

Klasifikasi Spesies Teripang (*Holothuroidea*) Menggunakan YOLOv11

Grea Nur Fadillah¹, Luther Alexander Latumakulita^{2*}, Eric Alfonsius³

^{1,2,3}Sistem Informasi, Universitas Sam Ratulangi, Indonesia

Email: ¹greaadillah106@student.unsrat.ac.id, ^{2*}latumakulitala@unsrat.ac.id, ³ericalfonsius@unsrat.ac.id

Abstrak

Teripang merupakan sumber daya hayati laut yang memiliki nilai ekologis dan ekonomis tinggi, namun identifikasi spesiesnya masih dilakukan secara manual sehingga rentan terhadap kesalahan akibat kemiripan karakteristik morfologi antarspesies. Penelitian ini bertujuan membangun model klasifikasi spesies teripang berbasis citra digital menggunakan YOLOv11. Dataset yang digunakan terdiri atas 1.000 citra tiga spesies teripang, yaitu *Holothuria scabra*, *Holothuria atra*, dan *Holothuria leucospilota*, yang diperoleh dari wilayah perairan Desa Serei dan Desa Paputungan, Kabupaten Minahasa Utara. Tahapan penelitian meliputi validasi ahli, pelabelan data, pembagian dataset dengan rasio 70:20:10, *preprocessing*, augmentasi pada data latih, pelatihan model YOLOv11n selama 50 *epoch*, evaluasi menggunakan data uji, serta implementasi model ke dalam sistem berbasis *Gradio*. Hasil evaluasi pada 100 data uji menunjukkan bahwa model memperoleh *Precision* sebesar 99,70%, *Recall* 100,00%, *F1-Score* 99,85%, *mAP50* 99,50%, dan *mAP50-95* 99,00%. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengidentifikasi ketiga spesies teripang serta mampu mempertahankan performa pada data yang tidak digunakan selama proses pelatihan. Penelitian ini juga menghasilkan prototipe sistem berbasis *web* yang dapat membantu proses identifikasi spesies teripang secara otomatis melalui citra digital.

Kata Kunci: Teripang; YOLOv11; Klasifikasi; Deep Learning; Citra Digital

Abstract

Sea cucumbers are marine organisms with high ecological and economic value; however, species identification is still commonly performed manually, making it prone to errors due to morphological similarities among species. This study aims to develop a digital image-based sea cucumber species classification model using YOLOv11. The dataset consisted of 1,000 images of three sea cucumber species, namely *Holothuria scabra*, *Holothuria atra*, and *Holothuria leucospilota*, collected from the coastal waters of Serei and Paputungan Villages, North Minahasa Regency, Indonesia. The research stages included expert validation, data labeling, dataset splitting with a 70:20:10 ratio, preprocessing, data augmentation on the training set, YOLOv11n model training for 50 epochs, model evaluation using the test set, and implementation through a *Gradio*-based application. Evaluation on 100 test images showed that the proposed model achieved a Precision of 99.70%, a Recall of 100.00%, an F1-Score of 99.85%, an mAP50 of 99.50%, and an mAP50-95 of 99.00%. These results indicate that the proposed model is capable of accurately classifying the three sea cucumber species while maintaining excellent generalization performance on previously unseen data. Furthermore, the developed web-based prototype demonstrates the potential application of YOLOv11 for automated sea cucumber species identification using digital images.

Keywords: Sea Cucumber; Classification; Deep Learning; Digital Images

*Corresponding Author:

Luther Alexander Latumakulita, Universitas Sam Ratulangi, Indonesia

Email: latumakulitala@unsrat.ac.id

1. PENDAHULUAN

Teripang (*Holothuroidea*) merupakan salah satu sumber daya hayati laut yang memiliki peran ekologis dan nilai ekonomi yang tinggi. Sebagai organisme benthik, teripang berperan dalam proses *deposit feeding* yang membantu daur ulang nutrisi serta menjaga kualitas sedimen di dasar perairan. Selain itu, beberapa spesies teripang memiliki nilai ekonomi tinggi karena dimanfaatkan sebagai bahan pangan, obat tradisional, serta bahan baku industri farmasi dan kosmetik [1], [2]. Tingginya nilai

ekonomi tersebut menyebabkan identifikasi spesies menjadi aspek penting dalam mendukung pemanfaatan dan pengelolaan sumber daya teripang secara berkelanjutan.

Meskipun demikian, proses identifikasi spesies teripang masih umumnya dilakukan secara manual berdasarkan karakteristik morfologi, seperti bentuk tubuh, warna, dan tekstur permukaan. Beberapa spesies memiliki kemiripan karakteristik visual sehingga sulit dibedakan hanya melalui pengamatan langsung, terutama oleh individu yang tidak memiliki keahlian di bidang taksonomi. Kondisi tersebut berpotensi menyebabkan kesalahan identifikasi yang dapat memengaruhi pemanfaatan, perdagangan, maupun pengelolaan sumber daya teripang [3]. Oleh karena itu, diperlukan suatu pendekatan yang mampu membantu proses identifikasi secara lebih cepat, objektif, dan konsisten.

Perkembangan *Artificial Intelligence* (AI), khususnya pada bidang *computer vision*, telah mendorong pemanfaatan *Deep Learning* untuk berbagai tugas klasifikasi dan deteksi objek berbasis citra digital [4], [5]. Salah satu algoritma yang banyak digunakan adalah *You Only Look Once* (YOLO), yang mampu melakukan deteksi objek dan klasifikasi secara efisien dalam satu proses [6]. Generasi terbaru, yaitu YOLOv11, menawarkan peningkatan kemampuan ekstraksi fitur, efisiensi komputasi, serta akurasi yang lebih baik dibandingkan generasi sebelumnya melalui pengembangan arsitektur C3k2 dan C2PSA sehingga berpotensi diterapkan pada objek yang memiliki kemiripan karakteristik visual [7].


Beberapa penelitian sebelumnya telah menunjukkan bahwa teknologi berbasis YOLO mampu diterapkan pada objek bawah air. [8] mengembangkan sistem deteksi teripang pada kondisi perairan keruh, [9] menerapkan *Deep Learning* untuk deteksi dan pelacakan perilaku teripang, sedangkan [10] dan [11] mengembangkan arsitektur YOLOv11 untuk meningkatkan performa deteksi objek bawah air. Namun, penelitian-penelitian tersebut masih berfokus pada deteksi keberadaan objek, bukan klasifikasi spesies berdasarkan karakteristik morfologi. Selain itu, sebagian besar penelitian menggunakan dataset luar negeri sehingga belum diketahui bagaimana performa YOLOv11 pada dataset primer yang diperoleh langsung dari perairan Indonesia dengan karakteristik lingkungan yang berbeda. Kesenjangan penelitian tersebut menjadi dasar penelitian ini, yaitu mengembangkan model klasifikasi tiga spesies teripang menggunakan YOLOv11 berdasarkan dataset primer Indonesia serta mengimplementasikannya ke dalam sistem berbasis web untuk mendukung proses identifikasi spesies secara otomatis.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penggunaan YOLOv11 untuk mengklasifikasikan tiga spesies teripang, yaitu *Holothuria scabra*, *Holothuria atra*, dan *Holothuria leucospilota*, berdasarkan citra digital. Dataset yang digunakan merupakan dataset primer yang diperoleh dari wilayah perairan Desa Serei dan Desa Paputungan, Kabupaten Minahasa Utara. Model dikembangkan melalui tahapan validasi ahli, pelabelan data, *preprocessing*, augmentasi, pelatihan menggunakan YOLOv11n, evaluasi pada data uji, serta implementasi ke dalam sistem berbasis *Gradio* untuk memudahkan proses identifikasi spesies teripang secara otomatis.

Penelitian ini bertujuan membangun model klasifikasi spesies teripang menggunakan YOLOv11 serta mengevaluasi performanya berdasarkan metrik *Precision*, *Recall*, *F1-Score*, *mAP50*, dan *mAP50-95* [12], [13]. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan sistem identifikasi spesies teripang berbasis citra digital yang akurat dan dapat diimplementasikan sebagai pendukung kegiatan penelitian maupun pengelolaan sumber daya hayati laut..

2. METODE PENELITIAN

Penelitian ini bertujuan mengembangkan model klasifikasi spesies teripang menggunakan YOLOv11 berdasarkan citra digital. Penelitian dilakukan melalui serangkaian tahapan yang saling berkaitan untuk menghasilkan model yang mampu mengidentifikasi spesies teripang secara akurat dan memiliki kemampuan generalisasi yang baik terhadap data baru. Proses penelitian diawali dengan pengumpulan dataset primer, kemudian dilanjutkan dengan pembagian data, pra pemrosesan dan augmentasi data, pelatihan model menggunakan YOLOv11n, evaluasi performa model berdasarkan metrik *Precision*, *Recall*, *F1-Score*, *mAP50*, dan *mAP50-95*, serta implementasi model ke dalam sistem berbasis web menggunakan *Gradio*. Alur tahapan penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

2.1. Pengumpulan Dataset

Dataset yang digunakan merupakan dataset primer yang diperoleh melalui proses dokumentasi langsung di wilayah perairan Desa Serei dan Desa Paputungan, Kecamatan Likupang Barat, Kabupaten Minahasa Utara. Dataset terdiri atas tiga spesies teripang, yaitu *Holothuria scabra*, *Holothuria atra*, dan *Holothuria leucospilota*, dengan jumlah keseluruhan sebanyak 1.000 citra digital. Proses pengambilan citra dilakukan menggunakan kamera iPhone 15 dengan mempertimbangkan variasi posisi, orientasi, dan latar belakang agar data mampu merepresentasikan kondisi objek secara lebih beragam.

Tabel 1. Komposisi Dataset Penelitian

Spesies	Jumlah Citra
<i>Holothuria scabra</i>	300
<i>Holothuria atra</i>	350
<i>Holothuria leucospilota</i>	350
Total	1000

Sebelum digunakan dalam proses pelatihan, identifikasi spesies divalidasi oleh ahli berdasarkan karakteristik morfologi untuk memastikan kesesuaian label setiap spesies [1]. Setelah proses validasi selesai, setiap citra diberi anotasi menggunakan platform Roboflow dengan metode *bounding box*. Tahap pelabelan bertujuan memberikan informasi lokasi objek dan kelas spesies sehingga dapat digunakan sebagai data masukan pada proses pelatihan model YOLOv11n.

2.2. Pembagian Dataset

Dataset yang telah diberi anotasi selanjutnya dibagi menjadi data latih, data validasi, dan data uji dengan rasio 70:20:10. Data latih digunakan untuk mempelajari karakteristik visual setiap spesies, data validasi digunakan untuk memantau performa model selama proses pelatihan serta memilih model terbaik (*best.pt*), sedangkan data uji digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah digunakan sebelumnya.

Tabel 2. Pembagian Dataset

Spesies	Latih	Validasi	Uji	Total
<i>Holothuria scabra</i>	212	62	26	300
<i>Holothuria atra</i>	229	81	40	350
<i>Holothuria leucospilota</i>	259	57	34	350
Total	700	200	100	1000

2.3. Pra-Pemrosesan dan Augmentasi Data

Tahap *preprocessing* dilakukan menggunakan Roboflow yang meliputi *Auto-Orient* untuk menyesuaikan orientasi citra serta perubahan ukuran citra menjadi 640×640 piksel. Setelah itu, augmentasi hanya diterapkan pada data latih menggunakan teknik *horizontal flip*, rotasi 90° searah dan berlawanan arah jarum jam, serta rotasi acak pada rentang -15° hingga $+15^\circ$. Tahapan ini bertujuan meningkatkan keragaman data pelatihan sehingga model memiliki kemampuan generalisasi yang lebih baik [2]. Setelah augmentasi, jumlah data latih meningkat dari 700 menjadi 2.094 citra sehingga total dataset yang digunakan dalam penelitian menjadi 2.394 citra.

2.4. Pelatihan Model YOLOv11n

Pelatihan model dilakukan menggunakan YOLOv11n yang diimplementasikan melalui pustaka Ultralytics pada platform Google Colab dengan dukungan GPU NVIDIA Tesla T4. Model dilatih menggunakan data latih hasil augmentasi selama 50 *epoch* dengan ukuran citra 640×640 piksel. Selama proses pelatihan, performa model dipantau menggunakan data validasi untuk memperoleh bobot terbaik (*best.pt*) berdasarkan nilai *mean Average Precision (mAP)* tertinggi [7], [14], [15].

Tabel 3. Parameter Pelatihan Model YOLOv11n

Parameter	Nilai
Model	YOLOv11n
Epoch	50
Image Size	640×640 piksel
Framework	Ultralytics YOLO
Platform	Google Colaboratory
GPU	Tesla T4

2.5. Evaluasi Model

Model terbaik selanjutnya dievaluasi menggunakan data uji yang tidak pernah digunakan pada tahap pelatihan maupun validasi. Evaluasi dilakukan menggunakan metrik *Precision*, *Recall*, *F1-Score*, *mean Average Precision* pada *Intersection over Union (IoU)* 0,5 (*mAP50*), serta *mAP50-95*, yang merupakan metrik standar dalam evaluasi model YOLO [12], [13]. Persamaan yang digunakan untuk menghitung *Precision*, *Recall*, dan *F1-Score* ditunjukkan pada Persamaan (1)-(3).

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

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

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

TP (True Positive) menyatakan jumlah prediksi benar pada objek target, *FP (False Positive)* jumlah prediksi positif yang salah, dan *FN (False Negative)* jumlah objek target yang tidak berhasil terdeteksi.

2.6. Implementasi Sistem

Model dengan performa terbaik diimplementasikan ke dalam aplikasi berbasis *web* menggunakan Gradio [16]. Sistem dirancang agar pengguna dapat mengunggah citra teripang, kemudian model melakukan proses inferensi secara otomatis dan menampilkan hasil klasifikasi, nilai *confidence*, serta informasi singkat mengenai spesies yang berhasil diidentifikasi. Implementasi ini bertujuan mempermudah penggunaan model tanpa memerlukan interaksi langsung dengan kode program.


3. HASIL DAN PEMBAHASAN

Hasil penelitian diawali dengan pemaparan proses pelatihan model menggunakan data latih hasil pra pemrosesan dan augmentasi, kemudian dilanjutkan dengan evaluasi performa model menggunakan data uji yang tidak terlibat pada proses pelatihan. Selanjutnya, dilakukan pembahasan terhadap hasil yang diperoleh serta implementasi model ke dalam sistem berbasis *web* menggunakan Gradio untuk menguji penerapan model dalam proses identifikasi spesies teripang.

3.1. Hasil Pelatihan Model

Pelatihan model dilakukan menggunakan YOLOv11n dengan dataset hasil *preprocessing* dan augmentasi yang berjumlah 2.394 citra. Proses pelatihan dilaksanakan selama 50 *epoch* menggunakan Google Colab dengan dukungan GPU NVIDIA Tesla T4. Selama proses pelatihan, model dipantau menggunakan data validasi untuk memperoleh bobot terbaik (*best.pt*) berdasarkan nilai *mean Average Precision* (*mAP*) tertinggi.

Gambar 2 menunjukkan hasil pelatihan model selama 50 *epoch*. Kurva *train loss* dan *validation loss* mengalami penurunan secara bertahap hingga mencapai kondisi yang stabil pada akhir pelatihan. Di sisi lain, nilai *Precision*, *Recall*, *mAP50*, dan *mAP50-95* meningkat secara bertahap seiring bertambahnya *epoch* sebelum akhirnya konvergen. Kondisi tersebut menunjukkan bahwa model mampu mempelajari karakteristik visual setiap spesies teripang dengan baik selama proses pelatihan.



Gambar 2. Hasil Pelatihan Model YOLOv11n

3.2. Hasil Evaluasi Model


Model terbaik (*best.pt*) yang diperoleh dari proses pelatihan selanjutnya dievaluasi menggunakan 100 citra data uji yang tidak pernah digunakan pada tahap pelatihan maupun validasi. Evaluasi dilakukan untuk mengukur kemampuan generalisasi model terhadap data baru menggunakan metrik *Precision*, *Recall*, *F1-Score*, *mAP50*, dan *mAP50-95*.

Tabel 4. Hasil Evaluasi Model YOLOv11n

Parameter	Nilai(%)
Precision	99,70
Recall	100,00
F1-Score	99,85
mAP50	99,50
mAP50-95	99,00

Berdasarkan Tabel 4, model memperoleh nilai *Precision* sebesar 99,70%, *Recall* sebesar 100,00%, *F1-Score* sebesar 99,85%, *mAP50* sebesar 99,50%, dan *mAP50-95* sebesar 99,00%. Nilai tersebut menunjukkan bahwa model mampu mengklasifikasikan ketiga spesies teripang dengan tingkat akurasi yang sangat tinggi.

Selain metrik evaluasi, performa model juga dianalisis menggunakan *confusion matrix* seperti ditunjukkan pada Gambar 3. Matriks tersebut memperlihatkan bahwa sebagian besar citra pada setiap kelas berhasil diklasifikasikan ke kelas yang benar dengan jumlah kesalahan klasifikasi yang sangat sedikit.



Gambar 3. *Confusion Matrix* Hasil Evaluasi Model

3.3. Pembahasan

Hasil penelitian menunjukkan bahwa model YOLOv11n mampu melakukan klasifikasi tiga spesies teripang, yaitu *Holothuria scabra*, *Holothuria atra*, dan *Holothuria leucospilota*, dengan performa yang sangat baik. Model memperoleh nilai Precision sebesar 99,70%, Recall sebesar 100,00%, F1-Score sebesar 99,85%, mAP50 sebesar 99,50%, dan mAP50-95 sebesar 99,00%. Nilai Precision yang tinggi menunjukkan bahwa hampir seluruh prediksi yang dihasilkan model sesuai dengan kelas sebenarnya, sedangkan nilai Recall sebesar 100,00% mengindikasikan bahwa seluruh objek pada data uji berhasil dikenali tanpa adanya objek yang terlewat.

Nilai F1-Score sebesar 99,85% menunjukkan keseimbangan yang sangat baik antara Precision dan Recall. Selain itu, nilai mAP50 sebesar 99,50% dan mAP50-95 sebesar 99,00% menunjukkan bahwa model tidak hanya mampu mengidentifikasi kelas objek dengan benar, tetapi juga menghasilkan lokalisasi *bounding box* yang akurat pada berbagai nilai *Intersection over Union* (IoU). Selisih yang relatif kecil antara mAP50 dan mAP50-95 menunjukkan bahwa performa model tetap konsisten meskipun dievaluasi menggunakan kriteria IoU yang lebih ketat, sehingga kemampuan deteksi dan klasifikasi model dapat dikatakan stabil.

Performa model yang tinggi dipengaruhi oleh beberapa faktor. Pertama, penggunaan dataset primer yang telah divalidasi oleh ahli memastikan bahwa setiap citra memiliki label yang benar sehingga kualitas data pelatihan tetap terjaga. Kedua, penerapan *preprocessing* dan augmentasi pada data latih meningkatkan variasi citra yang dipelajari model sehingga kemampuan generalisasi terhadap data baru berpotensi meningkatkan kemampuan generalisasi. Ketiga, penggunaan data validasi selama proses pelatihan untuk memilih bobot terbaik (*best.pt*) membantu memperoleh model dengan performa optimal tanpa hanya bergantung pada jumlah *epoch* pelatihan.

Hasil evaluasi juga menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah digunakan selama proses pelatihan. Hal ini ditunjukkan oleh tingginya nilai evaluasi pada data uji yang dipisahkan sejak awal penelitian menggunakan rasio 70:20:10 serta tidak pernah digunakan selama proses pelatihan maupun validasi. Perbedaan yang relatif kecil antara nilai mAP50 dan mAP50-95 menunjukkan bahwa model mampu mempertahankan performa yang konsisten meskipun dievaluasi menggunakan kriteria *Intersection over Union* (IoU) yang lebih ketat. Meskipun model memperoleh nilai Precision, Recall, dan mAP yang sangat tinggi, hasil tersebut tidak serta-merta menunjukkan bahwa model mengalami *overfitting*. Pemilihan model terbaik dilakukan berdasarkan performa pada data validasi menggunakan bobot *best.pt*, bukan berdasarkan


performa data latih, sehingga evaluasi pada data uji memberikan gambaran yang lebih objektif terhadap kemampuan model. Namun demikian, karena data uji masih berasal dari distribusi dataset yang sama dengan data pelatihan, kemampuan generalisasi model terhadap dataset dari lokasi atau kondisi perairan yang berbeda masih perlu dievaluasi lebih lanjut pada penelitian selanjutnya.

Jika dibandingkan dengan penelitian Chu *et al.* [8], Ge *et al.* [9], Luo *et al.* [10], dan Yi *et al.* [11], penelitian ini menunjukkan bahwa YOLOv11 juga mampu memberikan performa yang tinggi pada objek bawah air. Namun demikian, penelitian-penelitian tersebut lebih berfokus pada deteksi objek, pelacakan perilaku, atau pengembangan arsitektur deteksi untuk lingkungan bawah air, sedangkan penelitian ini menitikberatkan pada klasifikasi tiga spesies teripang menggunakan dataset primer yang diperoleh langsung dari perairan Indonesia. Dengan demikian, penelitian ini memberikan kontribusi yang berbeda, yaitu menunjukkan bahwa YOLOv11 tidak hanya efektif untuk deteksi objek bawah air, tetapi juga mampu dimanfaatkan untuk klasifikasi spesies berdasarkan karakteristik morfologi pada citra digital.

Meskipun menghasilkan performa yang sangat baik, penelitian ini masih memiliki beberapa keterbatasan. Dataset yang digunakan hanya mencakup tiga spesies teripang, yaitu *Holothuria scabra*, *Holothuria atra*, dan *Holothuria leucospilota*, sehingga kemampuan model untuk mengklasifikasikan spesies teripang lainnya belum dapat dievaluasi. Selain itu, seluruh citra diperoleh dari wilayah perairan Desa Serei dan Desa Paputungan dengan kondisi pengambilan citra yang relatif seragam, baik dari segi pencahayaan maupun lingkungan perairan. Kondisi tersebut memungkinkan model mempelajari karakteristik visual yang spesifik terhadap dataset yang digunakan, sehingga kemampuan generalisasi model pada citra yang berasal dari lokasi berbeda atau memiliki kondisi lingkungan yang lebih bervariasi, seperti tingkat kekeruhan yang tinggi, pencahayaan rendah, atau latar belakang yang lebih kompleks, masih perlu dikaji lebih lanjut. Oleh karena itu, penelitian selanjutnya perlu menggunakan dataset yang lebih beragam dari sisi jumlah spesies, lokasi pengambilan citra, dan kondisi lingkungan perairan agar kemampuan generalisasi model dapat dievaluasi secara lebih komprehensif.

3.4. Implementasi Sistem


Model dengan performa terbaik selanjutnya diimplementasikan ke dalam aplikasi berbasis *web* menggunakan Gradio [16]. Implementasi ini bertujuan menyediakan antarmuka yang memungkinkan pengguna melakukan identifikasi spesies teripang tanpa harus berinteraksi langsung dengan kode program. Sistem dirancang agar pengguna dapat mengunggah citra teripang, kemudian model melakukan proses inferensi secara otomatis dan menampilkan hasil identifikasi beserta informasi mengenai spesies yang terdeteksi.



Gambar 4. Tampilan Antarmuka Sistem Berbasis Gradio

Gambar 4 menunjukkan antarmuka sistem identifikasi spesies teripang yang dibangun menggunakan Gradio. Antarmuka dirancang sederhana agar pengguna dapat mengunggah citra

teripang, menjalankan proses identifikasi, serta melihat hasil klasifikasi dan informasi spesies secara langsung melalui satu halaman.



Gambar 5. Contoh Hasil Inferensi Sistem

Gambar 5 memperlihatkan contoh hasil inferensi sistem terhadap citra *Holothuria atra*. Model berhasil mengidentifikasi objek dengan memberikan *bounding box*, nama spesies, nilai *confidence*, serta informasi singkat mengenai spesies yang terdeteksi. Hasil tersebut menunjukkan bahwa model mampu diimplementasikan ke dalam sistem berbasis *web* dan memberikan keluaran identifikasi yang dapat dilihat secara langsung oleh pengguna melalui antarmuka sistem.

Untuk memastikan implementasi sistem tidak hanya dapat menampilkan antarmuka dan hasil inferensi, dilakukan pengujian fungsional terhadap fitur utama sistem. Pengujian mencakup proses unggah citra, pelaksanaan inferensi menggunakan model YOLOv11n, penampilan *bounding box* dan nama spesies, penampilan nilai *confidence*, serta penyajian informasi mengenai spesies yang terdeteksi. Hasil pengujian menunjukkan bahwa seluruh fungsi utama tersebut dapat dijalankan sesuai dengan rancangan, sehingga sistem telah memenuhi fungsi dasar sebagai aplikasi identifikasi spesies teripang berbasis citra.

Tabel 5. Hasil Pengujian Fungsional Sistem

No.	Fitur yang Diuji	Hasil yang Diharapkan	Hasil Pengujian
1.	Unggah citra	Citra berhasil dimasukkan ke sistem	Berhasil
2.	Proses inferensi	Model melakukan deteksi dan klasifikasi	Berhasil
3.	<i>Bounding box</i>	Objek terdeteksi ditandai <i>bounding box</i>	Berhasil
4.	Nama spesies	Nama spesies hasil klasifikasi ditampilkan	Berhasil
5.	Nilai <i>confidence</i>	Nilai <i>confidence</i> ditampilkan	Berhasil
6.	Informasi spesies	Informasi spesies hasil identifikasi ditampilkan	Berhasil

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi tiga spesies teripang, yaitu *Holothuria scabra*, *Holothuria atra*, dan *Holothuria leucospilota*, menggunakan YOLOv11 berdasarkan citra digital. Model yang dihasilkan menunjukkan performa yang sangat baik dengan memperoleh nilai Precision sebesar 99,70%, Recall 100,00%, F1-Score 99,85%, mAP50 99,50%, dan mAP50-95 99,00% pada data uji. Hasil tersebut menunjukkan bahwa YOLOv11 mampu mempelajari karakteristik visual masing-masing spesies secara efektif sehingga berpotensi digunakan sebagai pendukung identifikasi spesies teripang berbasis citra digital. Model terbaik juga berhasil diintegrasikan ke dalam sistem berbasis web menggunakan Gradio, sedangkan pengujian fungsional menunjukkan bahwa fitur utama sistem, meliputi unggah citra, proses inferensi, penampilan *bounding box*, nama spesies, nilai *confidence*, dan informasi spesies, dapat berjalan sesuai dengan rancangan.

Penelitian ini masih memiliki keterbatasan karena hanya menggunakan tiga spesies teripang dengan dataset primer yang diperoleh dari wilayah perairan Desa Serei dan Desa Paputungan. Kondisi pengambilan citra dan lingkungan perairan yang digunakan juga masih terbatas sehingga kemampuan model pada kondisi yang lebih kompleks, seperti tingkat kekeruhan tinggi, pencahayaan rendah, latar belakang yang lebih kompleks, serta lokasi perairan yang berbeda, belum dapat diketahui secara menyeluruh. Selain itu, penelitian ini belum melakukan *usability testing* yang melibatkan pengguna akhir untuk mengevaluasi kemudahan penggunaan sistem. Oleh karena itu, penelitian selanjutnya

disarankan untuk menggunakan dataset yang lebih besar dan beragam, melibatkan lebih banyak spesies dan lokasi pengambilan citra, menguji model pada berbagai kondisi lingkungan bawah air, serta melakukan *usability testing* untuk mengevaluasi aspek kemudahan penggunaan dan pengalaman pengguna terhadap sistem yang dikembangkan.

REFERENCES

- [1] S. W. Purcell, A. Lovatelli, M. González-Wangüemert, F. A. Solís-Marín, Y. Samyn, and C. Conand, *Commercially important sea cucumbers of the world – Second edition*. FAO Species Catalogue for Fishery Purposes, 2023.
- [2] S. Bordbar, F. Anwar, and N. Saari, "High-value components and bioactives from sea cucumbers for functional foods - A review," 2011, MDPI AG. doi: 10.3390/md9101761.
- [3] A. Setyastuti, I. Wirawati, S. Permadi, and I. B. Vimono, *Jenis, Sebaran, dan Status Nilai Ekonomi TERIPANG INDONESIA*. Jakarta: PT. Media Sains Nasional, 2019.
- [4] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. The MIT Press, 2016.
- [5] D. A. Roberts, S. Yaida, and B. Hanin, "The Principles of Deep Learning Theory," Aug. 2021, doi: 10.1017/9781009023405.
- [6] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, May 2016, [Online]. Available: <http://arxiv.org/abs/1506.02640>
- [7] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," Oct. 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>
- [8] C. Chu, Y.-F. Gu, A. Wong, and B. D. Russell, "Automated detection of sea cucumbers in turbid subtidal marine habitats: an explainable approach," 2024. [Online]. Available: <https://ssrn.com/abstract=5110525>
- [9] F. Ge *et al.*, "Multi-object detection and behavior tracking of sea cucumbers with skin ulceration syndrome based on deep learning," *Front. Mar. Sci.*, vol. 11, 2024, doi: 10.3389/fmars.2024.1365155.
- [10] Y. Luo, A. Wu, and Q. Fu, "MAS-YOLOv11: An Improved Underwater Object Detection Algorithm Based on YOLOv11," *Sensors*, vol. 25, no. 11, Jun. 2025, doi: 10.3390/s25113433.
- [11] W. Yi, X. Yu, and L. Yan, "YOLO11-AquaDetect: High-Precision Lightweight Framework for Underwater Biological Detection," *Engineering Letters*, vol. 34, no. 1, pp. 393–405, Jan. 2026.
- [12] 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 (Switzerland)*, vol. 10, no. 3, pp. 1–28, Feb. 2021, doi: 10.3390/electronics10030279.
- [13] Ultralytics, "Ultralytics Metrics Documentation." Accessed: Jul. 19, 2026. [Online]. Available: <https://docs.ultralytics.com/reference/utils/metrics?>
- [14] Ultralytics, "Configuration." Accessed: Jul. 19, 2026. [Online]. Available: <https://docs.ultralytics.com/usage/cfg>
- [15] T. Carneiro, R. V. M. Da Nobrega, T. Nepomuceno, G. Bin Bian, V. H. C. De Albuquerque, and P. P. R. Filho, "Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications," *IEEE Access*, vol. 6, pp. 61677–61685, 2018, doi: 10.1109/ACCESS.2018.2874767.
- [16] A. Abid, A. Abdalla, A. Abid, D. Khan, A. Alfozan, and J. Zou, "Gradio: Hassle-Free Sharing and Testing of ML Models in the Wild," Jun. 2019, [Online]. Available: <http://arxiv.org/abs/1906.02569>