

DETEKSI KESEGERAN IKAN LAYUR BERDASARKAN CITRA MATA MENGGUNAKAN YOLOV8

Deni Adi Saputra , Istiadi, Aviv Yuniar Rahman
Teknik Informatika, Institut Teknologi Nasional Malang
Jalan Raya Karanglo km 2 Malang, Indonesia
dhennyadisaputra90@gmail.com

ABSTRAK

Ikan layur (*Trichiurus lepturus*) ditemukan hampir di seluruh perairan laut Indonesia dan memiliki tubuh memanjang serta sangat pipih. Secara ekonomi, ikan ini merupakan komoditas ekspor penting yang menambah devisa negara, terutama karena tingginya permintaan dari pasar China dan Vietnam. Namun, penyortiran kesegaran ikan layur masih dilakukan secara konvensional dengan pengamatan manual. Ikan layur yang tidak segar dapat dikenali dari kondisi mata, warna tubuh, kondisi sisik, dan dinding perut. Penyortiran manual dirasa kurang efektif karena jumlah ikan yang harus disortir cukup banyak, rawan kesalahan human error, dan memerlukan biaya serta waktu yang besar. Penelitian ini mengusulkan pendeteksian kesegaran ikan layur berdasarkan citra mata menggunakan YOLOv8 (You Only Look Once versi 8), algoritma yang dikenal mampu melakukan pengenalan gambar dan video dengan cepat serta akurat. YOLOv8 dapat dijalankan dengan GPU, memungkinkan operasi paralel yang meningkatkan kecepatan deteksi dibandingkan dengan CPU saja. Pengolahan data melibatkan tahapan pre-processing, training, dan testing dengan data citra gambar ikan layur. Hasil pengujian menunjukkan bahwa model YOLOv8 memiliki nilai presisi 0.976, recall 0.996, dan mAP50 0.991. Akurasi masing-masing kelas adalah 0.989 untuk mata ikan layur segar dan 0.994 untuk mata ikan layur busuk. Model ini mampu mendeteksi kesegaran ikan layur dengan akurasi tinggi, memberikan hasil yang lebih efisien dan objektif dibandingkan cara manual.

Kata kunci : Ikan layur, Kesegaran ikan, YOLOv8, Pendeteksian otomatis, Pengenalan gambar, Efisiensi deteksi

1. PENDAHULUAN

Ikan layur, atau *Trichiurus lepturus*, ditemukan hampir di seluruh perairan laut Indonesia dan memiliki tubuh memanjang serta sangat pipih. Ikan ini adalah komoditas ekspor penting yang menambah devisa negara. *Trichiurus lepturus* menghuni secara musiman dari dasar hingga permukaan laut pada kedalaman 100-350 mm dan biasanya ditemukan di perairan pantai dengan dasar berpasir, membentuk kawanan besar. Sebagai organisme karnivora, ikan layur juga terkadang bersifat kanibal, memakan jenis yang sama [1].

Ikan layur merupakan salah satu ikan benthik ekonomis penting di perairan Indonesia, terutama karena tingginya permintaan ekspor dari pasar China dan Vietnam. Pada tahun 2015, total tangkapan layur mencapai 90.30 ton senilai Rp 2.19 miliar, namun turun menjadi 53.632 ton senilai Rp 1 miliar pada tahun 2017. Ekspor ikan layur dunia meningkat dari US\$12 juta pada tahun 2014 menjadi US\$27,5 juta pada tahun 2015, sebelum turun lagi menjadi US\$11 juta pada tahun 2017, dengan Vietnam dan Tiongkok [2].

Sebagai importir terbesar. Hingga kini, ikan layur yang dijual masih berasal dari hasil tangkapan alam di Indonesia. Salah satu masalah utama adalah penyortiran kesegaran ikan layur yang masih dilakukan secara konvensional dengan pengamatan kasat mata, yang kurang efektif dan rentan kesalahan. Penyortiran manual membutuhkan biaya besar dan waktu lama, serta jumlah tenaga yang banyak, menyebabkan biaya yang tinggi [3].

Penelitian oleh Suprianto, dkk menggunakan metode convolutional neural network (CNN) untuk menilai kesegaran ikan bandeng dengan akurasi 87.5% pada jarak ± 5 cm dengan kamera flash dan 66.67% tanpa flash [4]. Penelitian oleh Chiki Rizka Gunawan, dkk menggunakan YOLOv4-CNN untuk deteksi ikan segar secara real-time, memperoleh mAP sebesar 93.75%, dengan presisi 1,00%, recall 0.93%, f-score 0.96%, dan rata-rata IoU sebesar 74.17% [5].

Maulida et al. menggunakan metode naïve bayes classifier untuk deteksi ikan tongkol berformalin dengan akurasi 80% [6].

Sabarudin Saputra, Anton Yudhana, dan Rusydi Umar menggunakan algoritma KNN berbasis citra digital untuk identifikasi kesegaran ikan dengan akurasi 93,33% [6]. Richard, Natadjaja, dan Wonohadidjojo menggunakan kombinasi YOLOv4-Tiny dan EfficientNetV2-S untuk deteksi kesegaran ikan gurami, menghasilkan mean average precision sebesar 93.58% dan akurasi klasifikasi 93% [7].

Penelitian ini bertujuan untuk mengembangkan metode deteksi kesegaran ikan layur berdasarkan citra mata menggunakan YOLOv8. Teknologi ini diharapkan dapat meningkatkan efisiensi dan efektivitas dalam mendeteksi serta menyortir ikan layur, sehingga berkontribusi pada peningkatan kualitas dan keamanan produk ikan layur di skala industri. Penerapan algoritma YOLOv8 diharapkan memberikan solusi yang lebih baik dan efisien dalam proses ini. Dalam jangka panjang, penelitian ini dapat memberikan kontribusi penting bagi pengembangan

industri perikanan dengan meningkatkan kualitas dan keamanan produk ikan layur.

2. TINJAUAN PUSTAKA

2.1. Ikan Layur

Ikan layur, atau *Trichiurus lepturus*, dapat ditemukan hampir di seluruh perairan laut Indonesia dan memiliki tubuh memanjang serta sangat pipih. Secara ekonomi, ikan ini merupakan komoditas ekspor penting yang dapat menambah devisa negara. Ikan layur hidup secara musiman dari dasar hingga permukaan pada kedalaman 100-350 mm dan membentuk kawanan besar di perairan pantai dengan dasar berpasir. Sebagai organisme karnivora, ikan layur kadang-kadang juga bersifat kanibal, memakan jenis yang sama [1].



Gambar 1. Ikan Layur

Ikan layur yang ditunjukkan pada Gambar 1 adalah Ikan yang kaya protein, lemak, dan vitamin dapat memenuhi kebutuhan gizi tubuh dan memiliki efek kesehatan yang baik. Minyak ikan adalah komponen ikan paling penting yang sering dikaitkan dengan kesehatan ikan. Dengan 12-26 atom karbon dan 0-6 ikatan rangkap, produk ini memiliki berbagai karakteristik asam lemak. Ikan mengandung 15% hingga 25% asam lemak jenuh, 35% hingga 60% asam lemak tak jenuh tunggal, dan 25% hingga 40% asam lemak tak jenuh majemuk [2].

2.2. Parameter Kesegaran Ikan

Ikan segar memiliki sembilan tanda utama yaitu: kenampakan, warna mata, bau, sisik, warna insang, dubur, tekstur daging, dan tubuh. Ciri-ciri ini meliputi kenampakan cerah dan mengkilap, mata yang cerah dan menonjol, bau yang tidak menyengat, sisik yang kuat, mulut tertutup, dubur berwarna merah jambu, daging yang kenyal, dan tubuh yang tenggelam dalam air [1].

Ikan segar juga memiliki karakteristik seperti ikan hidup, termasuk rupa, bau, rasa, dan tekstur, dan dapat dikategorikan menjadi empat kelas mutu: sangat baik, baik, sedang, dan tidak segar/busuk. Perubahan menuju pembusukan terjadi akibat aktivitas bakteri, perubahan kimiawi oleh enzim, dan oksidasi lemak oleh udara [8].


Kesegaran ikan ditentukan dengan memeriksa kondisi fisiknya, termasuk kenampakan luar, lenturan daging, mata, daging, insang, dan sisik, di mana mata ikan segar harus cerah, bening, dan menonjol, sedangkan mata ikan yang mulai membusuk akan pudar, keruh, cekung, dan tenggelam [9].

2.3. Deep Learning

Deep Learning adalah metode pembelajaran yang menggunakan jaringan saraf tiruan (Artificial Neural Network) dengan banyak lapisan, menyerupai struktur otak manusia di mana setiap neuron terhubung membentuk jaringan yang kompleks [10].

Deep Learning, juga dikenal sebagai deep structured learning, hierarchical learning, atau deep neural, merupakan cabang dari machine learning berbasis Artificial Neural Networks (ANN) yang memungkinkan komputer untuk belajar mengklasifikasikan data langsung dari gambar atau suara. Metode ini menggunakan CPU, RAM, dan GPU dalam proses perhitungannya, sehingga memungkinkan perhitungan big data dilakukan lebih cepat [10].

2.4. Convolution Neural Network



Gambar 2. Klasifikasi gambar menggunakan CNN


Pada gambar 2 Convolutional Neural Networks (CNN) adalah salah satu algoritma yang paling umum digunakan dalam klasifikasi citra, terbukti memiliki performa baik dalam aplikasi dan dapat dikembangkan. CNN merupakan jaringan feed-forward yang mengalirkan informasi dari input ke output, terinspirasi oleh cara kerja otak manusia. Arsitektur CNN terdiri dari ekstraksi fitur melalui lapisan konvolusional dan pooling, serta lapisan yang terhubung sepenuhnya. Dalam CNN, keluaran dari lapisan konvolusional pertama digunakan sebagai masukan untuk lapisan konvolusional berikutnya. Convolutional layer mempelajari fitur dari input image, dengan neuron yang disusun menjadi feature map. Neuron pada feature map memiliki bidang reseptif dengan bobot yang dapat dilatih, dan hasil konvolusi dikirim melalui fungsi aktivasi non-linier. Semua neuron dalam satu feature map memiliki bobot yang sama, tetapi peta fitur yang berbeda dalam lapisan konvolusional yang sama memiliki bobot yang berbeda untuk mengekstraksi berbagai fitur dari suatu lokasi [11].

2.5. Yolo

YOLO (You Only Look Once) adalah algoritma machine learning yang digunakan untuk mendeteksi objek dalam frame, pertama kali diperkenalkan oleh Joseph Redmon et al. pada tahun 2016 dalam jurnal "You Only Look Once: Unified, Real-Time Object Detection" [11].

YOLO dikenal sebagai teknik pencarian objek baru yang memanfaatkan neural network untuk mengoptimalkan proses deteksi. Berbeda dengan pendekatan tradisional yang menggunakan pipeline untuk klasifikasi dan pencarian lokasi objek dalam beberapa langkah, YOLO mengubah deteksi objek menjadi masalah regresi, memungkinkan identifikasi koordinat bounding box dan klasifikasi kelas objek langsung dari pixel-pixel pada gambar. YOLO membagi gambar menjadi beberapa bagian NxN untuk melatih gambar secara utuh dan mengoptimalkan deteksi objek [12].

2.6. YOLOv8



Gambar 3. Arsitektur YOLOv8

Pada gambar 3 YOLOv8 adalah iterasi terbaru dari algoritma YOLO yang diluncurkan pada tahun 2020, dengan berbagai peningkatan seperti jaringan backbone yang lebih efisien, prediksi skala ganda, dan sistem anchor baru. Arsitektur YOLOv8 terdiri dari tiga komponen utama: backbone, neck, dan head. Jaringan backbone menggunakan Feature Pyramid Network (FPN) untuk mengekstraksi fitur dari gambar input, sementara bagian neck menggunakan serangkaian Cross-Layer Connections (CLC) untuk memperhalus fitur tersebut. Bagian head kemudian memanfaatkan fitur yang telah disempurnakan untuk memprediksi bounding boxes, skor kelas objek, dan akurasi untuk setiap objek dalam gambar. Arsitektur YOLOv8 memiliki total 105 layer [12].

2.7. Pre-Processing

Pre-Processing data adalah tahap persiapan data sebelum diterapkan dalam algoritma YOLOv8 dan digunakan untuk analisis atau pemodelan. Tahap ini mencakup memastikan kualitas gambar yang optimal, menyesuaikan ukuran gambar (resize) sesuai dengan

kebutuhan algoritma, serta melakukan augmentasi data seperti rotasi, pergeseran, atau pemutaran gambar untuk meningkatkan variasi dalam dataset. Pre-pemrosesan adalah langkah krusial dalam pengolahan data sebelum analisis atau pemodelan dilakukan [13].

2.8. Pelatihan (Training)

Pada proses training menggunakan dataset yang telah di pre-processing pada algoritma YOLOv8 akan mempelajari pola, belajar untuk mendeteksi kualitas kesegaran mata yang segar dan busuk. Selama pelatihan YOLOv8 akan menyesuaikan parameter modelnya untuk mengoptimalkan kemampuan deteksi dan klasifikasi [14].

2.9. Pengujian

Proses pengujian metode YOLOv8 adalah dengan menggunakan mode val untuk menjalankan kode yang telah dirancang peneliti. Pengujian ini menggunakan data terbaik dari hasil pelatihan sebelumnya. Dengan demikian, hasil pengujian dapat digunakan untuk evaluasi [15].

2.10. Deteksi Citra

Deteksi citra adalah proses analisis gambar menggunakan metode dan teknik tertentu untuk mengidentifikasi, mengukur, atau mengekstrak informasi penting dari gambar yang dianalisis. Teknologi seperti pengolahan citra digital, algoritma komputer, dan kecerdasan buatan digunakan untuk meningkatkan akurasi dan efisiensi interpretasi gambar. Teknik-teknik ini memiliki aplikasi luas, termasuk pengenalan wajah, deteksi objek, analisis medis, dan pengawasan keamanan. Dengan pendekatan yang tepat, deteksi citra dapat mengungkap pola, mendeteksi anomali, atau mengotomatisasi proses yang sebelumnya memerlukan intervensi manual [16].

2.11. Mean Average Precision

Mean Average Precision (mAP) adalah ukuran yang umum digunakan untuk mengevaluasi kinerja algoritma deteksi objek, seperti R-CNN, Faster R-CNN, dan SSD. mAP menggabungkan dua konsep: Average Precision (AP) dan nilai rata-rata. AP mengestimasi rata-rata presisi pada berbagai tingkat recall dengan mengubah ambang batas deteksi objek. Presisi mengukur keakuratan hasil deteksi, sedangkan recall mengukur sejauh mana objek yang sebenarnya terdeteksi. AP dihitung dengan mengambil rata-rata presisi pada setiap titik recall yang telah diurutkan. mAP kemudian memperoleh nilai rata-rata AP untuk setiap kelas objek yang berhasil terdeteksi, menggabungkan akurasi deteksi objek dari seluruh kelas dalam dataset. Nilai mAP berkisar antara 0 hingga 1, dengan nilai lebih tinggi menunjukkan kinerja deteksi objek yang lebih baik [17].

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

Rumus untuk menghitung Mean Average Precision (mAP) menggabungkan Average Precision (AP) dan nilai rata-rata dari setiap kelas objek yang terdeteksi. mAP memberikan gambaran tentang akurasi keseluruhan dari algoritma deteksi objek yang dievaluasi [18].

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

Presisi adalah metrik yang mengukur seberapa sering model memprediksi data positif dengan benar, dengan nilai berkisar antara 0 hingga 1. Nilai presisi yang lebih tinggi menunjukkan model yang lebih andal dalam mengidentifikasi data positif, mengindikasikan bahwa model meminimalkan prediksi positif yang salah [18].

$$Recall = \frac{TP}{TP+FN} \quad (3)$$


Recall adalah metrik yang mengukur kemampuan model untuk mengidentifikasi semua data positif, dengan nilai berkisar antara 0 hingga 1. Nilai recall yang lebih tinggi menunjukkan model yang lebih lengkap dalam mendeteksi data positif. Recall sering digunakan bersama dengan presisi dan akurasi untuk mengevaluasi model klasifikasi, dan pentingnya metrik ini tergantung pada aplikasi spesifiknya [18].

2.12. Google Colaboratory

Google Colab adalah IDE untuk pemrograman Python yang memanfaatkan server Google dengan perangkat keras berperforma tinggi. Colab menyediakan berbagai library penting seperti Keras, TensorFlow, NumPy, dan Pandas, serta mendukung versi berbeda dari TensorFlow dan Python. Dari sisi hardware, Colab menawarkan media penyimpanan terintegrasi dengan Google Drive, prosesor CPU, GPU, dan TPU, serta RAM. Jaringan stabil memastikan kapasitas server tetap andal selama proses di Google Colab [19].

3. METODE PENELITIAN

Dalam penelitian dapat beragam tergantung pada jenis penelitian yang digunakan. Dalam penelitian ini terdapat beberapa tahap secara umum, diantaranya tahapan persiapan, studi pustaka, perencanaan, pengumpulan data, implementasi, pengujian dan penyusunan laporan yang ditunjukkan pada gambar 4 Tahapan umum dalam Deteksi Kesegeran Ikan Layur Berdasarkan Citra Mata Menggunakan YOLOv8 sebagai berikut:



Gambar 4. Tahapan umum penelitian

3.1. Persiapan

Untuk memulai penelitian ini. Penulis memulai dengan studi pustaka yang dilakukan untuk perumusan

masalah, meninjau penelitian terdahulu sebagai acuan untuk melakukan penelitian ini. Studi pustaka ini dilakukan dengan melakukan peninjauan pustaka yang berhubungan dengan deteksi dan pengenalan objek pada video. Penulis menggunakan Google Scholar untuk mencari pustaka dengan memasukkan kata kunci You Only Look Once (YOLO), object detection, Optical Character Recognition (OCR) dan Ekstraksi data.

3.2. Studi Pustaka

Studi pustaka dilakukan dengan tujuan memperoleh pemahaman yang mendalam tentang deteksi kesegeran ikan layur berdasarkan citra mata dan algoritma YOLOv8. Dalam tahap ini, peneliti mempelajari penelitian terkait, metode yang telah digunakan, dan hasil yang telah diselidiki sebelumnya. Selain itu, studi pustaka juga bertujuan untuk mengidentifikasi kesenjangan penelitian yang dapat diisi pada penelitian ini.

3.3. Perencanaan

Tahapan perencanaan adalah langkah awal dalam penelitian yang bertujuan untuk merumuskan rencana kerja secara sistematis, menciptakan kerangka kerja yang terstruktur dan terorganisir seperti yang ditunjukkan dalam gambar 4, sehingga dapat menghasilkan hasil yang baik dan bermanfaat. Tahap ini mencakup penyusunan rencana penelitian, pemilihan lokasi penelitian, jenis data yang akan dikumpulkan, serta peralatan dan bahan yang akan digunakan.

3.4. Pengumpulan Data

Dataset citra ikan layur mencakup variasi kondisi citra dengan kualitas yang berbeda-beda, diperoleh melalui pengambilan foto dan video langsung menggunakan kamera smartphone Oppo A92. Untuk memastikan hasil yang representatif, gambar diambil dari berbagai sudut pandang (atas, samping, dan bawah) guna menangkap setiap detail yang mempengaruhi penilaian kualitas ikan. Data yang terkumpul mencakup 189 gambar ikan layur segar dan 189 gambar ikan layur busuk, yang digunakan sebagai data uji.

3.5. Implementasi

Tahap implementasi adalah ketika penulis menerapkan model yang telah dirancang dan mengembangkan solusi sesuai tujuan penelitian. Pada tahap ini, peneliti menggunakan Roboflow untuk melakukan pra-pemrosesan data. Sebelum pelatihan dimulai, dataset harus melalui pra-pemrosesan untuk memastikan data sesuai dan meningkatkan kualitas deteksi. Langkah pertama adalah mengubah gambar menggunakan fitur Auto-Orient untuk memutar gambar agar orientasinya benar dan konsisten, dan Resize Stretch to 640x640 untuk mengubah ukuran gambar menjadi 640x640 piksel guna mempercepat pelatihan dan inferensi serta mengurangi penggunaan

memori. Setelah itu, dilakukan anotasi gambar, augmentasi, dan pembagian data.

3.6. Anotasi Gambar

Anotasi gambar merupakan tahap memberikan labelling atau kelas pada setiap gambar. Pada tahap ini, setiap gambar di beri label atau kelas yang terdiri dari dari kelas mata ikan layur segar (fresh fish eyes) dan mata ikan layur busuk (rotten fish eyes). Anotasi gambar dilakukan menggunakan tools Roboflow menggunakan smart polygon.

3.7. Augmentasi

Penelitian ini menggunakan Roboflow untuk data augmentation dengan teknik seperti auto-orientasi, resize ke 640x640, flip horizontal, rotasi 90 derajat (jarum jam dan berlawanan jarum jam), crop dengan zoom minimum 0% dan maksimum 20%, rotasi antara -15° dan $+15^\circ$, shear $\pm 10^\circ$ horizontal dan $\pm 10^\circ$ vertikal, serta perubahan saturasi antara -25% dan +25%. Teknik tambahan mencakup perubahan kecerahan acak, pembalikan gambar secara horizontal dan vertikal, konversi 15% gambar menjadi hitam putih, perubahan hue antara -25 derajat dan +25 derajat, serta penyesuaian eksposur antara -10% dan +10%. Data awal terdiri dari 378 citra gambar ikan layur busuk dan segar yang diperbanyak menjadi 830 gambar. Pembagian dataset akhir adalah 82% untuk train set (678 gambar), 5% untuk valid set (38 gambar), dan 14% untuk test set (114 gambar).

3.8. Pembagian Dataset/split ratio

Setelah pengumpulan data, langkah berikutnya adalah implementasi, dimulai dengan anotasi gambar untuk memberikan label pada setiap objek menggunakan metode bounding box. Anotasi ini juga melibatkan pemberian kelas pada setiap objek yang dibatasi oleh bounding box, menggunakan alat polygon pintar dalam aplikasi web Roboflow. Kelas yang diberikan terdiri dari mata ikan layur segar (fresh fish eyes) dan mata ikan layur busuk (rotten fish eyes). Data yang telah dianotasi tersebut digunakan untuk melatih model guna mengembangkan karakteristik yang akan digunakan sebagai acuan dalam pengujian seperti pada tabel 1.


Tabel 1. Data Split Ratio

Dataset Split (Train,Valid,Test)	Jumlah Data Train	Jumlah Data Valid	Jumlah Data Test
10%, 10%,80%	111	37	304
20%,10%,70%	228	36	266
30%,10%,60%	336	36	230
40%,10%,50%	459	36	189
50%,10%,40%	567	36	153
60%,10%,30%	678	38	114
70%,10%,20%	795	36	77
80%,10%,10%	906	38	38

3.9. Pengujian dan Evaluasi


Setelah tahapan implementasi diselesaikan, maka tahapan selanjutnya yaitu pengujian. Pengujian dilakukan dengan menguji hasil training dengan data ikan layur yang telah dilakukan sebelumnya. Pada tahapan ini juga menganalisis hasil evaluasi model dan menginterpretasikan kemampuan algoritma YOLOv8 dalam melakukan deteksi kesegaran ikan layur berdasarkan citra mata.

4. HASIL DAN PEMBAHASAN



Gambar 5. Grafik Perbandingan Split Ratio Evaluation dengan mAP50

Gambar 5 menunjukkan grafik perbandingan mAP 50 (Mean Average Precision) untuk beberapa rasio pembagian data pelatihan, validasi, dan pengujian dalam tiga kategori: mata ikan layur segar (biru), mata ikan layur busuk (hijau), dan semua kelas (merah). Hasilnya menunjukkan bahwa model unggul dalam mendeteksi mata ikan layur busuk dengan mAP sekitar 0.986-0.995, sedangkan mata ikan layur segar memiliki nilai mAP 0.973-0.991. Secara keseluruhan, mAP 50 untuk semua kelas meningkat dengan bertambahnya porsi data pelatihan, mencapai hingga 0.993. Model ini menunjukkan performa baik dan konsisten, terutama dalam mendeteksi mata ikan layur busuk. Nilai tertinggi pada grafik mAP 50 dicapai pada rasio data Training 40%, Validasi 10%, Testing 50%, dengan puncak untuk mata ikan layur segar (0.991) dan semua kelas (0.993). Selain itu, rasio Training 80%, Validasi 10%, Testing 10% juga memberikan akurasi tinggi dengan mAP mendekati nilai tertinggi, menunjukkan kemampuan model yang kuat dalam berbagai kondisi pembagian data. Meskipun secara teori rasio Training 80%, Validasi 10%, Testing 10% seharusnya memberikan performa terbaik, dalam kasus ini rasio Training 40%, Validasi 10%, Testing 50% memberikan hasil tertinggi.



Gambar 6. Grafik Perbandingan Split Ratio Evaluation dengan mAP50 - 95

Gambar 6 menunjukkan grafik mAP 50-95 yang membandingkan kinerja model pada berbagai rasio pembagian data pelatihan, validasi, dan pengujian untuk tiga kategori: mata ikan layur segar (biru), mata ikan layur busuk (hijau), dan semua kelas (merah). Hasilnya menunjukkan bahwa nilai mAP meningkat seiring bertambahnya porsi data pelatihan. Kinerja terbaik tercapai pada rasio Training 60%, Validasi 10%, Testing 30%, dengan nilai mAP 0.548 untuk mata ikan layur segar, 0.655 untuk mata ikan layur busuk, dan 0.602 untuk semua kelas. Hal ini mencerminkan kemampuan model yang lebih baik dalam mendeteksi objek dengan porsi data pelatihan yang optimal.

Berdasarkan kedua data tersebut, nilai terbaik untuk kesimpulan diambil dari grafik mAP 50 dan mAP 50-95 yang menunjukkan performa model dalam berbagai rasio pembagian data. Grafik mAP 50 menunjukkan hasil terbaik pada rasio Training 40%, Validasi 10%, Testing 50% dengan nilai tertinggi 0.991 untuk mata ikan layur segar dan 0.993 untuk semua kelas. Grafik mAP 50-95 menunjukkan performa terbaik pada rasio Training 60%, Validasi 10%, Testing 30% dengan nilai mAP 0.548 untuk mata ikan layur segar, 0.655 untuk mata ikan layur busuk, dan 0.602 untuk semua kelas. Secara keseluruhan, mAP 50 menunjukkan nilai yang lebih tinggi dan konsisten, terutama dalam mendeteksi mata ikan layur busuk, dengan nilai tertinggi mencapai 0.995 untuk semua kelas pada rasio Training 60%, Validasi 10%, Testing 30%. Namun, karena nilai mAP 50 cenderung rata-rata sama pada berbagai rasio, mAP 50-95 dipilih sebagai ukuran utama untuk pengambilan kesimpulan, dengan hasil terbaik pada rasio Training 60%, Validasi 10%, Testing 30%, mencerminkan performa model yang sangat baik dan konsisten.

Tabel 1. Hasil pengujian ke objek

Objek	Nilai Confidence	Keterangan
 Gambar 7. Hasil deteksi ke ikan cakalang	0.67, 0.69	Segar


Objek	Nilai Confidence	Keterangan
 Gambar 8. Hasil deteksi ke ikan layur	0.65	Segar
 Gambar 9. Hasil deteksi ke ikan layur 2	0.68-0.70	Segar
 Gambar 10. Hasil deteksi ke ikan layur 3	0.55, 0.61, 0.70	Busuk

Pada tabel 2 hasil pengujian ke objek seperti pada gambar 7 menunjukkan nilai confidence untuk penentuan kesegaran ikan layur. Objek dengan nilai confidence 0.67 dan 0.69 dikategorikan sebagai segar. Gambar 8 Objek lain dengan nilai confidence 0.65 juga dikategorikan sebagai segar. Selain itu, gambar 9 objek dengan rentang nilai confidence 0.68 hingga 0.70 juga dianggap segar. Di sisi lain, gambar 10 objek dengan nilai confidence 0.55, 0.61, dan 0.70 dikategorikan sebagai busuk. Hasil ini menunjukkan bahwa model mampu mengidentifikasi kesegaran ikan layur dengan tingkat confidence yang bervariasi, dan meskipun ada beberapa tumpang tindih dalam nilai confidence antara kategori segar dan busuk, model umumnya dapat membedakan kondisi kesegaran ikan dengan baik.

Tabel 2. Hasil Pelatihan dan Akurasi Model YOLOv8 untuk Deteksi Kesegaran Ikan Layur Berdasarkan Citra Mata

Learning rate	Class	mAP50	ALL Class
Epoch: 100 Batch Size: 8 lr0: 0.001 lrf: 0.001 momentum: 0.937 patience: 0	Fresh fish eyes (mata ikan segar)	98.6 %	99.1 %
	Rotten fish eyes (mata ikan busuk)	99.5 %	

Pada tabel 3 dapat dijelaskan hasil nilai menggunakan nilai default learning rate dengan menggunakan 100 epoch mendapatkan hasil 98.7 % pada kelas mata ikan segar, 99.3 % pada mata ikan layur busuk, dan pada semua kelas mencapai 99.1 %. Dengan kecepatan 0.2ms, inference 5.7ms, loss 0.0ms, postprocess 2.5ms per citra. Model training berhasil menempuh proses pada epoch 100 dengan menempuh waktu 0.805 jam.



Gambar 11. Confusion Matrix YOLOv8

Gambar 11 menunjukkan kinerja hasil matriks konfusi dalam mengidentifikasi mata ikan layur segar (fresh fish eyes) dan mata ikan layur busuk (rotten fish eyes), pada matriks ini algoritma berhasil memprediksi kategori mata ikan layur segar "fresh fish eyes" dengan 105 prediksi benar dan 0 prediksi salah, kategori mata ikan layur busuk "rotten fish eyes" dengan 24 prediksi benar dan 2 prediksi salah. tidak ada kesalahan prediksi yang signifikan pada kategori "background". Hasil tersebut menunjukkan bahwa model cukup efektif, kinerja model dapat ditingkatkan dengan menambah data pelatihan dan menyesuaikan parameter model.

Pada tabel 4 adalah hasil perhitungan precision recall dengan menunjukkan perbandingan hasil akurasi antara kelas satu dengan kelas lainnya. hasil evaluasi model berdasarkan precision, recall, dan mAP50 pada threshold IoU 0.50 setelah 100 epoch pelatihan. Model mencapai akurasi tertinggi sebesar 0.991 secara keseluruhan, dengan precision 0.984 dan recall 0.995. Untuk kelas "Fresh fish eyes" (mata ikan segar), dengan 38 objek, model mencatat precision 0.988 dan recall 0.99, serta mAP50 sebesar 0.986. Sementara itu, untuk "Rotten fish eyes" (mata ikan busuk), dengan 38 objek, precision mencapai 0.98 dan recall 1, dengan mAP50 tertinggi 0.995. Meskipun jumlah objek sama model tetap menunjukkan kinerja yang sangat baik dalam mendeteksi objek dari berbagai kelas.

Tabel 3. Hasil Deteksi Ikan layur Berdasarkan Citra Mata Menggunakan YOLOv8

Class	Instances	Box and Mask		
		Precision	Recall	mAP50
All	129	98.4	99.5	99.1
Fresh fish eyes(mata ikan segar)	105	98.8	99	98.6
Rotten fish eyes(mata ikan busuk)	24	98	100	99.5

5. KESIMPULAN DAN SARAN

Berdasarkan hasil uji deteksi kualitas kesegaran ikan layur berdasarkan citra mata, peneliti menyimpulkan bahwa model deteksi yang digunakan mampu mengidentifikasi kesegaran ikan layur dengan tingkat akurasi yang tinggi. Model YOLOv8 menunjukkan potensi besar untuk mendukung pemantauan dan penyortiran kualitas kesegaran ikan layur. Analisis grafik mAP 50 dan mAP 50-95 menunjukkan bahwa meskipun nilai mAP 50 konsisten tinggi, grafik mAP 50-95 memberikan pandangan lebih mendalam, dengan rasio 60% Training, 10% Validasi, dan 30% Testing memberikan kinerja terbaik (nilai mAP 0.548 untuk mata ikan layur segar, 0.655 untuk mata ikan layur busuk, dan 0.602 untuk semua kelas).

Kesimpulannya, rasio ini dipilih sebagai yang terbaik karena memberikan hasil paling optimal dalam mendeteksi kesegaran ikan layur. Model ini berhasil mendeteksi mata ikan layur segar dengan nilai mAP 98.6%, mata ikan busuk 99.5%, dan semua kelas 99.1%. Selain itu, proses deteksi berlangsung cepat, dengan kecepatan preprocess 0.2 ms, inference 5.7 ms, loss 0.0 ms, dan postprocess 2.5 ms per citra. Model training juga efisien, menempuh 100 epoch dalam 0.805 jam. Penggunaan YOLOv8 dalam deteksi kualitas kesegaran ikan layur berdasarkan citra mata terbukti berhasil dan efisien, menunjukkan potensi besar dalam pemantauan dan penyortiran kualitas kesegaran ikan layur.

DAFTAR PUSTAKA

- [1] H. Rahmat, P. Gde Sasmita Julyantoro, and E. Wulandari Suryaningtyas, "Prevalensi dan Intensitas Parasit pada Ikan Layur (*Trichiurus lepturus*) di Pasar Ikan Kedonganan, Bali," *Curr. Trends Aquat. Sci. III*, vol. 1, no. 1, pp. 47–53, 2020.
- [2] A. Mardiono Jacob, Nurjanah, T. Hidayat, and R. Perdiansyah, "Komposisi Kimia dan Profil Asam Lemak Ikan Layur Segar Penyimpanan Suhu Dingin," *J. Pengolah. Has. Perikan. Indones.*, vol. 23, no. 1, pp. 147–157, 2020, doi: 10.17844/jphpi.v23i1.31057.
- [3] Y. R. Prayogi, C. L. Wibisono, and A. H. Abror, "Deteksi Kesegaran Ikan Bandeng Berbasis Pengolahan Citra Digital," *REMIK (Riset dan E-Jurnal Manaj. Inform. Komputer)*, vol. 4, no. 1, p. 53, 2019, doi: 10.33395/remik.v4i1.10228.
- [4] M. Sholihin, "Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 3, pp. 1352–1360, 2021, doi: 10.35957/jatisi.v8i3.939.
- [5] C. R. Gunawan, "Deteksi Ikan Segar Secara Realtime dengan YOLOv4 menggunakan Metode Convolutional Neural Network (CNN)," vol. 7, no. 1, pp. 1–11, 2023.

- [6] M. Maulida, E. Setya Wijaya, M. Reza Anwar, J. Brigjen Hasan Basri Kayutangi Banjarmasin, and K. Selatan, "Deteksi Ikan Tongkol Berformalin Berdasarkan Citra Mata Ikan Dengan Metode Naïve Bayes Classifier," *Kumpul. J. Ilmu Komput.*, vol. 08, no. 3, p. 305, 2021.
- [7] H. Richard, A. Natadjaja, and D. M. Wonohadidjojo, "Penerapan Algoritma YOLOv4-Tiny Dan Efficientnetv2-S Untuk Deteksi Kesegaran Ikan Gurami," *J. Ris. Sist. Inf. Dan Tek. Inform.*, vol. 8, no. 2, pp. 480–488, 2023, [Online]. Available: <https://tunasbangsa.ac.id/ejurnal/index.php/jurasik>
- [8] M. Christiawan, L. W. Santoso, and D. H. Setiabudi, "Deteksi Tingkat Kesegaran Ikan Menggunakan Metode Convolutional Neural Network Dengan Parameter Mata dan Warna Insang," *J. Infra*, vol. 9, no. 2, pp. 213–219, 2021.
- [9] A. J. Rindengan and M. Mananohas, "Perancangan Sistem Penentuan Tingkat Kesegaran Ikan Cakalang Menggunakan Metode Curve Fitting Berbasis Citra Digital Mata Ikan System Design of Freshness Level Determination of Skipper Fish Using Curve Fitting Method Based on Digital Image of Fish Eye," *J. Ilm. Sains*, vol. 17, no. 2, p. 164, 2017.
- [10] P. A. Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia," *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [11] B. K. Umri, E. Utami, and M. P. Kurniawan, "Tinjauan Literatur Sistematis tentang Deteksi Covid-19 menggunakan Convolutional Neural Networks," *Creat. Inf. Technol. J.*, vol. 8, no. 1, p. 9, 2021, doi: 10.24076/citec.2021v8i1.261.
- [12] M. Abdul Hadi, R. Ferdian, and L. Arief, "Klasifikasi Tingkat Ancaman Kriminalitas Bersenjata Menggunakan Metode You Only Look Once (YOLO)," *Chipset*, vol. 2, no. 01, pp. 33–40, 2021, doi: 10.25077/chipset.2.01.33-40.2021.
- [13] S. Mira, M. Kom, C. Gudiatto, S. Kom, M. Kom, and B. Chan, *Computer Vision dan YOLO Menggali Potensi Computer Vision dan Implementasi YOLO untuk Pertanian Pintar*. Uwais Inspirasi Indonesia, 2023.
- [14] C. A. Lorentius, K. Gunadi, and A. N. Tjondrowiguno, "Pengenalan aksara jawa dengan menggunakan metode convolutional neural network," *J. Infra*, vol. 7, no. 1, pp. 221–227, 2019.
- [15] M. M. A. R. Kuty, "Implementasi Real Time Stream Protocol Pada Cctv Kawasan Tanpa Merokok." Politeknik Negeri ujung Pandang, 2023.
- [16] D. N. Alfarizi, R. A. Pangestu, D. Aditya, M. A. Setiawan, and P. Rosyani, "Penggunaan Metode YOLO Pada Deteksi Objek: Sebuah Tinjauan Literatur Sistematis," *AI dan SPK J. Artif. Intell. dan Sist. Penunjang Keputusan*, vol. 1, no. 1, pp. 54–63, 2023.
- [17] A. F. Fandisyah, N. Iriawan, and W. S. Winahju, "Deteksi kapal di laut indonesia menggunakan yolov3," *J. Sains dan Seni ITS*, vol. 10, no. 1, pp. D25–D32, 2021.
- [18] M. Christopher, "Aplikasi Framework YOLO V. 3 untuk Deteksi Pelanggaran Penggunaan Masker," *KALBISIANA J. Sains, Bisnis dan Teknol.*, vol. 9, no. 4, pp. 625–634, 2023.
- [19] R. Gelar Guntara, "Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7," *J. Teknol. Dan Sist. Inf. Bisnis*, vol. 5, no. 1, pp. 55–60, 2023, doi: 10.47233/jteksis.v5i1.750.