa juga dilaporkan oleh Kim et al. [14], di mana *Faster R-CNN* mampu mencatatkan

Precision yang unggul dibanding keluarga YOLO, namun tertinggal dalam kecepatan dan sensitivitas deteksi objek berukuran kecil.

Sementara itu, SSD300 mencatatkan performa paling rendah dalam pengujian ini, dengan mAP50 hanya 0,003 dan Recall sebesar 0,004, meski *Precision*-nya menyentuh angka 0,750. Angka-angka ini mengindikasikan bahwa model hampir tidak memunculkan prediksi di sepanjang

pengujian, dan dari sedikit prediksi yang berhasil keluar, mayoritas di antaranya memang tepat (*Precision* tinggi). Hasil ini sejalan dengan keterbatasan mendasar SSD yang banyak diulas dalam literatur, yaitu lemahnya kemampuan deteksi objek berukuran sangat kecil akibat resolusi *feature map* pada lapisan-lapisan awal yang kurang memadai untuk menangkap detail spasial bercak korosi [15].



Gambar 1. Perbandingan hasil deteksi korosi lambung kapal pada citra uji HiRes_hull007 (atas), HiRes_hull017 (tengah), dan HiRes_hull024 (bawah). Kolom kiri: YOLOv8n (biru), kolom tengah: Faster R-CNN (hijau), kolom kanan: SSD300 (merah muda). Angka dalam kurung menunjukkan jumlah area korosi yang terdeteksi pada masing-masing model.

3.2.2. Kecepatan Inferensi dan Implikasi Praktis

Selain akurasi, kecepatan inferensi merupakan faktor penting yang perlu dipertimbangkan dalam pemilihan model untuk aplikasi inspeksi lapangan. Berdasarkan pengukuran pada GPU NVIDIA Tesla T4, YOLOv8n menghasilkan kecepatan inferensi rata-rata 18,8ms per gambar, menjadikannya kandidat yang paling layak untuk aplikasi inspeksi *real-time* maupun *semi-real-time*. Faster R-CNN memerlukan waktu inferensi yang lebih panjang, yakni sekitar 45–60ms per gambar, akibat tahap region proposal yang dilakukan secara eksplisit oleh RPN. SSD300 berada di antara keduanya dengan waktu inferensi sekitar 25–35ms. Dari dimensi

kecepatan, YOLOv8n dan SSD300 lebih unggul dibanding Faster R-CNN, konsisten dengan temuan Kim et al. [14] dan survei komprehensif Zou et al. [15]. Apabila ketiga dimensi evaluasi, akurasi (mAP50), keseimbangan *Precision-Recall* (F1-Score), dan kecepatan inferensi, dipertimbangkan secara bersamaan, YOLOv8n secara konsisten mengungguli dua model lainnya.

Dalam konteks inspeksi korosi lambung kapal, nilai Recall yang memadai memiliki bobot kepentingan yang lebih tinggi dibanding *Precision* semata. Dari perspektif keselamatan pelayaran, konsekuensi dari *false negative*, yakni area korosi yang sebenarnya ada namun tidak terdeteksi oleh sistem, jauh lebih

berbahaya dibanding *false positive*, karena korosi yang tidak teridentifikasi dapat berkembang menjadi kerusakan struktural yang mengancam keselamatan. Sebaliknya, *false positive* hanya membutuhkan verifikasi ulang oleh inspektor manusia yang relatif murah secara biaya dan waktu. Dari perspektif ini, YOLOv8n dengan Recall 0,226 dan F1-Score 0,263 jauh lebih sesuai untuk aplikasi inspeksi lambung kapal dibanding Faster R-CNN (Recall 0,088, F1 0,155) maupun SSD300 (Recall 0,004, F1 0,008). Pertimbangan tambahan yang relevan untuk implementasi lapangan adalah ukuran model. YOLOv8n dengan hanya 3 juta parameter dapat berjalan pada perangkat komputasi yang lebih terjangkau dibanding Faster R-CNN yang memiliki 41 juta parameter, membuka kemungkinan *deployment* pada sistem robotik inspeksi otonom atau perangkat *embedded* yang memiliki keterbatasan daya komputasi. Hal ini menjadikan YOLOv8n tidak hanya unggul secara performa, tetapi juga lebih praktis secara teknis dan ekonomis untuk implementasi nyata dalam sistem inspeksi korosi lambung kapal.

4. KESIMPULAN

Penelitian ini telah berhasil mengembangkan sistem deteksi korosi lambung kapal berbasis citra serta menyajikan perbandingan komparatif secara komprehensif antara arsitektur YOLOv8, Faster R-CNN, dan SSD300 pada kondisi eksperimen yang seragam. Dari hasil pengujian, YOLOv8n-Detection terbukti memberikan performa terbaik secara keseluruhan dengan nilai mAP50 sebesar 0,131, *Precision* 0,313, Recall 0,226, dan F1-Score 0,263. Keunggulan ini utamanya ditopang oleh skema arsitektur anchor-free serta dukungan augmentasi data yang kaya, yang memungkinkan model memiliki daya generalisasi lebih baik dalam menangani bentuk bercak korosi yang tidak beraturan. Sebaliknya, Faster R-CNN mencatatkan *Precision* tertinggi (0,651) tetapi diiringi Recall yang sangat rendah (0,088) akibat sifat RPN yang terlalu selektif dalam mengusulkan region proposal, sehingga kurang cocok untuk aplikasi inspeksi yang menuntut kelengkapan deteksi. Sementara itu, SSD300 menunjukkan kinerja paling rendah dengan mAP50 hanya 0,003, yang menegaskan keterbatasan mendasar arsitektur single-scale anchor dalam merespons objek-objek berukuran sangat kecil pada citra lambung kapal.

Berdasarkan temuan tersebut, penelitian ini merekomendasikan penggunaan arsitektur berbasis YOLOv8 sebagai prioritas utama dalam pengembangan sistem deteksi korosi lambung kapal secara otomatis. Untuk pengembangan ke depan,

studi lanjutan dapat diarahkan pada beberapa aspek krusial. Pertama, memperluas dan mendiversifikasi dataset dengan mencakup berbagai variasi jenis kapal, kondisi pencahayaan lingkungan, dan tingkat kerusakan korosi yang lebih kompleks. Kedua, menguji varian arsitektur dengan skala parameter lebih besar, seperti YOLOv8s atau YOLOv8m, guna meningkatkan kapasitas ekstraksi fitur model. Terakhir, mengintegrasikan *pipeline* inferensi model ini dengan platform sistem robotik atau drone untuk mewujudkan proses inspeksi lambung kapal secara mandiri di lapangan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Politeknik Perkapalan Negeri Surabaya (PPNS) atas dukungan finansial yang diberikan dalam penelitian ini melalui skema pendanaan DIPA PPNS Tahun Anggaran 2026. Terima kasih juga disampaikan kepada seluruh pihak yang telah membantu pelaksanaan penelitian ini hingga selesai.

DAFTAR PUSTAKA

- [1] U. N. C. Trade and Development, "Review of Maritime Transport 2023," 2023 2023. [Online]. Available: <https://unctad.org/publication/review-maritime-transport-2023>.
- [2] R. E. Melchers and R. Jeffrey, "Probabilistic Models for Steel Corrosion Loss and Pitting of Marine Infrastructure," *Reliab. Eng. Syst. Saf.*, vol. 93, no. 3, pp. 423–432, 2008/3 2008, doi: <http://dx.doi.org/10.1016/j.ress.2006.12.006>.
- [3] F. Bonnin-Pascual and A. Ortiz, "On the Use of Robots and Vision Technologies for the Inspection of Vessels: A Survey on Recent Advances," *Ocean Engineering*, vol. 190, p. 106420, 2019/10 2019, doi: <http://dx.doi.org/10.1016/j.oceaneng.2019.106420>.
- [4] Y. Yao, Y. Yang, Y. Wang, and X. Zhao, "Artificial Intelligence-Based Hull Structural Plate Corrosion Damage Detection and Recognition Using Convolutional Neural Network," *Applied Ocean Research*, vol. 90, p. 101823, 2019/9 2019, doi: <http://dx.doi.org/10.1016/j.apor.2019.05.008>.
- [5] O. Mursida, S. Adam, A. R. Prabowo, and H. Nubli, "Artificial Intelligence-Based Ship Hull Plate Corrosion Monitoring Using Convolutional Neural Network (CNN): Comparison of YOLOv8 and Detectron2 Architecture Models," *Ship Technology Research*, vol. 72, no. 2, pp. 88–98, 2024 2024, doi: <http://dx.doi.org/10.1080/09377255.2024.2397608>.
- [6] K. Kamzelis, G. Chliveros, and I. Tzanetatos, "MaVeCoDD: Marine Vessel Corrosion Dry-Dock Images Dataset," 2021 2021, doi: <http://dx.doi.org/10.17632/ry392rp8cj.1>.
- [7] Z. Ameli, S. J. Nesheli, and E. N. Landis, "Deep Learning-Based Steel Bridge Corrosion Segmentation and Condition Rating Using Mask R-

- CNN and YOLOv8," *Infrastructures (Basel)*, vol. 9, no. 1, p. 3, 2024/1 2024, doi: <http://dx.doi.org/10.3390/infrastructures9010003>.
- [8] G. Chliveros, "A Deep Learning Image Corrosion Classification Method for Marine Vessels Using an Eigen Tree Hierarchy Module," *Coatings*, vol. 14, no. 6, p. 768, 2024/6 2024, doi:<http://dx.doi.org/10.3390/coatings14060768>.
- [9] G. Jocher, A. Chaurasia, and J. Qiu, "Ultralytics YOLOv8," 2023 2023. [Online]. Available: <https://github.com/ultralytics/ultralytics>.
- [10] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *Adv. Neural Inf. Process. Syst.*, vol. 28, pp. 91–99, 2015 2015.
- [11] W. Liu, "SSD: Single Shot MultiBox Detector," presented at the Proceedings of the European Conference on Computer Vision (ECCV, 2016, 2016. [Online]. Available: http://dx.doi.org/10.1007/978-3-319-46448-0_2.
- [12] J. Terven, D. M. Córdova-Esparza, and J. A. Romero-González, "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS," *Mach. Learn. Knowl. Extr.*, vol. 5, no. 4, pp. 1680–1716, 2023 2023, doi: <http://dx.doi.org/10.3390/make5040083>.
- [13] T. Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature Pyramid Networks for Object Detection," presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR, 2017, 2017. [Online]. Available: <http://dx.doi.org/10.1109/CVPR.2017.106>.
- [14] J. A. Kim, J. Y. Sung, and S. H. Park, "Comparison of Faster-RCNN, YOLO, and SSD for Real-Time Vehicle Type Recognition," presented at the Proceedings of the IEEE International Conference on Consumer Electronics-Asia (ICCE-Asia), Seoul, 2020, 2020. [Online]. Available: <http://dx.doi.org/10.1109/ICCE-Asia49877.2020.9277040>.
- [15] Z. Zou, K. Chen, Z. Shi, Y. Guo, and J. Ye, "Object Detection in 20 Years: A Survey," *Proceedings of the IEEE*, vol. 111, no. 3, pp. 257–276, 2023/3 2023, doi: <http://dx.doi.org/10.1109/JPROC.2023.3238524>.