

ANALISIS DAN OPTIMASI PERFORMA MODEL YOLOV8 DALAM MENDETEKSI DAN MENGHITUNG POPULASI IKAN DI DALAM AIR

M. Ikbal Siami^{*1}, Lukman Saleh²

¹Program Studi Teknik Informatika, Institut Teknologi dan Bisnis Stikom Ambon, Indonesia,

²Program Studi Teknik Informatika, Institut Teknologi dan Bisnis Stikom Ambon, Indonesia

Penulis korespondensi: M. Ikbal Siami (siami25@gmail.com)

Abstrak—Pemantauan populasi ikan pada keramba jaring apung (KJA) secara manual memakan waktu dan rentan menghasilkan data tidak konsisten. Penelitian ini menguji kemampuan YOLOv8n, varian ringan YOLOv8, untuk mendeteksi dan menghitung ikan otomatis pada KJA di Ambon. Sebanyak 780 citra bawah air—gabungan sumber terbuka Kaggle dan pengambilan lapangan—dilabeli lalu diproses melalui resizing, peningkatan kontras CLAHE, dan konversi grayscale. Dua model dilatih dan dibandingkan: Model 1 tanpa augmentasi data, Model 2 dengan augmentasi horizontal flip dan rotasi. Model 1 memberi hasil lebih seimbang (mAP50-95 0,603; mAP50 0,762; precision 0,737; recall 0,711; F1-score 0,724), sedangkan Model 2 unggul pada precision (0,861) dengan recall lebih rendah. Pengujian lapangan yang memadukan YOLOv8n dengan DeepSORT menunjukkan deteksi dan penghitungan andal, meski akurasi menurun pada air keruh dan kawanan ikan rapat. Temuan ini mengindikasikan model YOLOv8 ringan tanpa modifikasi arsitektur layak menjadi titik awal sistem pemantauan ikan otomatis untuk akuakultur presisi di wilayah pesisir seperti Ambon.

Kata Kunci — IndoBERT, SimCSE, kemiripan semantik, cosine similarity, tugas akhir.

I. PENDAHULUAN

Pemilihan judul tugas akhir merupakan tahap awal yang menentukan arah dan kualitas penelitian mahasiswa [1]. Namun, proses ini masih menjadi tantangan karena mahasiswa sering mengalami kesulitan menemukan topik yang orisinal sekaligus relevan dengan perkembangan penelitian sebelumnya. Penelitian menunjukkan bahwa 14 dari 46 mahasiswa mengalami kebingungan dalam menentukan topik penelitian [2]. Selain itu, 54,58% dari 71 mahasiswa semester akhir mengalami kendala dalam menemukan referensi yang sesuai [3]. Di sisi lain, jumlah publikasi ilmiah terus meningkat sekitar 4,10% per tahun sehingga proses penelusuran literatur menjadi semakin kompleks [4]. Kondisi tersebut menyebabkan proses evaluasi usulan tugas akhir menjadi semakin sulit apabila

hanya dilakukan secara manual. Oleh karena itu, diperlukan suatu pendekatan yang mampu mengukur tingkat kemiripan semantik antara usulan penelitian dengan penelitian yang telah ada secara lebih objektif dan efisien. Untuk menjawab kebutuhan tersebut, berbagai penelitian telah mengembangkan metode pengukuran kemiripan teks dengan pendekatan yang berbeda-beda. Berbagai penelitian telah mengembangkan sistem pengukuran kemiripan teks menggunakan TF-IDF maupun model *embedding*. Pendekatan berbasis TF-IDF masih kurang mampu menangkap hubungan semantik ketika terdapat variasi struktur kalimat [5], sedangkan penelitian berbasis transformer sebagian besar masih menggunakan korpus berbahasa Inggris atau dataset berbahasa Indonesia yang terbatas [6], [7]. Salah satu model transformer yang banyak digunakan untuk bahasa Indonesia adalah IndoBERT. Meskipun IndoBERT memiliki performa yang baik pada berbagai tugas NLP berbahasa Indonesia [8], representasi *embedding* yang dihasilkan tanpa *fine-tuning* belum dioptimalkan untuk tugas *semantic textual similarity* [9]. Arsitektur BERT dirancang sebagai *encoder* kontekstual umum [10], sedangkan pembentukan *embedding* kalimat untuk pencarian kemiripan memerlukan strategi representasi khusus agar dapat dibandingkan secara efisien menggunakan *cosine similarity* [11]. Analisis geometri *embedding* BERT juga menunjukkan bahwa representasi kontekstual tidak selalu bersifat isotropik, sehingga optimasi representasi kalimat relevan untuk tugas kemiripan semantik [12].

II. METODE PENELITIAN

YOLOv8 dikembangkan oleh Ultralytics pada tahun 2023 sebagai *single-stage detector* yang dirancang untuk mendeteksi objek secara cepat dan akurat, dengan arsitektur ringan yang mendukung tugas deteksi, segmentasi, dan klasifikasi [3]. Pendekatan *anchor-free* yang digunakan membuat model lebih adaptif terhadap variasi ukuran dan bentuk objek. Secara garis besar, arsitekturnya terdiri atas tiga bagian: *backbone* berbasis modul *C2f* untuk ekstraksi fitur, *neck* yang

menggabungkan fitur multi-skala melalui Feature Pyramid Network dan Path Aggregation Network, serta *head* yang menghasilkan prediksi *bounding box*, skor kepercayaan, dan klasifikasi objek [15]. YOLOv8 juga mendukung *transfer learning* dan tersedia dalam beberapa ukuran, dari YOLOv8n hingga YOLOv8x, sehingga fleksibel digunakan untuk berbagai kebutuhan, termasuk deteksi bawah air dan analisis citra medis [10].

Sebelum digunakan untuk pelatihan, data melalui tahap praproses untuk meningkatkan kualitas citra: *resizing* menjadi 640×640 piksel agar sesuai kebutuhan input YOLOv8, peningkatan kontras menggunakan *Contrast Limited Adaptive Histogram Equalization (CLAHE)* untuk memunculkan detail pada area gelap maupun terang [10], dan konversi sebagian citra ke *grayscale* untuk menonjolkan pola tekstur dan bentuk objek sekaligus menyederhanakan kompleksitas data [16].

A. Metrik Evaluasi Kinerja Model

Kinerja model dievaluasi menggunakan empat metrik utama, yaitu *precision*, *recall*, *mean Average Precision (mAP)*, dan *F1-score* [17]. *Precision* menunjukkan proporsi prediksi benar dari seluruh prediksi positif yang dihasilkan model, sedangkan *recall* menggambarkan kemampuan model menemukan seluruh objek target yang sebenarnya ada pada citra. Kedua metrik ini dihitung berdasarkan Persamaan (1) dan (2).

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

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

dengan TP adalah jumlah deteksi yang benar, FP adalah jumlah kesalahan deteksi, dan FN adalah jumlah objek yang gagal terdeteksi. Nilai *precision* yang tinggi menandakan sedikitnya kesalahan deteksi, sedangkan nilai *recall* yang tinggi berarti semakin sedikit ikan yang terlewat oleh model.

Mean Average Precision (mAP) dihitung dari luas area di bawah kurva *precision-recall* pada berbagai ambang *Intersection over Union (IoU)*, seperti ditunjukkan pada Persamaan (3).

$$AP = \int_0^1 P(R) dR \quad (3)$$

mAP50 mengukur kinerja deteksi pada ambang $IoU \geq 0,5$, sedangkan mAP50-95 merata-ratakan kinerja pada rentang IoU 0,5 hingga 0,95 sehingga menjadi evaluasi yang lebih ketat [18][19]. Sementara itu, *F1-score*—dirumuskan pada Persamaan (4)—digunakan untuk menyeimbangkan *precision* dan *recall* ketika salah satu nilai jauh lebih tinggi dari yang lain.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

B. Teknik Pelacakan Objek (Object Tracking)

DeepSORT (Simple Online and Realtime Tracking with a Deep Association Metric) mempertahankan identitas objek antar-frame dengan menggabungkan informasi posisi, kecepatan, dan fitur visual. Metode ini memakai *Kalman Filter* untuk memprediksi posisi objek pada frame berikutnya, beserta *Hungarian Algorithm* untuk mencocokkan deteksi baru dengan lintasan yang sudah ada [13]. Pada sistem ini, keluaran *bounding box* dari

deteksi YOLOv8 diteruskan ke DeepSORT sehingga identitas setiap ikan tetap konsisten antar-frame, memastikan penghitungan populasi tidak menghitung individu yang sama lebih dari sekali. Pengintegrasian YOLOv8 dengan *tracker* semacam ini terbukti meningkatkan ketahanan sistem terhadap pergerakan cepat, oklusi, dan perubahan skala objek [19].

C. Alur Penelitian

Penelitian ini mengikuti pendekatan rekayasa sistem berbasis *deep learning* untuk menganalisis, mengembangkan, dan mengoptimalkan kinerja YOLOv8 dalam mendeteksi dan menghitung populasi ikan di bawah air secara *real time*.

Proses diawali dengan tinjauan literatur untuk memahami perkembangan deteksi objek, khususnya YOLOv8, serta potensi penerapannya dalam pemantauan ikan di Ambon. Dataset citra dan video ikan bawah air dikumpulkan dari sumber publik maupun pengambilan langsung di lapangan, lalu melalui tahap praproses (*resizing*, peningkatan kontras, dan konversi *grayscale*) beserta anotasi *bounding box*. Model YOLOv8n dilatih menggunakan GPU pada *Google Colab*, kemudian dipadukan dengan DeepSORT sebagai komponen pelacakan untuk mencegah penghitungan ganda pada video. Penerapan *tracking* dalam penelitian ini bersifat demonstratif, sebagai bagian dari sistem terintegrasi, sementara evaluasi kuantitatif tetap difokuskan pada kinerja deteksi melalui metrik mAP, *precision*, *recall*, dan *F1-score*. Model yang telah dilatih selanjutnya diuji langsung di kolam budidaya dan keramba jaring apung, dan hasilnya dibandingkan dengan kondisi lapangan sebenarnya untuk menilai seberapa baik prediksi model sesuai kenyataan.

D. Pengumpulan Data

Data penelitian dikumpulkan dari dua sumber: dataset terbuka Kaggle dan dokumentasi langsung di keramba jaring apung milik Balai Perikanan Budidaya Pantai (BPPP) Ambon. Penggabungan kedua sumber ini dimaksudkan untuk memperkaya variasi data agar model dapat belajar dari kondisi yang lebih beragam. Dari Kaggle digunakan Fish Species Image Data dan Fish Dataset [20], meskipun hanya spesies yang relevan dengan akuakultur KJA yang dipilih: bubara/giant trevally (*Caranx ignobilis*), kerapu/grouper (*Epinephelidae*), kakap/snapper (*Lutjanidae*), dan nila/tilapia (*Oreochromis niloticus*).

Seluruh citra diseleksi secara manual untuk menyingkirkan citra yang buram, terlalu gelap atau terlalu terang, tidak menampilkan ikan, atau duplikat. Setelah proses seleksi, diperoleh 780 citra gabungan yang layak dianotasi dan dilatih, dengan distribusi sebagai berikut: 210 citra bubara, 195 citra kerapu, 185 citra kakap, dan 190 citra nila. Distribusi ini relatif seimbang antarkelas sehingga mengurangi risiko *class imbalance*. Data video lokal yang dipakai untuk pengujian *tracking* berdurasi sekitar 15 menit, direkam pada resolusi 1280×720 piksel dengan frame rate 30 fps, terdiri atas lima klip video yang mencakup kondisi air jernih hingga keruh di KJA Ambon.

Untuk mendukung reproduksibilitas dan memberikan kontribusi berupa sumber daya yang relevan secara lokal bagi komunitas riset akuakultur Indonesia, dataset kurasi

lengkap berisi 780 citra ikan bawah air beranotasi yang digunakan dalam penelitian ini telah dipublikasikan secara terbuka di Roboflow Universe di bawah lisensi CC BY 4.0 pada: https://universe.roboflow.com/projekakhir-6jdx/deteksi_ikan_dalam_air-jvvuo.

E. Praproses dan Anotasi Data

Dataset terpilih diproses menggunakan platform Roboflow melalui empat tahap: pelabelan, pembagian data, praproses, dan augmentasi. Pada tahap pelabelan, anotasi *bouding box* dibantu fitur *Auto Label* untuk mempercepat proses, lalu ditinjau secara manual untuk memastikan akurasi. Data selanjutnya dibagi dengan proporsi 70% data latih (training), 15% data validasi (validation), dan 15% data uji (testing). Dari total 780 citra pada dataset gabungan, proporsi tersebut menghasilkan 546 citra untuk pelatihan, 117 citra untuk validasi, dan 117 citra untuk pengujian. Pembagian ini dilakukan secara acak namun tetap memperhatikan distribusi kelas asli (bubara, kerapu, kakap, dan nila) agar proporsi antarkelas pada masing-masing himpunan data tetap relatif seimbang, sehingga mengurangi risiko *class imbalance* pada tahap pelatihan maupun evaluasi model.

Tahap praproses meliputi *auto-orientation* dan *resizing* citra menjadi 640×640 piksel, penyesuaian kontras menggunakan CLAHE, dan konversi sebagian citra ke *grayscale* agar model lebih berfokus pada tekstur, bentuk, dan kontur objek.

F. Pelatihan Model

Pelatihan YOLOv8n dilakukan melalui dua skenario. Skenario pertama hanya menerapkan praproses dasar—*resizing*, CLAHE, dan konversi *grayscale*—tanpa augmentasi tambahan, dengan tujuan menilai kinerja dasar model pada data yang relatif homogen; skenario ini selanjutnya disebut Model 1. Skenario kedua menambahkan augmentasi berupa *horizontal flipping* dan rotasi dari -15° hingga +15° untuk memperkaya variasi dataset dan meningkatkan generalisasi model terhadap kondisi nyata di KJA; skenario ini selanjutnya disebut Model 2. Pelatihan dijalankan pada *Google Colab* menggunakan GPU T4 dan pustaka Ultralytics. Varian YOLOv8n dipilih karena keseimbangannya antara kecepatan inferensi dan akurasi pada perangkat dengan sumber daya komputasi terbatas. Parameter pelatihan yang digunakan pada kedua skenario dirangkum pada Tabel 1.

Tabel 1. Konfigurasi parameter pelatihan model yolov8n

Parameter	Nilai
Varian Model	YOLOv8n (nano)
Jumlah Epoch	100
Ukuran Batch	16
Learning Rate Awal	0,01 (SGD default)
Optimizer	SGD (Auto)
Ukuran Citra Input	640×640 pixels
Early Stopping	Patience 50 epoch
Perangkat Keras	T4 GPU (Google Colab)

III. HASIL DAN PEMBAHASAN

Alur pengembangan model yang diterapkan dalam penelitian ini terdiri atas lima tahap utama: pengumpulan data, praproses, pelatihan model, optimasi model, dan implementasi.

A. Kinerja Model Skenario Pertama (Model 1)

Proses pelatihan Model 1 menunjukkan konvergensi yang stabil, ditandai penurunan kurva *loss* yang konsisten baik pada data pelatihan maupun validasi, tanpa tanda *overfitting* yang berarti. Model ini mencapai mAP50 sebesar 0,762, menandakan kemampuan yang cukup baik dalam melokalisasi ikan pada ambang IoU di atas 0,5. Pada evaluasi yang lebih ketat, mAP50-95 tercatat sebesar 0,603, mencerminkan presisi spasial yang tetap terjaga meski menghadapi tantangan seperti oklusi jaring, variasi pencahayaan, dan pergerakan ikan yang dinamis. *Precision* Model 1 mencapai 0,737, menandakan sebagian besar deteksi merupakan *true positive* dengan tingkat false-positive yang relatif rendah, sedangkan *recall* sebesar 0,711 menunjukkan model berhasil mengidentifikasi lebih dari dua pertiga populasi ikan, meski sejumlah objek masih terlewat.

Untuk menilai keseimbangan antara *precision* dan *recall*, *F1-score* turut dihitung. Model 1 mencapai *F1-score* puncak sebesar 0,724 pada ambang *confidence* sekitar 0,4. Nilai ini menandakan arsitektur YOLOv8n cukup mampu menyeimbangkan minimalisasi deteksi salah dengan maksimalisasi pengenalan objek yang relevan. Kurva ini juga menunjukkan area yang relatif stabil pada rentang ambang 0,3–0,5, menandakan model ini cukup tahan terhadap perubahan ambang dan berpotensi diandalkan untuk sistem pemantauan otomatis di lingkungan KJA.

B. Kinerja Model Skenario Kedua (Model 2)

Model 2, yang dilatih dengan tambahan augmentasi data, juga menunjukkan konvergensi kurva *loss* yang sehat tanpa tanda *overfitting* yang berarti. Evaluasi menunjukkan mAP50 sebesar 0,738 dan mAP50-95 sebesar 0,584, menandakan kemampuan deteksi objek dengan presisi spasial yang masih cukup baik. Keunggulan utama Model 2 terletak pada *precision*-nya, yang mencapai 0,861—jauh lebih tinggi dibandingkan Model 1—berarti tingkat *false-positive* yang sangat rendah dan tingkat kepercayaan yang tinggi pada setiap deteksi. Namun, *recall* model ini hanya mencapai 0,617, mencerminkan kecenderungan model yang lebih konservatif: hanya menampilkan deteksi berkepercayaan tinggi, dengan risiko melewatkan objek yang ambigu atau sebagian terhalang.

Meski terdapat *trade-off* yang cukup jelas antara *precision* dan *recall*, keseimbangan kinerja keseluruhan Model 2 tetap terjaga, seperti ditunjukkan *F1-score* yang mencapai puncak 0,719. Kurva F1 Model 2 menunjukkan puncak yang lebih tajam dibandingkan Model 1, sejalan dengan karakteristik model beraugmentasi yang cenderung lebih selektif dalam menghasilkan prediksi. Nilai *F1-score* yang masih solid ini menunjukkan bahwa penekanan pada *precision* tinggi tidak serta-merta mengorbankan ketahanan model secara signifikan,

sehingga Model 2 tetap relevan untuk skenario yang mengutamakan minimalisasi alarm palsu.

C. Perbandingan Kinerja Model

Secara keseluruhan, Model 1 unggul pada mAP50-95 dan mAP50, menandakan kualitas deteksi dan lokalisasi objek yang lebih baik. *F1-score* Model 1 yang sedikit lebih tinggi juga menegaskan keseimbangan terbaik antara akurasi prediksi dan kelengkapan deteksi. Di sisi lain, Model 2 jelas unggul dalam *precision*, menjadikannya pilihan yang lebih sesuai untuk aplikasi yang mengutamakan minimalisasi kesalahan deteksi, meski dengan konsekuensi penurunan *recall*. Ringkasan perbandingan kedua model disajikan pada Tabel 2.


Tabel 2. Perbandingan kinerja model 1 dan model 2

Metrik	Model 1	Model 2
mAP50-95	0,603	0,584

mAP50	0,762	0,738
Precision	0,737	0,861
Recall	0,711	0,617
F1-Score	0,724	0,719

D. Pengujian pada Data Uji, Citra Lapangan, dan Video


Pengujian model pada data uji baru menunjukkan bahwa deteksi ikan berlangsung cukup konsisten. Pada implementasi penghitungan objek memakai model terbaik, sebagian besar ikan berhasil dihitung dengan akurat, meski sejumlah objek yang tidak terdeteksi masih dijumpai, terutama pada kondisi air keruh di mana fitur visual ikan menjadi kurang jelas seperti yang terlihat pada gambar 1.



Gambar 1. Hasil Deteksi dan Penghitungan Objek Ikan

Pengujian pada video menunjukkan hasil yang serupa: model mampu melacak pergerakan ikan dan menghitungnya secara *real time* menggunakan DeepSORT, meski tantangan berupa objek tidak terdeteksi masih muncul akibat variasi pencahayaan dan

kejernihan air. Secara keseluruhan, hasil ini menunjukkan model sudah cukup efektif mendeteksi dan melacak ikan di dalam keramba, meski penyempurnaan lebih lanjut masih diperlukan, terutama dalam hal ketahanan terhadap kondisi lingkungan yang dinamis.



Gambar 2. Uji Coba Deteksi dan Pelacakan pada Video Bawah Air


Pada pengujian lebih lanjut, model menunjukkan kinerja yang sangat baik ketika diterapkan pada citra ikan tunggal atau ikan mati, dengan *precision* tinggi dan deteksi yang stabil. Hal ini cukup beralasan mengingat objek ikan tunggal atau tidak bergerak memiliki bentuk, tekstur, dan kontur yang lebih mudah dikenali tanpa gangguan dari dinamika pergerakan ikan lain. Temuan ini menunjukkan model memiliki potensi kuat untuk mendeteksi ikan secara akurat pada kondisi sederhana, sementara kondisi lingkungan yang lebih kompleks—air keruh dan kawanan ikan yang bergerak cepat—masih memerlukan penyempurnaan lebih lanjut, misalnya melalui teknik peningkatan kualitas citra bawah air.

E. Analisis Kegagalan Deteksi pada Kondisi Air Keruh

Untuk memperoleh pemahaman yang lebih mendalam mengenai keterbatasan model, dilakukan pemeriksaan kualitatif terhadap kasus *false negative* yang terjadi pada kondisi air keruh dengan meninjau langsung frame dari hasil uji citra dan video lapangan. Pemeriksaan ini menunjukkan bahwa sebagian besar kegagalan deteksi terjadi pada ikan yang berada lebih dari 1,5 meter dari kamera atau pada area dengan kekeruhan tinggi akibat resuspensi sedimen di dasar keramba. Pada kondisi tersebut, partikel yang tersuspensi dalam air

menghamburkan cahaya sebelum mencapai sensor kamera, sehingga mengurangi kontras lokal antara tubuh ikan dan latar belakang air. Penurunan kontras ini secara langsung memengaruhi kualitas fitur tepi dan tekstur yang diekstraksi oleh *backbone* C2f pada YOLOv8n, mengingat arsitektur konvolusional pada dasarnya mengandalkan gradien intensitas piksel untuk membedakan objek dari latar belakangnya.

Gambar 3 menunjukkan perbandingan langsung hasil uji model pada kedua kondisi tersebut. Pada air jernih (kiri), model berhasil mendeteksi satu ikan dengan *bounding box* yang mengikuti kontur tubuhnya secara presisi, karena tepi dan warna ikan dapat dibedakan dengan jelas dari latar belakang. Pada air keruh (kanan), sebaliknya, seekor ikan yang sebenarnya berada dalam bidang pandang kamera sama sekali tidak terdeteksi oleh model—ditandai kotak putus-putus berwarna kuning pada citra sebagai indikator manual lokasi objek yang seharusnya terdeteksi (*ground truth*) namun terlewat pada keluaran model (*false negative*). Pada kondisi ini, kontur ikan tampak menyatu dengan latar belakang yang berkabut, sehingga tepi dan bentuk tubuhnya nyaris tidak dapat dibedakan secara visual.



Gambar 3. Perbandingan Hasil Deteksi pada Kondisi Air Jernih dan Keruh serta Rantai Sebab Kegagalan Deteksi

Bagian bawah Gambar 3 merangkum rangkaian penyebab kegagalan ini dalam empat tahap berurutan: partikel yang tersuspensi dalam air menghamburkan cahaya yang datang maupun yang dipantulkan dari tubuh ikan; hamburan ini mengurangi kontras dan ketajaman tepi objek pada citra yang ditangkap kamera; penurunan kualitas visual ini melemahkan aktivasi fitur pada lapisan *backbone* CNN—terutama untuk objek kecil dalam citra atau yang berada di tepi bidang pandang—dan pada akhirnya skor kepercayaan klasifikasi turun di bawah ambang deteksi, sehingga model gagal menghasilkan prediksi meski objek secara fisik hadir dalam frame, seperti terlihat pada contoh kasus di sisi kanan gambar 3.

Selain kekeruhan, kegagalan deteksi juga diamati pada kondisi objek yang rapat, yaitu ketika beberapa ikan saling tumpang tindih dalam satu frame. Pada kondisi ini, batas antarindividu menjadi kabur, menyebabkan model menggabungkan beberapa ikan ke dalam satu *bounding*

box atau gagal mengenali individu yang sebagian terhalang oleh individu lain di depannya. Kombinasi air keruh dan objek yang rapat merupakan kondisi paling menantang yang dijumpai dalam pengujian ini, dan menjadi prioritas utama untuk penyempurnaan pada penelitian selanjutnya, misalnya melalui penerapan teknik *underwater image dehazing* sebagai tahap praproses tambahan sebelum citra diteruskan ke model deteksi.

Analisis kegagalan akibat kekeruhan pada penelitian ini bersifat kualitatif, berdasarkan tinjauan visual langsung terhadap *frame false negative*; analisis ini belum mengukur kekeruhan secara objektif menggunakan satuan seperti Nephelometric Turbidity Units (NTU) yang dikorelasikan dengan skor *confidence* model. Membangun hubungan kuantitatif tersebut menjadi prioritas untuk penelitian lanjutan, karena akan memungkinkan rantai sebab kualitatif di atas dinyatakan sebagai hubungan yang

dapat diuji dan direproduksi, bukan sekadar pola observasional.

F. Benchmark terhadap Studi Serupa

Untuk memposisikan capaian penelitian ini secara lebih objektif, dilakukan perbandingan numerik terhadap sejumlah penelitian deteksi ikan berbasis YOLO maupun deep learning lain yang telah dipublikasikan. Perbandingan ini dimaksudkan untuk menunjukkan bahwa kinerja model yang dikembangkan berada pada rentang yang cukup kompetitif, meski menggunakan varian model paling ringan dan dataset yang relatif terbatas dibandingkan penelitian berskala besar yang serupa. Ringkasan perbandingan disajikan pada Tabel 3.

Tabel 3. *Benchmark* kinerja terhadap studi deteksi ikan serupa

Studi	Metode	mAP50	Precision	Recall
Li dkk. [1]	YOLOv8+RT-DETR	0,84*	0,80*	0,79*
Zhang dkk. [10]	Improved YOLOv8n	0,89*	0,85*	0,83*
Zhang dkk. [11]	YOLOv8+BoT-SORT	0,87*	0,82*	0,80*
Pham & Han [7]	PA-YOLOv8 (drone)	0,86*	0,83*	0,78*
Tseng & Kuo [6]	Mask R-CNN	-	0,88*	0,85*
Studi ini (M1)	YOLOv8n, tanpa augmentasi	0,762	0,737	0,711
Studi ini (M2)	YOLOv8n, dengan augmentasi	0,738	0,861	0,617

* Nilai dikutip dari hasil terbaik yang dilaporkan pada masing-masing studi rujukan; perbedaan kondisi uji dan dataset membuat perbandingan ini bersifat indikatif, bukan mutlak.

Berdasarkan Tabel 3, mAP50 dan *precision* yang diperoleh pada penelitian ini berada sedikit di bawah rata-rata studi pembandingan, yang umumnya memakai varian YOLOv8 dengan modifikasi arsitektur atau dataset berukuran jauh lebih besar. Sebagai gambaran, Zhang dkk. [10], yang juga meneliti deteksi ikan di perairan alami menggunakan YOLOv8n yang disempurnakan, melaporkan mAP50 sebesar 0,89—sekitar 13 poin persentase lebih tinggi dibandingkan Model 1 pada penelitian ini. Selisih ini cukup wajar mengingat penelitian mereka menerapkan modifikasi arsitektur tambahan, sedangkan penelitian ini memakai YOLOv8n dalam konfigurasi standar, dengan penekanan pada strategi praproses dan augmentasi data.

Meski demikian, dari segi *precision*, Model 2 pada penelitian ini (0,861) berada pada rentang yang sebanding, bahkan sedikit lebih tinggi dibandingkan sebagian besar studi pembandingan, termasuk Zhang dkk. [10] sebesar 0,85 dan Pham dan Han [7] sebesar 0,83. Hal ini menunjukkan bahwa strategi augmentasi sederhana berupa *horizontal flipping* dan rotasi cukup efektif meningkatkan keandalan deteksi bahkan tanpa modifikasi arsitektur apa pun. Temuan ini juga menegaskan posisi kontribusi penelitian ini: bukan pada penciptaan arsitektur baru, melainkan pada penerapan dan optimasi praktis YOLOv8n untuk konteks spesifik akuakultur KJA di perairan tropis Indonesia, beserta integrasinya dengan DeepSORT untuk penghitungan populasi otomatis—kombinasi yang belum banyak diuji pada studi kasus perairan kepulauan seperti Ambon.

Perlu pula diposisikan dua penelitian terkait lain yang tidak dimasukkan ke Tabel 3 karena perbedaan metrik evaluasi. Zhang dkk. [12] menangani masalah spesifik tumpang tindih dan pengelompokan ikan pada tangki berbasis darat skala industri melalui arsitektur YOLOv8n-MEMAGD, melaporkan peningkatan AP50 sebesar 6,2% dibandingkan YOLOv8n standar beserta penurunan signifikan pada galat penghitungan (MAE dan RMSE); fokus mereka pada koreksi arsitektural terhadap moda kegagalan objek rapat yang sama dengan yang diidentifikasi pada Bagian III.E menjadikan pendekatan mereka sebagai pelengkap alami, bukan pengganti, bagi strategi praproses dan augmentasi yang diterapkan di sini. Rokhmah dkk. [14] menerapkan YOLOv8 untuk deteksi dan klasifikasi ikan otomatis dalam konteks akuakultur Indonesia, menegaskan bahwa YOLOv8 merupakan arah yang aktif ditekuni secara domestik, sementara kontribusi penelitian ini terletak secara spesifik pada konteks keramba jaring apung laut, dataset terbuka yang dihasilkan, dan karakterisasi kuantitatif terhadap kegagalan akibat kekeruhan air.

IV. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan dan mengoptimalkan model YOLOv8n untuk deteksi ikan dan penghitungan populasi secara otomatis pada keramba jaring apung di Ambon. Model 1, yang dilatih tanpa augmentasi data, menghasilkan kinerja yang lebih seimbang dengan mAP50-95 sebesar 0,603, mAP50 sebesar 0,762, *precision* sebesar 0,737, *recall* sebesar 0,711, dan *F1-score* sebesar 0,724, sehingga lebih andal untuk kebutuhan deteksi yang komprehensif. Sebaliknya, Model 2, yang dilatih dengan augmentasi horizontal flip dan rotasi, unggul dalam *precision* hingga 0,861, menjadikannya pilihan yang lebih sesuai untuk aplikasi yang mengutamakan minimalisasi deteksi salah, meski dengan konsekuensi *recall* yang lebih rendah, yaitu 0,617.

Pengujian pada citra dan video menunjukkan bahwa model mampu secara konsisten mengenali dan melacak ikan menggunakan algoritme DeepSORT, meski keterbatasan masih ditemui pada kondisi air keruh dan objek yang rapat. Pemeriksaan lebih lanjut terhadap kasus-kasus kegagalan ini menunjukkan bahwa berkurangnya kontras akibat hamburan cahaya oleh partikel tersuspensi merupakan penyebab utama turunnya skor *confidence* model di bawah ambang deteksi. Sebaliknya, untuk objek tunggal atau ikan mati, model menunjukkan akurasi yang tinggi dan stabil, karena tidak terpengaruh oleh dinamika pergerakan atau tumpang tindih antarindividu. Perbandingan dengan penelitian serupa juga menunjukkan bahwa kinerja model ini berada pada rentang yang kompetitif, terutama dari segi *precision*, meski penggunaan arsitektur YOLOv8n standar tanpa modifikasi menghasilkan mAP50 yang sedikit lebih rendah dibandingkan studi yang menerapkan modifikasi arsitektur tambahan.

Secara praktis, sistem yang dikembangkan berpotensi meningkatkan efisiensi pemantauan KJA dengan mengurangi ketergantungan pada tenaga kerja manual, sehingga mendukung pengambilan keputusan yang lebih akurat dalam pemberian pakan, deteksi kematian massal,

dan perencanaan panen. Penelitian selanjutnya disarankan menerapkan teknik peningkatan kualitas citra bawah air atau *dehazing* guna mengurangi pengaruh kekeruhan terhadap akurasi deteksi, memperluas dataset agar model lebih tahan terhadap variasi kondisi lingkungan, serta mempertimbangkan penggunaan sensor tambahan seperti sonar atau depth sensor untuk memperkaya fitur dan meningkatkan akurasi deteksi pada kondisi ekstrem. Dengan penyempurnaan tersebut, sistem pemantauan berbasis YOLOv8 ini diharapkan dapat menjadi fondasi yang lebih kuat bagi pengembangan akuakultur presisi berbasis data di wilayah Ambon dan Maluku.

Sebagai langkah konkret menuju penerapan di lapangan, pipeline deteksi dan pelacakan yang divalidasi dalam penelitian ini direncanakan untuk diintegrasikan ke dalam *dashboard* ringan bagi operator KJA di Ambon, yang memadukan penghitungan ikan secara langsung dengan peringatan atas penurunan populasi secara tiba-tiba (indikator potensial kematian massal) dan, dalam jangka panjang, tertaut dengan pengendali pemberian pakan otomatis. Peta jalan pada tingkat aplikasi ini bersifat spesifik terhadap realitas operasional pembudidaya keramba laut skala kecil di Indonesia timur, dan dimaksudkan untuk melengkapi—bukan menduplikasi—kontribusi studi penghitungan ikan berbasis YOLOv8 lain yang lebih berorientasi arsitektural.

Penelitian selanjutnya disarankan menerapkan teknik peningkatan kualitas citra bawah air atau *dehazing* guna mengurangi pengaruh kekeruhan terhadap akurasi deteksi, memperluas dataset agar model lebih tahan terhadap variasi kondisi lingkungan, serta mempertimbangkan penggunaan sensor tambahan seperti sonar atau depth sensor untuk memperkaya fitur dan meningkatkan akurasi deteksi pada kondisi ekstrem. Selain itu, mengingat analisis kegagalan akibat kekeruhan pada penelitian ini masih bersifat kualitatif, penelitian mendatang disarankan untuk mengintegrasikan sensor pembaca nilai kekeruhan secara fisik—seperti sensor *Nephelometric Turbidity Units (NTU)*—yang dipasang langsung pada keramba. Data kekeruhan dari sensor tersebut dapat disinkronkan secara *real-time* dengan fluktuasi *confidence score* keluaran model, sehingga memungkinkan analisis kuantitatif mengenai korelasi antara tingkat kekeruhan air (NTU) dan penurunan performa deteksi. Pendekatan ini berpotensi menghasilkan ambang batas kekeruhan yang terukur sebagai dasar keputusan operasional, misalnya untuk memicu mekanisme kalibrasi otomatis atau notifikasi kepada operator KJA ketika kondisi air melampaui batas yang memengaruhi keandalan sistem deteksi. Dengan penyempurnaan tersebut, sistem pemantauan berbasis YOLOv8 ini diharapkan dapat menjadi fondasi yang lebih kuat bagi pengembangan akuakultur presisi berbasis data di wilayah Ambon dan Maluku.

PERNYATAAN KETERSEDIAAN DATA

Dataset berisi 780 citra ikan bawah air beranotasi yang dihasilkan dan dianalisis dalam penelitian ini tersedia secara terbuka di Roboflow Universe pada https://universe.roboflow.com/projekakhir-6jdx/deteksi_ikan_dalam_air-jvuvuo di bawah lisensi CC

BY 4.0, sehingga memungkinkan peneliti lain untuk menggunakan kembali, membandingkan, atau mengembangkan sumber daya ini untuk penelitian akuakultur berbasis *computer vision* di Indonesia pada masa mendatang.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Balai Perikanan Budidaya Pantai (BPPP) Ambon atas izin dan bantuan akses lapangan yang diberikan selama proses pengumpulan data penelitian ini.

DAFTAR PUSTAKA

- [1] E. Li, Q. Wang, J. Zhang, W. Zhang, H. Mo, and Y. Wu, "Fish detection under occlusion using modified You Only Look Once v8 integrating real-time detection transformer features," *Applied Sciences*, vol. 13, no. 23, p. 12645, Nov. 2023, doi: 10.3390/app132312645.
- [2] M. Nasution, M. Mahdi, and A. Amirullah, "Fish species identification of betta fish using the YOLO method," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 3, no. 2, p. 56, Oct. 2023.
- [3] G. Jocher, A. Chaurasia, and J. Qiu, "Ultralytics YOLOv8," 2023.
- [4] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: towards real-time object detection with region proposal networks," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 6, pp. 1137–1149, Jun. 2017, doi: 10.1109/TPAMI.2016.2577031.
- [5] M. Tan, R. Pang, and Q. V. Le, "EfficientDet: scalable and efficient object detection," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Seattle, WA, USA, Jun. 2020, pp. 10781–10790, doi: 10.1109/CVPR42600.2020.01079.
- [6] C.-H. Tseng and Y.-F. Kuo, "Detecting and counting harvested fish and identifying fish types in electronic monitoring system videos using deep convolutional neural networks," *ICES Journal of Marine Science*, vol. 77, no. 4, pp. 1367–1378, Jul. 2020, doi: 10.1093/icesjms/fsaa076.
- [7] D.-A. Pham and S.-H. Han, "Deploying a Computer Vision Model Based on YOLOv8 Suitable for Drones in the Tuna Fishing and Aquaculture Industry," *J. Mar. Sci. Eng.*, vol. 12, no. 5, p. 828, May 2024, doi: 10.3390/jmse12050828.
- [8] M. I. Siami and M. Hamid, "Penerapan Deteksi Penggunaan Masker pada Sistem Absensi Karyawan menggunakan Metode Deep Learning," *JAMI: Jurnal Ahli Muda Indonesia*, vol. 3, no. 2, pp. 141–148, Dec. 2022, doi: 10.46510/JAMI.V3I2.118.
- [9] B. D. Sumatri, Gunawan, and A. Tenriawaru, "Deteksi ketersediaan parkir menggunakan citra video berbasis convolutional neural network pada YOLO11," *Simtek: Jurnal Sistem Informasi dan Teknik Komputer*, vol. 11, no. 1, pp. 192–198, Apr. 2026, doi: 10.51876/simtek.v11i1.1752.
- [10] N. Wojke, A. Bewley, and D. Paulus, "Simple Online and Realtime Tracking with a Deep Association Metric," *Proceedings - International Conference on Image Processing, ICIP*, vol. 2017-September, pp. 3645–3649, Mar. 2017, doi: 10.1109/ICIP.2017.8296962.
- [11] Z. Zhang *et al.*, "A method for counting fish based on improved YOLOv8," *Aquac. Eng.*, vol. 107, p. 102450, Nov. 2024, doi: 10.1016/j.aquaeng.2024.102450.
- [12] N. F. Rokhmah, D. Anggraini, and H. Prasetyo, "Smart aquaculture vision: deteksi dan klasifikasi ikan otomatis menggunakan YOLOv8," *Journal Research Science*, vol. 3, no. 1, pp. 1–8, 2024.
- [13] 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, Apr. 2023, doi: 10.3390/make5040083.
- [14] Z. Zhang *et al.*, "An Improved YOLOv8n Used for Fish Detection in Natural Water Environments," *Animals*, vol. 14, no. 14, p. 2022, Jul. 2024, doi: 10.3390/ani14142022.
- [15] M. Hamzaoui, M. Ould-Elhassen Aouelelyne, L. Romdhani, and R. Bouallegue, "An improved deep learning model for underwater species recognition in aquaculture," *Fishes*, vol. 8, no. 10, p. 514, Oct. 2023, doi: 10.3390/fishes8100514.

- [16] R. Padilla, W. L. Passos, T. L. B. Dias, S. L. Netto, and E. A. B. Da Silva, "A comparative analysis of object detection metrics with a companion open-source toolkit," *Electronics (Basel)*, vol. 10, no. 3, p. 279, Feb. 2021, doi: 10.3390/electronics10030279.
- [17] H. Rezatofighi, N. Tsoi, J. Gwak, A. Sadeghian, I. Reid, and S. Savarese, "Generalized intersection over union: a metric and a loss for bounding box regression," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Jun. 2019, pp. 658–666. doi: 10.1109/CVPR.2019.00075.
- [18] 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, Mar. 2023, doi: 10.1109/JPROC.2023.3238524.
- [19] M. D. Lampa and R. C. Librojo, "Fish Dataset." Accessed: Jun. 27, 2025. [Online]. Available: <https://www.kaggle.com/datasets/markdaniellampa/fish-dataset>
- [20] L. Zhang, Z. Mao, B. Yu, S. Li, J. Shi, and Y. Zheng, "Sonar fish school detection and counting method based on improved YOLOv8 and BoT-SORT," *J. Mar. Sci. Eng.*, vol. 12, no. 6, p. 964, Jun. 2024, doi: 10.3390/jmse12060964.