

Implementasi YOLOv11 untuk Deteksi Multi-Objek Kesegaran Ikan Cakalang Beku

1st Annenta Gistya Sudiartama
 Fakultas Teknik Elektro
 Universitas Telkom
 Bandung, Indonesia
 ORCID : 0009-0005-7342-9013S

2nd Dehani Nurkemala Hidayat
 Fakultas Teknik Elektro
 Universitas Telkom
 Bandung, Indonesia
 ORCID : 0009-0003-2521-6713

3rd Ledy Novamizanti
 Fakultas Teknik Elektro
 Universitas Telkom
 Bandung, Indonesia
 ledyaldn@telkomuniversity.ac.id

4rd Suryo Adhi Wibowo
 Fakultas Teknik Elektro
 Universitas Telkom
 Bandung, Indonesia
 suryoadhiwibowo@telkomuniversity.ac.id

Memastikan kesegaran ikan merupakan tantangan penting dalam industri perikanan modern, terutama untuk komoditas bernilai tinggi seperti Cakalang. Makalah ini mengusulkan sistem deteksi multi-objek secara real-time menggunakan model YOLOv11 khusus untuk secara otomatis mengklasifikasikan kualitas kesegaran ikan Cakalang (Katsuwonus pelamis) beku dan tidak beku. Tiga varian YOLOv11, yaitu YOLOv11S, YOLOv11M, dan YOLOv11L, dilatih dan divalidasi pada set data gambar yang telah dianotasi. YOLOv11S mencapai akurasi pengujian sebesar 88,4%, akurasi validasi sebesar 90,1%, dan akurasi pelatihan sebesar 88,4%. YOLOv11M mencapai kinerja yang lebih tinggi, dengan akurasi pengujian 92,9%, akurasi validasi 94,8%, dan akurasi pelatihan 85,7%. Hasil terbaik diperoleh dari YOLOv11L, yang mencapai akurasi pengujian sebesar 91,5%, akurasi validasi 94,9%, dan akurasi pelatihan 83,7%. Temuan ini menunjukkan bahwa YOLOv11L menawarkan kinerja tertinggi, sementara YOLOv11M dan YOLOv11S juga menunjukkan hasil yang kompetitif. Pendekatan berbasis YOLOv11 yang diusulkan menunjukkan potensi deteksi kesegaran ikan secara real-time dalam sistem kontrol kualitas otomatis, yang bertujuan untuk mengurangi kerugian pascapanen dan meningkatkan daya saing produk makanan laut Indonesia di tingkat global.

Kata Kunci-YOLOv11, pembelajaran mendalam, deteksi objek, waktu nyata, kesegaran ikan

I. PENDAHULUAN

Produk perikanan merupakan salah satu sumber makanan utama di Indonesia dengan tingkat konsumsi yang tinggi. Di antara berbagai jenis ikan yang dikonsumsi, Cakalang (Katsuwonus pelamis) merupakan salah satu komoditas utama yang memiliki permintaan tinggi baik di pasar domestik maupun pasar global [1]. Keberlanjutan produksi cakalang dan kualitas produknya sangat berpengaruh terhadap daya saing industri perikanan Indonesia di kancah internasional. Namun, tantangan utama yang dihadapi dalam rantai distribusi cakalang adalah hilangnya kesegaran akibat penanganan yang tidak tepat selama transportasi dan penyimpanan [2]. Penurunan kesegaran ini dapat mempengaruhi kualitas organoleptik, keamanan pangan, dan nilai ekonomi ikan di pasaran. Oleh karena itu, diperlukan sistem deteksi yang handal dan efisien untuk

mengklasifikasikan tingkat kesegaran ikan secara akurat agar kualitas produk tetap terjaga.

Dalam beberapa tahun terakhir, metode machine learning (ML) telah banyak diterapkan dalam industri perikanan, khususnya dalam deteksi dan klasifikasi objek berdasarkan citra digital. Teknologi ini menawarkan kemampuan analisis yang lebih akurat dengan preprocessing gambar dan ekstraksi fitur yang minimal [3]. Salah satu pendekatan yang paling banyak dikembangkan adalah deep learning (DL), yang memungkinkan pemrosesan end-to-end tanpa memerlukan ekstraksi fitur secara manual. Salah satu teknik yang paling banyak digunakan dalam pendekatan objek adalah You Only Look Once (YOLO), sebuah algoritma yang pertama kali diperkenalkan oleh Redmon dkk. (2015). YOLO dapat mendekati dan mengklasifikasikan objek secara real-time secara efisien dengan menggabungkan proses region proposal dan klasifikasi ke dalam sebuah convolutional neural network (CNN) [4].

Beberapa penelitian telah mengeksplorasi implementasi YOLO di sektor perikanan, khususnya dalam klasifikasi spesies ikan dan deteksi kesegaran ikan berdasarkan citra digital. Model YOLO telah diaplikasikan dalam berbagai penelitian untuk menilai kondisi ikan berdasarkan karakteristik visual seperti warna, tekstur, serta tingkat kecerahan mata dan insang [5]. Pada penelitian sebelumnya, YOLOv8 berhasil digunakan dalam sistem klasifikasi kesegaran ikan dengan akurasi pelatihan dan pengujian yang tinggi. Hasil ini menunjukkan bahwa pendekatan berbasis deep learning dapat secara efektif meningkatkan akurasi dalam menentukan kesegaran ikan [6]. Sejalan dengan perkembangan teknologi pendekatan objek, YOLOv11 dikembangkan sebagai versi terbaru dengan peningkatan akurasi dan efisiensi komputasi dibandingkan dengan versi sebelumnya.

Untuk menjawab tantangan tersebut, penelitian ini mengusulkan perancangan sistem pendeksi objek dengan menggunakan metode You Only Look Once (YOLO). Penelitian ini membandingkan beberapa varian model YOLOv11 diantaranya: Model YOLOv11S, YOLOv11M, dan YOLOv11L dipilih berdasarkan keefektifannya dalam mengidentifikasi tingkat kesegaran ikan Cakalang secara akurat. Penelitian ini menganalisis bagaimana perbedaan di

antara model-model ini memengaruhi kinerja dalam mendeteksi kesegaran ikan. YOLO menggunakan konsep pengenalan objek dengan terlebih dahulu melatih gambar beranotasi untuk menghasilkan bobot model, diikuti dengan klasifikasi kesegaran tuna melalui analisis gambar digital [7]. Dengan memanfaatkan arsitektur YOLOV11, penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi kesegaran ikan dan mendukung industri perikanan dalam menjaga kualitas produk secara lebih efisien. Selain itu, temuan ini juga diharapkan dapat menjadi referensi untuk pengembangan sistem berbasis AI di sektor perikanan, membantu memastikan kualitas produk dan memperkuat daya saing di pasar global [8]. Penelitian ini juga mendorong integrasi teknologi pembelajaran mesin dan pembelajaran mendalam dalam industri perikanan. Dengan mengimplementasikan YOLOV11, ia memberikan solusi otomatis yang andal untuk klasifikasi kesegaran ikan secara real-time, sehingga mengurangi kerugian pascapanen [9]. Kemajuan ini memiliki potensi untuk meningkatkan kontrol kualitas di seluruh rantai pasokan, memastikan produk yang lebih segar bagi konsumen dan meningkatkan posisi Indonesia di pasar makanan laut global.

II. METODOLOGI

Metode yang diusulkan untuk mendeteksi kesegaran beberapa cakalang beku melibatkan dua tahap inti: prapemrosesan data dan pembelajaran mendalam dengan model YOLOv11. Gambar 1 menunjukkan arsitektur sistem yang digunakan untuk evaluasi kualitas cakalang.



GAMBAR 1.
Diagram proses evaluasi kualitas cakalang

1) Akuisisi Citra

Pada penelitian ini, akuisisi citra dilakukan sebagai tahap awal untuk mendapatkan data visual ikan cakalang beku. Gambar diambil menggunakan perangkat pencitraan digital dalam kondisi pencahayaan yang terkendali untuk meminimalkan gangguan visual dan menjaga konsistensi antar sampel. Proses ini bertujuan untuk mengekstrak karakteristik visual seperti kejernihan mata, tekstur kulit, dan warna tubuh, yang merupakan indikator penting dari kesegaran ikan. Gambar yang diperoleh berfungsi sebagai masukan utama untuk analisis dan klasifikasi lebih lanjut. Memastikan akuisisi gambar berkualitas tinggi sangat penting untuk mengoptimalkan kinerja model pembelajaran mendalam dalam tugas pendekripsi objek secara real-time.

2) Preprocessing

Dalam penelitian ini, tahap prapemrosesan data melibatkan beberapa langkah penting untuk menyiapkan dataset dan input gambar untuk melatih model YOLOv11. Pada awalnya, koreksi orientasi otomatis dilakukan untuk memastikan keselarasan gambar yang konsisten dan menghilangkan distorsi rotasi yang tidak disengaja yang dapat mengganggu proses pembelajaran model. Hal ini diikuti dengan langkah pengubahan ukuran untuk menyatukan semua dimensi gambar pada 640×640 piksel, untuk memastikan pemrosesan yang konsisten dan dioptimalkan oleh model.

Operasi pra-pemrosesan ini secara signifikan berkontribusi dalam mengoptimalkan fase pelatihan, sehingga memungkinkan model YOLOv11 untuk

mempelajari fitur-fitur pembeda yang terkait dengan kesegaran cakalang secara lebih efektif. Untuk meningkatkan keragaman dataset dan mengatasi kelangkaan data, beberapa strategi augmentasi data digunakan, termasuk pembalikan horizontal dan vertikal, rotasi 90° (searah jarum jam, berlawanan arah jarum jam, dan terbalik), serta rotasi acak dalam kisaran -15° hingga $+15^\circ$. Selain itu, penyesuaian saturasi mulai dari -60% hingga $+60\%$ dan modifikasi kecerahan antara -20% dan $+20\%$ juga diperkenalkan [10].

Peningkatan keragaman visual dalam dataset melalui teknik augmentasi dapat memperkuat peningkatan ketangguhan dan generalisasi model. Hasilnya, dataset akhir terdiri dari 643 gambar, yang terdiri dari 399 gambar yang diberi label "segar" dan 304 gambar yang diberi label "tidak segar".

3) Model YOLOV11

YOLO telah berkembang secara signifikan sejak diperkenalkan oleh Redmon dkk. (2016) sebagai YOLOv1. YOLO telah mengalami beberapa iterasi, yang berpuncak pada YOLOv8 oleh Ultralytics pada tahun 2023. Peningkatan utama termasuk peningkatan pada tulang punggung, adopsi deteksi bebas jangkar, dan dukungan untuk aplikasi waktu nyata. Dalam penelitian ini, YOLOv8 digunakan sebagai dasar dan disebut sebagai YOLOv11. Penelitian sebelumnya telah menunjukkan keefektifan YOLO untuk deteksi kesegaran ikan [5], menyoroti potensinya dalam kontrol kualitas perikanan. Dataset benchmark seperti COCO dan PASCAL VOC biasanya digunakan untuk evaluasi, sementara ImageNet mendukung prapelatihan dalam pembelajaran transfer. Roboflow digunakan untuk anotasi dan augmentasi data untuk meningkatkan keragaman visual dalam dataset gambar ikan [16].

YOLOv11 adalah model pembelajaran mendalam yang dirancang untuk deteksi objek berkecepatan tinggi dengan akurasi tinggi. Model ini menggabungkan lokalisasi dan klasifikasi dalam CNN satu tahap, sehingga memungkinkan pemrosesan waktu nyata dengan biaya komputasi yang rendah. Model ini dilatih menggunakan gambar ikan cakalang yang diberi label, yang dilabeli ke dalam dua kategori: "segar" dan "tidak segar". Dengan mengekstraksi fitur spasial dan semantik, YOLOv11 dapat mendeteksi beberapa contoh ikan dan mengklasifikasikan kesegarannya dalam sekali proses. Desainnya menyeimbangkan efisiensi dan akurasi, sehingga cocok untuk penerapan industri dalam sistem kontrol kualitas ikan.

4) Klasifikasi

Tahap akhir dari sistem ini mengklasifikasikan ikan yang terdeteksi berdasarkan kesegarannya. Setelah deteksi dan ekstraksi fitur, YOLOv11 menempatkan setiap ikan ke dalam kategori "segar" atau "tidak segar". Hasilnya ditampilkan dengan kotak pembatas berlabel pada gambar input, memberikan output yang jelas dan dapat diinterpretasikan. Klasifikasi ini dilakukan secara real time untuk mendukung penyortiran otomatis dan pemantauan kualitas. Dengan mengotomatiskan proses, sistem ini mengurangi subjektivitas, menurunkan risiko kesalahan manusia, dan meningkatkan konsistensi dalam evaluasi kesegaran di seluruh rantai pasokan makanan laut.

A. Kumpulan Data

Dataset yang digunakan untuk evaluasi dibagi menjadi tiga kategori, Pelatihan, Validasi, dan Pengujian, masing-

masing berisi dua kelas, "segar" dan "tidak segar". Data didistribusikan di seluruh subset ini untuk memastikan representasi yang seimbang dari kedua kelas, yang akan mendukung evaluasi model yang komprehensif. Bagian berikut ini akan memberikan rincian lebih lanjut tentang jumlah yang tepat untuk setiap subset.

TABEL 1
DESKRIPSI DATA

No	Kelas	Pelatihan	Validasi	Tes	Total
1	segar	580	70	77	727
2	tidak segar	580	70	77	727
	Total	1.160	140	154	1454

Untuk memastikan keragaman dan kualitas data yang optimal, set data yang ditunjukkan pada Tabel I, yang digunakan dalam penelitian ini terdiri dari gambar cakalang yang dikategorikan ke dalam: "segar" dan "tidak segar". Dataset ini terdiri dari 1454 gambar, dibagi menjadi tiga subset: 1160 gambar untuk pelatihan, 140 gambar untuk validasi, dan 154 gambar untuk pengujian. Secara khusus, kelas "segar" terdiri dari 580 gambar di subset pelatihan, 70 gambar di subset validasi, dan 77 gambar di subset pengujian, dengan total 727 gambar. Kelas "tidak segar" memiliki distribusi yang sama, dengan 580 gambar di subset pelatihan, 70 gambar di subset validasi, dan 77 gambar di subset pengujian, yang juga berjumlah 727 gambar. Distribusi data ini memastikan representasi yang seimbang dari kedua kelas pada fase pengujian model deteksi kesegaran ikan.

Kumpulan data yang digunakan dalam penelitian ini dikumpulkan dari berbagai sumber yang dapat diandalkan, seperti organisasi industri perikanan dan platform online terkemuka. Proses seleksi ini bertujuan untuk memastikan kualitas dan relevansi data untuk menilai kesegaran ikan Cakalang. Dengan menggabungkan gambar dari berbagai sumber, termasuk menampilkan perbedaan pencahaayaan, perspektif kamera, dan kondisi fisik ikan, kumpulan data dibuat lebih beragam, sehingga meningkatkan ketahanan proses pelatihan. Keragaman tersebut tidak hanya memperluas distribusi sampel visual yang tersedia untuk model, tetapi juga memungkinkan arsitektur YOLOv11 untuk belajar dari spektrum citra ikan yang komprehensif [11]. Hasilnya, model ini mendapatkan kemampuan generalisasi yang lebih baik ketika diterapkan pada data dunia nyata dan menunjukkan ketahanan yang lebih besar terhadap variasi kontekstual, seperti perubahan lingkungan atau perbedaan perangkat pencitraan. Pendekatan ini diharapkan dapat menghasilkan sistem deteksi yang adaptif dan dapat diandalkan untuk implementasi praktis dalam industri perikanan.

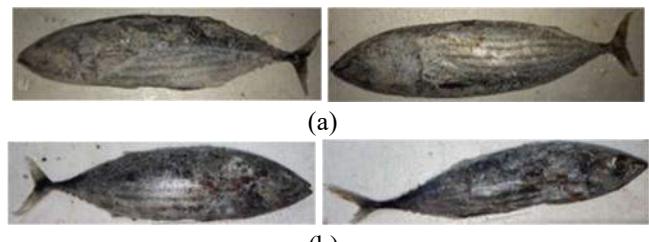
Bagian selanjutnya menguraikan metodologi persiapan dataset, yang meliputi pemilihan gambar, pra-pemrosesan data, dan pembagian data ke dalam subset pelatihan, validasi, dan pengujian. Pendekatan komprehensif ini memungkinkan penilaian yang terstruktur dan mendalam terhadap kinerja model YOLOv11 dalam mengidentifikasi kesegaran cakalang.

B. Pengumpulan Gambar

Dalam penelitian ini, set data yang terdiri dari 1.454 gambar ikan Cakalang yang diklasifikasikan ke dalam dua kategori: "segar" dan "tidak segar". Tabel II menyoroti karakteristik utama yang membedakan ikan segar dan tidak segar, seperti yang dilustrasikan pada Gambar 2.

TABLE 2
KARAKTERISTIK KESEGARAN IKAN

Kelas	Karakteristik
Beku dan segar	Mata agak buram, kulit kusam dengan sedikit bersinar, dan tekstur kulit kaku.
Beku dan tidak segar	Mata tidak jelas, kulit pucat keabu-abuan, dan tubuh yang sedikit rapuh.



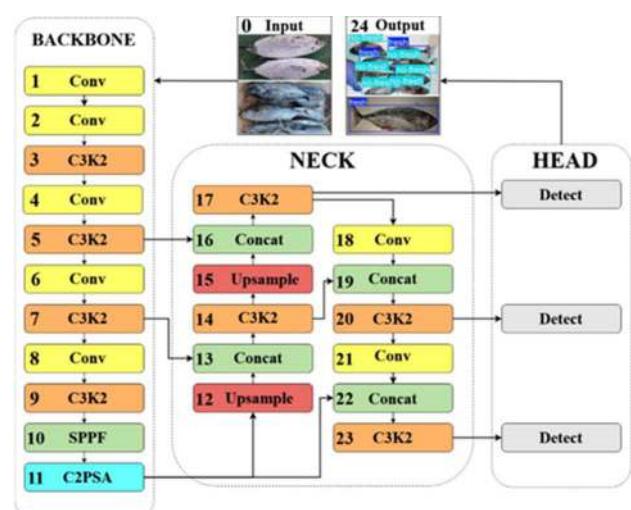
GAMBAR 2.

Sampel ikan Cakalang (a) Beku segar, (b) Beku tidak segar

C. YOLOV11 (Varian Khusus dari YOLOV11)

Istilah "YOLOv11" yang digunakan dalam penelitian ini mengacu pada implementasi dengan nama khusus dari kerangka kerja pendekripsi objek YOLOv8 resmi yang dikembangkan oleh Ultralytics [12]. Model YOLO (You Only Look Once) terkenal dengan kemampuan deteksi objek secara real-time, yang menggabungkan klasifikasi dan pelokalan dalam satu kali proses. Meskipun belum ada rilis resmi dari versi YOLOv11 pada saat tulisan ini dibuat, konvensi penamaan "YOLOv11" digunakan secara internal dalam penelitian ini untuk membedakan antara konfigurasi eksperimental model YOLOv8 (YOLOv8s, YOLOv8m, dan YOLOv8l), yang kemudian disebut sebagai YOLOv11s, YOLOv11M, dan YOLOv11L untuk memudahkan.

Dalam penelitian ini, varian YOLOv11 digunakan untuk mengklasifikasikan kesegaran ikan Cakalang, dengan memanfaatkan kemampuan YOLO dalam mengekstrak fitur spasial seperti kejernihan mata, tekstur kulit, dan kondisi tubuh [13]. Model-model tersebut dilatih dengan gambar-gambar beranotasi dari tuna yang "segar" dan "tidak segar", sehingga memungkinkan mereka untuk mendekripsi pola-pola visual yang relevan dan membedakan tingkat kesegaran secara efektif. Pendekatan ini bertujuan untuk mendukung sistem pemeriksaan otomatis secara real-time di industri makanan laut.



GAMBAR 3
Arsitektur YOLOv11

Arsitektur YOLOv11 yang diusulkan (Gambar. 3) dikembangkan berdasarkan kerangka kerja YOLOv8 dengan beberapa modul khusus untuk meningkatkan kinerja deteksi. Tulang punggung mengintegrasikan modul C2PSA (Blok 11), yang menerapkan perhatian saluran dan spasial untuk meningkatkan ekstraksi fitur, terutama untuk detail halus seperti kejernihan mata dan tekstur kulit.

Struktur NECK menggunakan lapisan konvolusi (C3K2, Conv), upsampling, dan penggabungan untuk menangkap fitur multi-skala. HEAD tetap mirip dengan YOLO asli, terdiri dari tiga lapisan deteksi untuk resolusi yang berbeda.

Arsitektur ini menyeimbangkan efisiensi dan akurasi. Metrik evaluasi standar termasuk presisi, recall, skor F1, dan mAP, menunjukkan kemampuannya untuk mendeteksi perbedaan visual yang halus dalam kesegaran ikan. Namun, variasi pencahayaan dan kualitas gambar masih mempengaruhi konsistensi kinerja.

D. Matriks Evaluasi

Untuk memastikan klasifikasi kesegaran ikan Cakalang yang akurat, sebuah matriks evaluasi secara sistematis mengukur kinerja YOLOV11. Matriks ini menilai presisi, recall, spesifitas, F1-score, dan mAP@50 untuk membedakan tuna segar dan tidak segar berdasarkan kejernihan mata, tekstur kulit, dan kondisi tubuh. Terinspirasi oleh studi deteksi fruitlet berbasis YOLO, evaluasi ini juga mempertimbangkan kecepatan inferensi waktu nyata dan efisiensi model untuk kontrol kualitas perikanan yang praktis. Menerapkan matriks ini dapat meningkatkan akurasi deteksi, meminimalkan kerugian pascapanen, dan meningkatkan manajemen rantai pasokan makanan laut [14].

1) Akurasi

Akurasi menunjukkan tingkat keberhasilan model dalam menghasilkan prediksi yang benar, dihitung sebagai persentase prediksi yang benar relatif terhadap jumlah total prediksi True Positive (TP) terjadi ketika prediksi positif sesuai dengan hasil aktual, sedangkan True Negative (TN) terjadi ketika prediksi negatif benar. False Positive (FP) mengacu pada prediksi positif yang salah, dan False Negative (FN) mengacu pada prediksi negatif yang salah. Keempat metrik ini digunakan untuk mengevaluasi kinerja akurasi model.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

2) Presisi

Precision mengukur seberapa akurat prediksi positif model, atau persentase prediksi positif yang benar dibandingkan dengan semua prediksi positif yang dibuat.

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

3) Recall

Recall mengukur seberapa baik model mengidentifikasi semua contoh positif yang sebenarnya. Ini menunjukkan persentase prediksi positif yang benar dari semua titik data positif yang sebenarnya.

$$\text{Recall} = \frac{TP+T}{TP+TN+FP+FN} \quad (3)$$

4) Spesifitas

Spesifitas adalah kebalikan dari recall, mengukur seberapa baik model mendeteksi contoh negatif yang benar,

atau kemampuan model untuk mengenali contoh negatif secara akurat.

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (4)$$

5) F1-Skor

F1-Skor adalah metrik gabungan dari presisi dan recall, yang sering digunakan ketika ada kebutuhan untuk menyeimbangkan keduanya. Ini adalah rata-rata harmonis dari presisi dan recall, memberikan ukuran yang seimbang dari kedua metrik tersebut.

$$F1 - Score = 2 \times \frac{\text{Precision} + \text{Recall}}{\text{Precision} + \text{Recall}} = \frac{2TP}{2TP + FP + FN} \quad (5)$$

6) mAP

mAP adalah metrik yang mengevaluasi seberapa baik model mendeteksi objek atau melakukan tugas klasifikasi. Nilai ini menunjukkan metrik presisi rata-rata yang dievaluasi untuk semua kelas objek dalam dataset yang digunakan. mAP menggabungkan presisi dan recall pada berbagai nilai ambang batas, menawarkan ukuran kinerja yang lebih komprehensif.

$$mAP = \frac{1}{N} \sum_{i=1}^N \text{Precision}_i \quad (6)$$

Model YOLOV11 mengevaluasi kesegaran ikan Cakalang menggunakan metrik utama. Akurasi Deteksi mengukur klasifikasi yang benar, sementara Presisi memastikan tuna segar yang terdeteksi benar-benar segar [15]. Recall menangkap semua sampel segar, Spesifitas mencegah kesalahan klasifikasi tuna yang tidak segar, dan skor F1 menggabungkan nilai presisi dan recall untuk menghasilkan ukuran evaluasi yang seimbang di antara keduanya [16]. Metrik ini meningkatkan kontrol kualitas makanan laut secara otomatis, meningkatkan penilaian kesegaran dan mengurangi kerugian pascapanen.

Selain itu, pelabelan yang tepat pada dataset sangat penting untuk membedakan dengan jelas antara kategori "segar" dan "tidak segar" [17]. Pelabelan yang akurat membentuk fondasi untuk membuat model pembelajaran mesin yang diawasi melalui pelatihan seperti YOLOV11, memberikan kebenaran dasar yang digunakan model untuk belajar dan membuat prediksi yang andal. Proses anotasi yang mendetail ini memperkuat pemahaman model dan mendukung kinerjanya dalam tugas-tugas klasifikasi di masa depan [18].

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian dan evaluasi kinerja model YOLOV11 dalam deteksi waktu nyata kesegaran ikan cakalang. Performa model ini dinilai dimulai dengan menggunakan beberapa indikator utama, termasuk Precision, Recall, F1 Score, Mean Average Precision (mAP@0.5 dan mAP@0.95), dan waktu inferensi. Selain itu, analisis kualitatif berdasarkan gambar uji disediakan untuk menggambarkan akurasi deteksi model secara visual.

A. Pelatihan Model

Bagian ini menguraikan proses pelatihan YOLOv11 untuk klasifikasi kesegaran ikan, dengan fokus pada hiperparameter utama yang ditunjukkan pada Tabel III, termasuk laju pembelajaran, pengoptimalkan, fungsi aktivasi, epoch, ukuran batch, dan ukuran gambar. Nilai-nilai ini dipilih untuk mengoptimalkan model kinerja dan efisiensi pelatihan.

TABEL 3
HYPERPARAMETER UNTUK PELATIHAN MODEL

Parameter	Nilai
Fungsi Aktivasi	Mish
Pengoptimisasi	AdamW
Tingkat Pembelajaran	0.001667
Zaman	100
Ukuran Batch	16
Ukuran Gambar	640×640 piksel

Pelatihan dilakukan menggunakan pytorch 2.1 (Ultralytics YOLO) di Google Colab Pro dengan GPU NVIDIA Tesla T4. Rata-rata pelatihan waktu per model adalah sekitar 2,5 jam. Anotasi dataset dilakukan dengan menggunakan Roboflow dan di ekspor dalam format YOLO (TXT).

B. Analisis Kinerja Pelatihan

Proses pelatihan model YOLOv11 menunjukkan pembelajaran yang efektif dan stabil, yang dibuktikan dengan penurunan yang konsisten pada nilai kerugian pelatihan dan validasi di seluruh epoch. Tren ini mengindikasikan bahwa model ini mampu meminimalkan kesalahan prediksi sekaligus menghindari overfitting yang signifikan secara progresif. Di antara yang dievaluasi YOLOv11 menunjukkan perilaku konvergensi yang unggul, mencapai nilai kerugian yang lebih rendah dalam epoch yang lebih sedikit dan mempertahankan stabilitas pelatihan selama proses berlangsung [19]. Lebih jauh lagi, metrik rata-rata Average Precision (mAP) menunjukkan peningkatan yang stabil, memperkuat kemampuan model yang semakin baik untuk mendekripsi dan mengklasifikasikan tingkat kesegaran ikan secara akurat, bahkan dalam kondisi yang beragam.

Di antara varian YOLOV11 yang diuji pada ikan cakalang segar yang disediakan pada Tabel IV, YOLOV11S menunjukkan kinerja keseluruhan tertinggi dengan akurasi 90,6%, presisi 92,1%, dan recall 92,9%, yang mencerminkan kemampuan identifikasi yang kuat dan klasifikasi palsu yang rendah. YOLOV11M menunjukkan hasil yang sebanding dengan presisi yang sedikit lebih rendah (89,6%) dan recall (91,9%) tetapi sensitivitas dan spesifisitasnya seimbang. Sementara itu, YOLOV11L mencapai pelokalan terbaik dengan skor mAP@0.50 tertinggi yaitu 0,949, meskipun akurasi dan recallnya sedikit lebih rendah daripada YOLOV11S. Khususnya, YOLOV11M mencatat skor mAP@0.50-0.90 tertinggi sebesar 0,905, yang menunjukkan deteksi yang konsisten di berbagai ambang batas IoU.

TABEL 4
LAPORAN EVALUASI IKAN CAKALANG SEGAR

Metrik	YOLOV11S	YOLOV11M	YOLOV11L
Akurasi	0.906	0.886	0.880
Presisi	0.921	0.896	0.900
Recall	0.929	0.919	0.907
Skor F1	0.925	0.908	0.903
Kekhususan	0.870	0.833	0.833
mAP 0.50	0.947	0.948	0.949
mAP 0,50-0,90	0.854	0.905	0.903

TABEL 5
LAPORAN EVALUASI IKAN CAKALANG TIDAK SEGAR

Metrik	YOLOV11S	YOLOV11M	YOLOV11L
Akurasi	0.906	0.860	0.879
Presisi	0.881	0.864	0.845
Recall	0.870	0.833	0.833

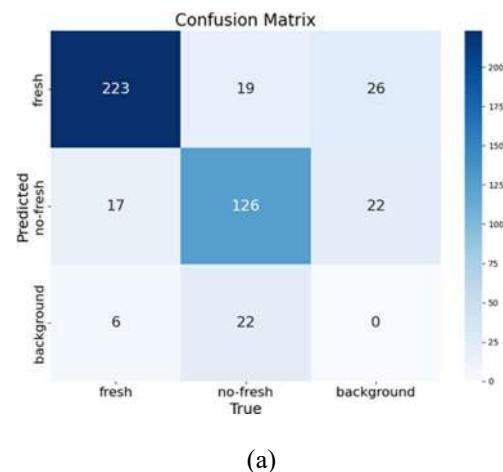
Skor F1	0.875	0.895	0.839
Kekhususan	0.930	0.919	0.907
mAP 0.50	0.854	0.830	0.840
mAP 0,50-0,95	0.777	0.758	0.772

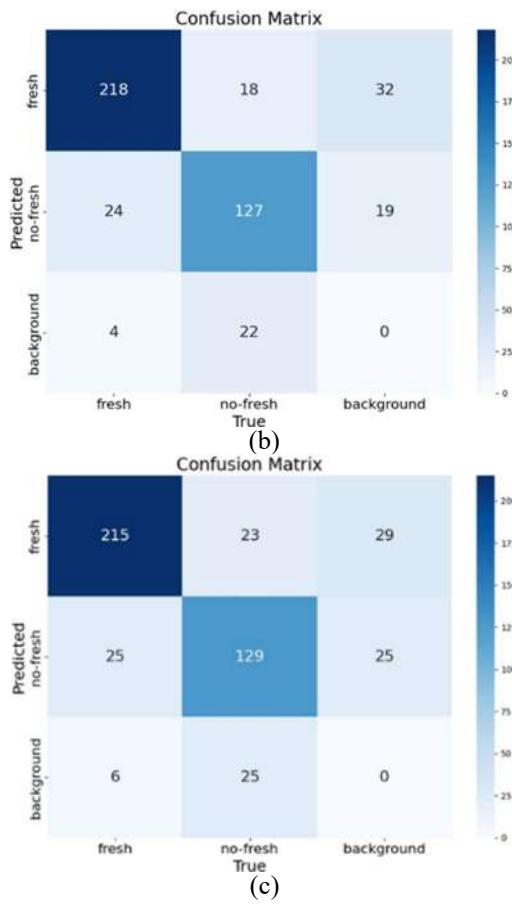
TABEL 6
LAPORAN PENILAIAN KUALITAS PERBANDINGAN IKAN CAKALANG YOLOV11

Model	Akurasi	Presisi	Recall	F1-Skor	mAP 0.95
YOLOV11S	0.91	0.90	0.90	0.90	0.84
YOLOV11M	0.89	0.88	0.88	0.88	0.83
YOLOV11L	0.88	0.87	0.87	0.87	0.84

Pola yang sama juga terlihat pada deteksi ikan cakalang yang tidak segar, seperti yang disajikan pada Tabel V. YOLOV11S mencapai akurasi tertinggi (90,6%) dan spesifisitas (93,0%), yang secara efektif meminimalkan positif palsu. Namun, YOLOV11M menunjukkan kinerja klasifikasi yang paling seimbang, dengan skor F1 tertinggi 0,895, melampaui skor YOLOV11S sebesar 0,875. Meskipun YOLOV11L menunjukkan presisi dan recall yang sedikit lebih rendah, YOLOV11L mempertahankan spesifisitas yang kompetitif (90,7%), yang menunjukkan identifikasi sampel negatif yang andal. Hasil ini menunjukkan bahwa YOLOV11M memberikan ketahanan yang lebih besar dalam mendekripsi sampel yang tidak segar, sementara YOLOV11S unggul dalam meminimalkan kesalahan klasifikasi.

Tabel VI melaporkan hasil klasifikasi secara keseluruhan, dengan YOLOV11S memimpin dengan akurasi 90,6%, presisi 90,2%, recall 90,1%, F1-Score 0,901, dan mAP@0.95 tertinggi (0,839), yang menunjukkan generalisasi yang kuat dalam klasifikasi kesegaran ikan. YOLOV11M, meskipun memiliki akurasi yang sedikit lebih rendah (88,6%), unggul dalam F1-Score untuk sampel yang tidak segar dan mencapai mAP@0.50-0.90 tertinggi untuk sampel segar, yang mengindikasikan ketangguhan dalam berbagai kondisi. YOLOV11L, meskipun sedikit tertinggal dalam metrik klasifikasi, menawarkan pelokalan yang unggul dengan mAP@0.50 sebesar 0,949, menjadikannya ideal untuk tugas pendekripsi objek yang tepat.





GAMBAR 4.

Hasil pelatihan matriks kebingungan dalam model perbandingan: (a) YOLOV11S, (b) YOLOV11M, (c) YOLOV11L.

C. Kinerja YOLOV11

Model YOLOV11, yang dilatih dengan set data yang disesuaikan, secara akurat mengklasifikasikan gambar ikan berdasarkan tingkat kesegarannya. Efektivitasnya dievaluasi melalui metrik presisi, recall, dan F1-Score di berbagai varian YOLOV11. Hasil klasifikasi kesegaran ikan cakalang yang diperoleh dengan menggunakan model YOLOV11 ditunjukkan pada Gambar 4.

Berdasarkan hasil analisis terhadap model YOLOV11, yaitu YOLOV11S, YOLOV11M, dan YOLOV11L, untuk mengevaluasi tingkat kesegaran ikan cakalang, masing-

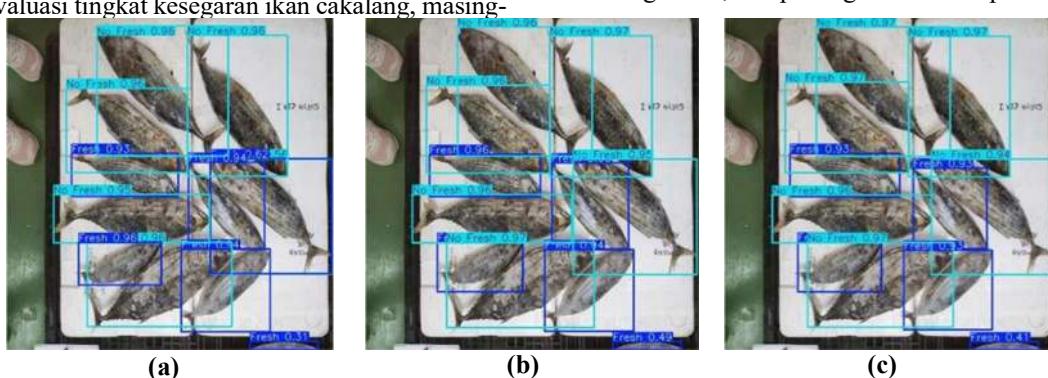
masing model menunjukkan kinerja yang baik, meskipun dengan karakteristik yang berbeda. Model YOLOV11S (Gambar. 4 (a)) mencapai akurasi yang baik tetapi menunjukkan tingkat positif palsu dan negatif palsu yang relatif tinggi dalam kategori ikan segar, sehingga lebih cocok untuk aplikasi yang memprioritaskan kecepatan pemrosesan, meskipun akurasinya dapat ditingkatkan lebih lanjut. Analisis terperinci menunjukkan bahwa YOLOV11S menawarkan pertukaran yang ideal antara kecepatan inferensi dan akurasi deteksi, sehingga sangat sesuai untuk penilaian kesegaran ikan secara real-time.

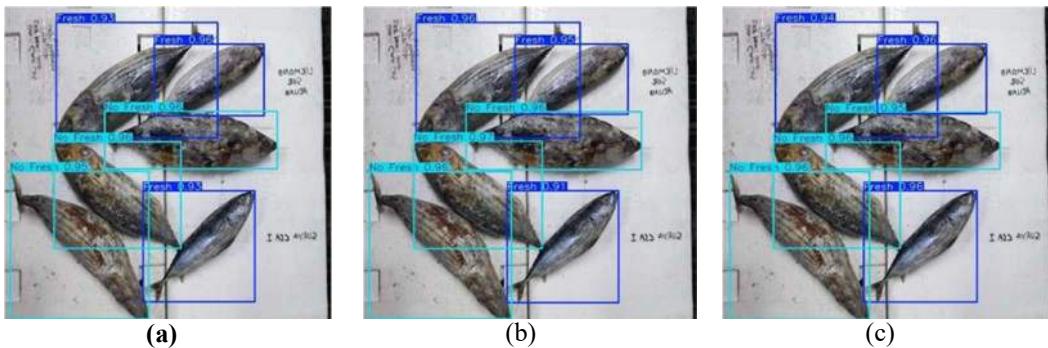
Model YOLOV11M (Gambar. 4 (b)) memberikan keseimbangan yang lebih baik antara presisi dan recall, menjadikannya pilihan ideal untuk aplikasi penyortiran ikan yang membutuhkan kombinasi kecepatan dan akurasi, meskipun itu menunjukkan recall yang sedikit lebih rendah untuk ikan segar. Model YOLOV11L (Gambar. 4 (c)

memberikan kinerja terbaik, dengan akurasi dan recall tertinggi untuk kategori segar dan tidak segar, menjadikannya pilihan utama untuk aplikasi yang membutuhkan akurasi tinggi, seperti kontrol kualitas pasca-penangkapan. Secara keseluruhan, ketiga model YOLOV11 menunjukkan kinerja yang efektif dalam mengklasifikasikan kesegaran ikan, dengan model terbaik yang menawarkan akurasi tinggi yang cocok untuk aplikasi yang membutuhkan kecepatan dan efisiensi tinggi.

D. Perbandingan Kinerja Deteksi Model YOLOV11

Setelah meninjau gambar pada Gambar. 5, model YOLOV11 terbukti secara efektif mengklasifikasikan cakalang sebagai segar atau tidak segar dengan akurasi yang tinggi. Setiap gambar diberi label dengan jelas, yang menunjukkan kemampuan model untuk mendeteksi kesegaran berdasarkan tekstur, warna kulit, dan penampilan secara keseluruhan. Ikan yang dikategorikan sebagai tidak segar diidentifikasi secara konsisten, menunjukkan sensitivitas model terhadap tanda-tanda kerusakan [5]. Meskipun prediksi umumnya konsisten, ada sedikit variasi dalam kepercayaan diri yang muncul di seluruh gambar karena perbedaan halus seperti perubahan warna atau tekstur. Meskipun demikian, hasil penelitian ini menegaskan bahwa YOLOV11 tetap dapat diandalkan dan kuat dalam skenario dunia nyata di mana faktor-faktor seperti pencahayaan, kualitas gambar, dan penanganan ikan dapat bervariasi [20].





GAMBAR 5

Representasi visual dari hasil yang dihasilkan oleh sistem penilaian kualitas untuk dua gambar cakalang menggunakan model YOLOv11: (a) YOLOv11S, (b) YOLOv11M, dan (c) YOLOv11L.

Untuk memvalidasi kemampuan deteksi waktu nyata, evaluasi benchmark dilakukan pada tiga varian YOLOv11 termasuk YOLOv11s, YOLOv11m, dan YOLOv11l, dengan menggunakan GPU NVIDIA Tesla T4 (15GB), konfigurasi perangkat keras yang biasa digunakan di lingkungan industri yang dapat diskalakan. Hasilnya menunjukkan bahwa semua model beroperasi di atas waktu nyata ambang batas 30 FPS. YOLOv11s mencapai kecepatan tertinggi, dengan waktu inferensi rata-rata 5,3 ms, ditambah 0,3 ms untuk prapemrosesan dan 4,1 ms untuk pascapemrosesan, dengan total 9,7 ms per gambar atau sekitar 103 FPS. YOLOv11m direkam 13,5 ms untuk inferensi, 0,3 ms untuk prapemrosesan, dan 3,8 ms untuk pascapemrosesan, menghasilkan 17,6 ms per gambar atau sekitar 56,8 FPS. YOLOv11l membutuhkan 16,0 ms untuk inferensi, 1,2 ms untuk prapemrosesan, dan 6,2 ms untuk pascapemrosesan, dengan total 23,4 ms per gambar atau sekitar 42,7 FPS. Hasil ini mengonfirmasi bahwa ketiga varian tersebut memenuhi kriteria untuk pemrosesan waktu nyata, mendukung penerapannya dalam tugas-tugas yang sangat penting seperti penilaian kesegaran otomatis dan kontrol kualitas pascapanen dalam industri makanan laut.

IV. CONCLUSION

Penelitian ini berhasil mengimplementasikan dan mengevaluasi tiga varian model YOLOV11 termasuk YOLOV11S, YOLOV11M, dan YOLOV11L untuk deteksi multi-objek untuk menilai kesegaran ikan Cakalang beku menggunakan analisis citra digital. Model YOLOV11S mencapai akurasi pengujian sebesar 88,4%, dengan waktu pemrosesan yang relatif cepat (mAP @0,5: 94,8%, mAP @0,95: 90,4%). Namun, itu menunjukkan tingkat positif palsu dan negatif palsu yang lebih tinggi dalam mendeteksi ikan segar, yang mengindikasikan perlunya peningkatan akurasi klasifikasi. YOLOV11M menunjukkan kinerja yang lebih seimbang, mencapai akurasi pengujian 92,9% dan stabilitas deteksi yang lebih baik (mAP @0,5: 95,3%, mAP @0,95: 90,6%). Dengan presisi dan recall yang lebih tinggi daripada YOLOV11S, YOLOV11M lebih cocok untuk aplikasi yang membutuhkan keseimbangan antara kecepatan dan akurasi, seperti penyortiran ikan otomatis berdasarkan kesegaran. YOLOV11L mengungguli YOLOV11S dan YOLOV11M, dengan akurasi pengujian sebesar 91,5% dan recall tertinggi dalam kategori ikan segar (92%). Dengan kinerja deteksi yang kuat (mAP @0,5: 95,5%, mAP @0,95: 90,4%), YOLOV11L menawarkan klasifikasi yang lebih konsisten dan andal untuk ikan segar dan tidak segar, menjadikannya model yang paling sesuai untuk aplikasi dengan akurasi tinggi, seperti kontrol kualitas pasca- penangkapan di industri perikanan.

YOLOV11L muncul sebagai model yang paling efektif untuk deteksi kesegaran ikan cakalang beku. Meskipun demikian, YOLOV11M dan YOLOV11S tetap menjadi alternatif yang layak untuk skenario yang mengutamakan kecepatan pemrosesan dan efisiensi komputasi. Pemilihan model yang sesuai harus dipandu oleh persyaratan operasional spesifik dan sumber daya komputasi yang tersedia dari aplikasi target.

UCAPAN TERIMA KASIH

Penelitian ini sebagian didukung dan didanai oleh Direktorat Riset dan Pengabdian Masyarakat, Universitas Telkom, di bawah Hibah No. 138/LIT06/PPM-LIT/2024 dan 492/LIT06/PPM-LIT/2024, serta Hibah Komersialisasi Produk Inovasi melalui Bandung Techno Park, Universitas Telkom.

REFERENCES

- [1] R. Dwi and M. Ibrahim, "An Image Processing Study: Image Enhancement, Image Segmentation, and Image Classification using Milkfish Freshness Images," *International Journal of Engineering Computing Advanced Research*, vol. 1, no. 1, pp. 11–22, Jul. 2024.
- [2] W. A. Tonapa, P. Manembu and F. D. Kambez, "Fish Classification of Skipjack and Mackerel Tuna Using Convolutional Neural Network," *Jurnal Teknik Informatika*, vol. 19, no. 01, pp. 31–36, 2024.
- [3] R. Archana and P. E. Jeevaraj, "Deep learning models for digital image processing: a review," *Artif. Intell. Rev.*, vol. 57, no. 1, p. 11, 2024.
- [4] F. Akhyar, L. Novamizanti, T. Putra, E. N. Furqon, M.-C. Chang, and C.-Y. Lin, "Lightning YOLOv4 for a surface defect detection system for sawn lumber," in Proc. 2022 IEEE 5th Int. Conf. Multimedia Inf. Process. Retrieval (MIPR), 2022, pp. 184–189.
- [5] A. Kuswantori and D. J. Suroso, "Fish Detection and Classification using YOLOv8 for Automated Sorting Systems," *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 7, no. 2, p. 447, Jul. 2024.
- [6] K. Aziz, M. D. Maulana, R. F. Adawiyah, R. F. Firdaus, L. Novamizanti, and F. Ramdhon, "Comparative analysis of YOLOv8 models in skipjack fish quality assessment system," in Proc. 2023 3rd
- [7] F. Akhyar, L. Novamizanti, K. Usman, G. M. Aditya, F. N. Hakim, M. Z. Ilman, F. Ramdhon, and C.-Y. Lin, "A comparative analysis of the YOLO models for intelligent lobster surveillance camera," in Proc. 2023 Asia Pacific Signal Inf. Process. Assoc. Annu. Summit Conf. (APSIPA ASC), 2023, pp. 2131–2136.
- [8] S. Azizah, M. Padang, L. Novamizanti, and S. Sa'idah, "Identifying the ripeness and quality level of strawberries based on YOLOv7 EfficientNet," in Proc. 2024 Int. Conf. Data Sci. Its Appl. (ICoDSA), 2024, pp. 451–456.
- [9] F. A. Talmees and A. M. Affandi, "Enhancing Epileptic Seizure Detection Accuracy Using YOLOV11 Classification," *Journal of Advances in Mathematics and Computer Science*, vol. 40, no. 5, pp. 1–27, Apr. 2025.

- [10] T. Kumar, R. Brennan, A. Mileo, and M. Bendechache, "Image Data Augmentation Approaches: A Comprehensive Survey and Future Directions," IEEE Access, pp. 1–1, 2024.
- [11] U. Sirisha, S. Praveen, P. N. Srinivasu, P. Barsocchi, and A. K. Bhoi, "Statistical Analysis of Design Aspects of Various YOLO-Based Deep Learning Models for Object Detection," International Journal of Computational Intelligence Systems, vol. 16, no. 1, Aug. 2023.
- [12] J. Yang, T. Tian, Y. Liu, C. Li, D. Wu and L. Wang, "A Rainy Day Object Detection Method Based on YOLOV11 Combined with FFT and MF Model Fusion," in 2024 International Conference on Advanced Control Systems and Automation Technologies (ACSAT), pp. 246–250, Nov. 2024.
- [13] N. W. Kurniawan, Aliyah Kurniasih, and A. Ghani, "Real or Deepfake Face Detection in Images and Video Data using YOLO11 Algorithm," Journal of Artificial Intelligence and Engineering Applications (JAIEA), vol. 4, no. 2, pp. 1514–1521, Feb. 2025.
- [14] T. Ahmad, Y. Ma, M. Yahya, B. Ahmad, S. Nazir, and A. ul Haq, "Object Detection through Modified YOLO Neural Network," Scientific Programming, vol. 2020, pp. 1–10, Jun. 2020.
- [15] S. Saputra, A. Yudhana, and R. Umar, "Implementation of Naïve Bayes for Fish Freshness Identification Based on Image Processing," RESTI Journal (System Engineering and Information Technology), vol. 6, no. 3, pp. 412–420, Jun. 2022.
- [16] M. Mao and M. Hong, "YOLO Object Detection for Real-Time Fabric Defect Inspection in the Textile Industry: A Review of YOLOv1 to YOLOv11," Sensors (Basel, Switzerland), vol. 25, no. 7, p. 2270, Apr. 2025.
- [17] R. Padilla, S. L. Netto, and E. A. B. da Silva, "A Survey on Performance Metrics for Object-Detection Algorithms," in 2020 International Conference on Systems, Signals and Image Processing (IWSSIP), vol. 1, no. 1, Jul. 2020.
- [18] L.-H. He, Y.-Z. Zhou, L. Liu, W. Cao, and J.-H. Ma, "Research on object detection and recognition in remote sensing images based on YOLOV11," Scientific Reports, vol. 15, no. 1, Apr. 2025.
- [19] J. He, Y. Ren, W. Li, and W. Fu, "YOLOV11-RCDWD: A New Efficient Model for Detecting Maize Leaf Diseases Based on the Improved YOLOV11," Applied Sciences, vol. 15, no. 8, p. 4535, Apr. 2025.
- [20] D. F. Anas, I. Jaya, and Nurjanah, "Design and implementation of fish freshness detection algorithm using deep learning," in IOP Conference Series: Earth and Environmental Science, vol. 944, no. 1, p. 012007, Dec. 2021.