

BAB I

PENDAHULUAN

1.1 Latar Belakang

Ikan merupakan hewan kelompok vertebrata yang harus segera diolah setelah diperoleh dari laut karena kualitasnya akan menurun jika tidak mendapat penanganan ataupun pengolahan khusus. Setelah diangkat dari air, pengolahan ikan harus segera dimulai dengan perlakuan panas rendah sembari mempertimbangkan sanitasi. Dengan pertimbangan tersebut maka kesegaran menjadi faktor penentu harga jual dari suatu ikan (Gunawan et al., 2023)

Ikan nila merupakan ikan yang banyak diminati oleh masyarakat sebagai sumber protein hewani. Dan sebagai sumber protein hewani, ikan nila sangat mudah didapatkan di pasaran sehingga sangat mudah terjangkau oleh hampir seluruh lapisan masyarakat (Jebrida, 2017).

Kondisi penanganan ikan di pasaran saat ini terutama di pasar tradisional kurang menerapkan prinsip penanganan dengan hati-hati, cepat, dan bersih, sehingga ikan yang dijual tercemar bahan-bahan kimia maupun mikrobiologi. Menurut , ikan segar umumnya mengandung 65 - 80% air, 17 - 22% protein, 0,5 - 2% lemak, dan 1 - 2% abu. Ikan laut mengandung Poly Unsaturated Fatty Acids (PUFA) seperti EPA (Eicosapentaenoic Acid) dan DHA (Docosahexaenoic Acid). Kadar Omega 3 pada ikan laut adalah lebih tinggi dari ikan air tawar. Kementerian Kelautan dan Perikanan (KKP) menyatakan bahwa konsumsi ikan konsumsi ikan telah meningkat dari 33,89 kg/kapita/tahun pada tahun 2012 menjadi 46,49 kg/kapita/tahun pada tahun 2017 (Sari et al., 2020). Berdasarkan pernyataan tersebut, peningkatan konsumsi ikan di Indonesia juga dapat menjadi salah satu faktor yang meningkatkan potensi ikan tidak segar di pasar. Hal ini dikarenakan permintaan ikan yang meningkat dapat menyebabkan pasokan ikan tidak mencukupi. Akibatnya, pedagang ikan terkadang terpaksa menjual ikan yang sudah tidak segar.

Salah satu cara untuk memeriksa kesegaran dari suatu ikan adalah melihat kondisi mata serta insang ikan tersebut. Ikan yang masih segar memiliki kornea yang masih jernih serta insang yang masih cerah sedangkan ikan yang sudah tidak segar memiliki kornea yang keruh serta insang yang berwarna kecoklatan (Chandra et. al, 2020). Memeriksa kesegaran ikan dengan cara ini tidak menutup kemungkinan terjadinya kesalahan disebabkan manusia yang juga rentan dari kelelahan fisik.

Kegiatan pemeriksaan ini termasuk kegiatan yang repetitif dan terdapat peluang adanya human error saat melakukan pemeriksaan tersebut, baik karena kelelahan ataupun kurang fokus. Agar kesalahan dalam pemeriksaan kesegaran ikan dapat dihindari, dibutuhkan alat ataupun teknologi sebagai alternatif yang dapat membantu mendeteksi kesegaran ikan.

Computer Vision merupakan salah satu teknologi yang dapat menjadi solusi sekaligus tindakan preventif untuk mencegah terjadinya kesalahan-kesalahan yang dapat terjadi jika dilakukan secara manual. Salah satu penelitian menemukan bahwa tingkat kesegaran ikan dapat dideteksi dengan menggunakan mata sebagai indikator tingkat kesegaran ikan dengan tingkat presisi diatas 90% (Banwari et al., 2022). Dari penelitian tersebut, bukan tidak mungkin bahwa computer vision memiliki dampak yang cukup besar sebagai alat bantu dalam menyelesaikan masalah yang ada di sekitar.

Adapun penelitian yang dilakukan sebelumnya mengenai kesegaran ikan, sistem pendeteksi kesegaran ikan berbasis android dapat dilakukan dengan menggunakan algoritma CNN yang menghasilkan akurasi 99% untuk data train, 100% untuk data val, dan 98% untuk data test. Adapun percobaan *training* CNN yang menggunakan K-Fold Cross Validation menghasilkan akurasi 94,81% (Mardiani, 2023)

Pada penelitian ini digunakan algoritma YOLOv8 karena memiliki performa dan ekstraksi fitur yang lebih baik dibandingkan versi sebelumnya dengan kemampuan mendeteksi objek dengan cepat dan akurat. Selain itu YOLOv8 juga memiliki ukuran yang lebih kecil dibanding sebelumnya, sehingga lebih mudah untuk digunakan dan diimplementasikan.

1.2 Teori

1.2.1 Ikan Nila

Ikan nila dikenal dengan nama ilmiah *Oreochromis niloticus*. Nama umum ikan ini berbeda-beda di setiap negara. Di Indonesia, dikenal sebagai ikan nila, sementara di Inggris disebut *nile tilapia*. Gambar Ikan Nila dapat dilihat pada Gambar 1.



Gambar 1 Bentuk Fisik Ikan Nila (*Nila Salin – Kembangkan Potensi Budidaya Ikan di Indonesia, 2023*)

Berdasarkan Gambar 1 dapat dilihat bahwa ikan nila memiliki sisik sikloid dan mulut yang dapat menonjol keluar. Mulut ini biasanya terbatas oleh moncong yang lebar dan sering kali tebal. Rahang ikan ini dilengkapi dengan gigi berbentuk kerucut. Ciri khas nila adalah sirip dorsal yang panjang serta garis lateral yang sering terputus di ujung sirip dorsal, dengan tambahan dua atau tiga baris sisik di bawahnya.

Banyak orang di Indonesia menyukai ikan nila, sehingga permintaan pasar untuk ikan ini tinggi. Ikan ini mudah dibudidayakan dalam berbagai kondisi lingkungan, mulai dari skala kecil seperti di halaman belakang hingga skala besar dengan teknik pembenihan yang intensif. Hal ini mendorong perkembangan industri dan kegiatan pemasaran yang berfokus pada ikan nila. Tingginya permintaan pasar juga memicu upaya pembudidayaan dan peningkatan produksi ikan nila. Di beberapa daerah, budidaya nila sangat menguntungkan karena tingginya penerimaan konsumen, dan praktik produksi dikelola dengan efisien.

1.2.2 Kesegaran Ikan

Ikan termasuk komoditas yang sangat mudah rusak dan membutuhkan penanganan segera setelah dipanen dari laut. Hal ini dapat dilihat pada ikan-ikan yang baru ditangkap dalam beberapa jam saja kalau tidak diberi perlakuan atau penanganan yang tepat, maka mutu ikan tersebut akan menurun (Aldianto, 2021). Perubahan ini terjadi secara fisik, kimiawi maupun biologis. Secara garis besar, perubahan yang dialami ikan berlangsung dalam tiga fase, yaitu fase pre-rigor mortis, rigor mortis, dan post-rigor mortis. Perubahan fase ini dapat digunakan sebagai indikator perubahan kualitas ikan dimana ikan yang masih berada pada fase pre-rigor mortis dan rigor mortis masih dapat dikategorikan sebagai ikan segar (Liviawaty & Afrianto, 2014).

Salah satu cara untuk mengecek kesegaran dari sebuah ikan adalah melihat kondisi dari mata ikan. Dalam SNI 01-2729.2013 tentang spesifikasi ikan segar, mata ikan yang masih segar memiliki kornea dan

pupul yang jernih serta bola mata yang cembung, sedangkan ikan yang sudah kurang segar memiliki kornea yang keruh, pupil yang keabu-abuan, serta bola mata yang cekung.

1.2.3 Visi Komputer

Visi Komputer adalah bidang ilmu yang mempelajari bagaimana mesin dapat menginterpretasikan dan memahami dunia visual melalui citra dan video. Dengan menggunakan teknik dan algoritma dari ilmu komputer, computer vision dapat melakukan tugas seperti pengenalan wajah, klasifikasi objek, deteksi gerakan, dan segmentasi citra. Ini termasuk dalam kategori ilmu komputer yang disebut "perkiraan" (prediction), di mana mesin belajar dari data yang diberikan untuk membuat prediksi atau keputusan berdasarkan citra yang diterima.

Visi Komputer digunakan dalam berbagai bidang, termasuk yang sudah lama dikenal seperti navigasi robot bergerak, inspeksi dalam industri, dan intelijen militer, serta yang lebih baru seperti interaksi antara manusia dan komputer, pencarian gambar di perpustakaan digital, analisis citra medis, dan pembuatan tampilan realistis dari adegan sintetis dalam grafis komputer (Forsyth & Ponce, 2012).

1.2.4 Pengolahan Citra Digital

Citra digital merupakan sebuah larik (*array*) yang berisi nilai-nilai real maupun kompleks yang direpresentasikan dengan deretan bit tertentu. Secara umum, pengolahan citra digital merupakan sebuah proses yang dilakukan untuk mengubah sebuah informasi pada gambar 2 dimensi menggunakan komputer. Proses ini bertujuan untuk meningkatkan kualitas atau mengambil suatu informasi pada gambar tersebut. (Putra, 2010)

Preprocessing adalah sebuah operasi yang dilakukan pada citra digital untuk mengurangi data dan mempermudah proses analisis pada gambar tersebut. Operasi tersebut meliputi ekstraksi *region of interest*, melakukan operasi matematika pada gambar, peningkatan kualitas pada fitur gambar tertentu, perubahan warna, serta merubah resolusi serta kecerahan gambar.

Augmentasi merupakan suatu teknik yang dapat dilakukan untuk meningkatkan jumlah pada dataset dengan merubah suatu informasi pada gambar. Augmentasi dilakukan dengan melakukan modifikasi pada gambar yang sudah ada untuk membuat gambar baru. Teknik yang dilakukan meliputi operasi geometrik seperti *resize*, *rotation*, *flipping*, *translation*, dan *zoom*. (Umbaugh, 2022)

1.2.5 Deep Learning


Deep learning merupakan sub-bidang dari *machine learning* yang mempelajari abstraksi tingkat tinggi dalam data dengan memanfaatkan arsitektur hierarkis. *Deep learning* merupakan pendekatan yang sedang *berkembang* dan telah banyak diterapkan dalam berbagai domain kecerdasan buatan seperti *transfer learning*, *natural language processing*, *computer vision*, dan lain-lain.

Dalam beberapa tahun terakhir, *deep learning* telah dipelajari secara ekstensif pada bidang visi komputer yang mengarah pada munculnya berbagai pendekatan baru. Secara umum, metode tersebut dapat dibagi menjadi 4 kategori yaitu : *Convolutional Neural Network* (CNN), *Restricted Boltzmann Machine* (RBM), Autoencoder, dan *Sparse Coding* (Guo et al., 2016).

1.2.6 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu pendekatan *deep learning* yang sering dipakai dalam kasus visi komputer. Secara umum, CNN terdiri dari tiga lapisan utama, yaitu *convolution*

layer, *pooling layer*, dan *fully connected layer* dimana tiap lapisan memiliki peran yang berbeda. CNN dilatih melalui dua *stage*, yaitu *forward stage* dan *backward stage*. *Forward stage* bertujuan untuk memproses input citra dan menghasilkan sebuah prediksi sedangkan *backward stage* bertujuan untuk menghitung dan memperbarui gradien tiap parameter berdasarkan nilai *loss* pada prediksi sebelumnya. Proses tersebut akan diulang hingga mencapai performa yang optimal (Guo et al., 2016).




Gambar 2 Arsitektur CNN (Sakib et al., 2019)

Convolutional Neural Network terdiri dari beberapa lapisan atau *layer*. Berikut adalah penjelasan mengenai tiap layer :

1. *Input layer*
Data yang akan digunakan dalam operasi CNN akan masuk terlebih dahulu ke dalam lapisan ini. Data tersebut akan dicek pada lapisan ini untuk memastikan bahwa data tersebut kompatibel untuk digunakan.
2. *Convolution layer*
Convolution layer memiliki peran yang cukup penting dalam operasi CNN. Pada *Convolution layer*, filter akan diberikan pada data input yang akan menghasilkan *feature map*. Proses ini dilakukan untuk mendeteksi bagian tepi, tekstur, dan bentuk dalam gambar input.
3. *Pooling layer*
Pooling layer berperan untuk mengurangi dimensi *feature map* dengan mengambil fitur yang relevan. Hal tersebut dapat mengurangi parameter yang digunakan serta kompleksitas data agar komputasi menjadi lebih ringan.
4. *Fully Connected layer*
Pada lapisan ini, fitur yang telah diekstrak pada lapisan sebelumnya akan dipelajari untuk melakukan klasifikasi akhir.
5. *Output layer*
Output layer merupakan lapisan terakhir yang berfungsi untuk menghitung probabilitas setiap kelas pada suatu data.

1.2.7 You Only Look Once (YOLO)

Algoritma *You Only Look Once* atau biasa disingkat YOLO merupakan salah satu algoritma yang sering dipakai pada kasus visi komputer. YOLO mulai diperkenalkan Joseph Redmon dkk. pada CVPR 2016. YOLO merupakan algoritma yang bekerja dengan memandang sekilas pada suatu gambar seperti manusia dan objek apa yang ada dalam gambar, apa yang mereka lakukan, dan di mana mereka berada (Wang et al., 2023).




Gambar 3 Alur Kerja Algoritma YOLO(Redmon et al., 2015)

YOLO bekerja dengan cara membagi gambar input menjadi *grid* $S \times S$. Untuk setiap sel pada *grid*, YOLO akan memprediksi *bounding box* serta nilai *confidence score* sebuah kelas pada tiap sel. Prediksi tersebut berisi informasi mengenai seberapa yakin model bahwa *bounding box* tersebut berisi objek dan seberapa akurat koordinat penempatan *bounding box*.

Mean Average Precision (mAP), merupakan metrik yang sering digunakan untuk mengevaluasi performa model dalam mendeteksi objek. *Precision* mengukur akurasi prediksi positif model, sedangkan *recall* mengukur seberapa baik model mengenali kasus positif. mAP dihitung dengan mempertimbangkan nilai antara *precision* dan *recall* dengan menggunakan kurva *precision-recall* (Terven et al., 2023).


YOLOv8 dirilis pada Januari 2023 oleh *Ultralytics*, perusahaan yang mengembangkan YOLOv5. YOLOv8 rilis dengan 5 versi yang berbeda berdasarkan ukuran modelnya, yaitu YOLOv8n (nano), YOLOv8s (small), YOLOv8m (medium), YOLOv8l (large), YOLOv8x (extra-large).

Refine




Gambar 4 Proses kerja YOLOv8 (Yaseen, 2024)

YOLOv8 memiliki 3 komponen utama dalam melakukan proses deteksi, yaitu *Backbone*, *Neck*, dan *Head*. *Backbone* pada YOLOv8 merupakan CSPDarknet yang telah dioptimisasi untuk mengesktrak fitur pada gambar. Pada bagian ini, ada 3 layer yang dipakai untuk mengekstrak fitur pada gambar, yaitu *Convolutional Layer*, *C2f layer*, dan *SPPF layer*.



Gambar 5 C2f layer(Timilsina, 2024)

Pada *C2f layer*, *feature map* yang dihasilkan oleh *Convolutional layer* akan dipisah dimana sebagian akan masuk ke blok *bottleneck* dan sisanya akan langsung ke blok *Concat*. Blok *bottleneck* bertujuan untuk mengurangi beban komputasi pada proses *training*.



Gambar 6 SPPF layer(Timilsina, 2024)

SPPF layer terdiri dari *Convolutional layer* yang diikuti oleh 3 *MaxPool2d layer*. Pada *layer* ini, *input* gambar akan diubah bentuknya menjadi *grid* dan fitur akan diekstrak pada tiap *cell* yang memungkinkan model untuk menangani gambar dengan ukuran berbeda secara efektif.

Neck pada YOLOv8 bertujuan untuk menyempurnakan fitur *multi-scale* yang telah diekstrak sebelumnya oleh *backbone*. Integrasi fitur *multi-scale* pada komponen ini sangat krusial pada pendeteksian objek untuk berbagai ukuran. Komponen *neck* merupakan Path Aggregation Network (PANet) yang telah dioptimisasi untuk mengurangi beban komputasi pada proses training. Pada bagian ini, ada 4 *layer* yang dipakai untuk mengekstrak fitur pada gambar, yaitu *Convolutional Layer*, *C2f layer*, *Concat layer*, dan *Upsample layer*.(Yaseen, 2024)

Head pada YOLOv8 bertujuan untuk menghasilkan prediksi akhir, termasuk koordinat *bounding box*, nilai *confidence score*, dan label kelas. YOLOv8 menggunakan fungsi CloU dan DFL untuk menghitung nilai *bounding-box loss* serta fungsi *binary cross-entropy* untuk menghitung nilai *classification loss*. Fungsi tersebut meningkatkan performa model dalam deteksi objek, khususnya pada pendeteksian objek berukuran kecil(Terven et al., 2023)

1.2.8 Confusion Matrix

Confusion Matrix merupakan salah satu metrik evaluasi yang digunakan untuk mengukur kemampuan suatu model dalam melakukan klasifikasi. *Confusion matrix* berisi informasi mengenai perbandingan hasil klasifikasi model dan kelas aktual sebuah data. Gambar dibawah merupakan contoh *confusion matrix* yang berukuran 2x2.

		Predicted label	
		1	-1
Actual label	1	True Positive	False Negative
	-1	False Positive	True Negative

Gambar 7 Confusion Matrix(Habibi Aghdam & Jahani Heravi, 2017)

Berdasarkan gambar 7 diatas, ada empat komponen yang digunakan dalam mengevaluasi model. *True Positive* (TP) adalah data yang memiliki label 1 dan terklasifikasi sebagai 1. *False Negative* (FN) adalah data yang memiliki label -1 dan terklasifikasi sebagai 1. *False Positive* (FP) adalah data yang memiliki label 1 dan terklasifikasi sebagai -1. *True Negative* (TN) adalah data yang memiliki label -1 dan terklasifikasi sebagai -1 (Habibi Aghdam & Jahani Heravi, 2017).

Dari keempat komponen tersebut, performa model dapat diukur menggunakan metrik evaluasi seperti *accuracy*, *precision*, dan *recall*. *Accuracy* adalah perbandingan antara prediksi benar dan seluruh prediksi. *Accuracy* dapat dihitung menggunakan rumus pada Persamaan 1.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Precision adalah perbandingan antara prediksi benar kelas positif dan seluruh prediksi pada kelas positif. *Precision* dapat dihitung menggunakan rumus pada Persamaan 2.

$$Precision = \frac{TP}{TP + FP}$$

Recall adalah perbandingan antara prediksi benar kelas positif dan jumlah data kelas positif pada pada klasifikasi. *Recall* dapat dihitung menggunakan rumus pada Persamaan 3.

$$Recall = \frac{TP}{TP + FN}$$

F1-Score adalah *harmonic mean* dari *precision* dan *recall* yang bernilai dari 0 sampai 1 dimana performa model semakin baik seiring dengan besarnya nilai tersebut. *F1-Score* dapat dihitung menggunakan rumus pada Persamaan 4.

$$F1 = \frac{2}{\frac{1}{precision} + \frac{1}{recall}} = \frac{2TP}{2TP + FP + FN}$$

1.3 Rumusan Masalah

Adapun rumusan masalah dari penelitian ini ialah sebagai berikut :

1. Bagaimana implementasi algoritma YOLO dalam klasifikasi kesegaran ikan nila?
2. Bagaimana hasil kinerja model klasifikasi kesegaran ikan nila dalam mengklasifikasi kesegaran ikan nila pada data video?

1.4 Tujuan Penelitian

Adapun tujuan dari penelitian ini ialah sebagai berikut :

1. Mengimplementasikan algoritma YOLO dalam klasifikasi kesegaran ikan nila
2. Menganalisis kinerja model klasifikasi kesegaran ikan nila dalam mengklasifikasi kesegaran ikan nila pada data video.

1.5 Manfaat Penelitian

Adapun manfaat secara umum dari penelitian ini adalah dapat menerapkan ilmu teknologi yang diperoleh, khususnya computer vision di bidang perikanan sekaligus dapat memberikan sumbangsih dalam bidang ilmu perikanan, khususnya pada topik klasifikasi kesegaran pada ikan.

1.6 Ruang Lingkup

Setelah dirumuskan permasalahan, maka ditentukan ruang lingkup penelitian sebagai berikut:

1. Objek yang dideteksi berfokus pada warna mata ikan.
2. Pengambilan data dilakukan dengan kondisi cahaya terang.
3. Sistem deteksi diimplementasikan pada conveyor.

BAB II

METODE PENELITIAN

2.1 Lokasi Penelitian

Penelitian ini dilaksanakan sejak Desember 2023 dimana pengambilan data dilakukan di Pasar Jembatan Toddopuli dan diproses di Laboratorium Kecerdasan Buatan Departemen Teknik Informatika Universitas Hasanuddin.


2.2 Instrumen Penelitian

Berikut adalah instrumen penelitian yang digunakan pada penelitian ini:

1. Perangkat Lunak
 - a. Windows 10x64
 - b. Python
 - c. Visual Studio Code
 - d. Kaggle
 - e. Roboflow
 - f. Jupyter Notebook
 - g. Microsoft Office
 - h. Google Colab
2. Perangkat Keras
 - a. Microsoft Surface Pro 4 Intel Core i7-6600U dengan RAM 16GB dan penyimpanan SSD 512GB
 - b. Kamera digital
3. Jaringan Internet

2.3 Tahapan Penelitian

Tahapan penelitian yang dilaksanakan secara garis besarnya dapat dilihat pada Gambar 8.



Gambar 8 Tahapan Penelitian

Berdasarkan Gambar 8 diatas, penelitian ini memiliki 6 tahapan, yaitu :

1. Studi Literatur

Pada tahap ini, peneliti melakukan kajian literatur terkait topik yang relevan dengan penelitian terkhusus dalam bidang visi komputer. Tujuannya adalah untuk memahami konsep dasar dan perkembangan terbaru terkait penelitian yang akan dilakukan
2. Akuisisi Data

Tahap ini melibatkan pengumpulan data yang diperlukan untuk penelitian. Pengambilan data dilakukan dengan pengambilan video pada objek ikan dalam kondisi diam dan diatas konveyor.
3. Pengolahan Data

Pada Tahap ini, data akan diolah terlebih dahulu sebelum dipakai untuk pembuatan model. Data akan dilabel terlebih dahulu dan dilakukan pre-processing untuk menstandarisasi data.

4. Perancangan Sistem

Pada tahap ini, data akan diproses dan akan dibagi menjadi 3 bagian yaitu data *training*, data *testing*, data *validasi*. Data tersebut kemudian digunakan untuk pembuatan model.

5. Pengujian dengan Konveyor

Pada tahap ini, model akan diuji dengan menggunakan data ikan yang diletakkan diatas konveyor berjalan. Evaluasi model akan dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

6. Pembuatan Laporan

Pada tahap ini, laporan akan dibuat mengenai sistematika penelitian serta hasil dari penelitian yang dilakukan.

2.4 Teknik Pengambilan Data

Data yang digunakan penulis pada penelitian merupakan data primer yang diperoleh langsung oleh penulis. Jumlah ikan yang dikumpulkan sebanyak 50 buah. Sebelum pengambilan data, sebagian ikan akan ditinggalkan di ruangan terbuka selama beberapa jam agar kualitasnya menurun.

Sebelum pengambilan data, objek akan diberikan plastik bening sebagai alas sebelum diletakkan diatas konveyor. Pengambilan data dilakukan menggunakan kamera Logitech Brio Ultra HD. Kamera ini memiliki resolusi 13MP dengan ukuran 1920 x 1080 piksel dan 30 *Frame per Second* (FPS). Kamera terpasang didalam *box* pada konveyor menghadap lurus ke bawah. Skenario jarak antara kamera dan objek adalah 10 cm dan 15 cm. Skenario kecepatan objek yang melalui *conveyor belt* adalah 60 rpm dan 70 rpm. Selama proses pengambilan data, objek akan berorientasi horizontal. Gambar 9 adalah contoh orientasi objek yang akan digunakan dalam pengambilan data.



Gambar 9 Contoh Objek Data Penelitian


Pada saat pengambilan data, ada 2 skenario pengambilan data dengan kecepatan konveyor dan jarak kamera terhadap objek yang berbeda. Skenario kombinasi kecepatan konveyor serta jarak kamera dapat dilihat pada Tabel 1.

Tabel 1 Skenario Pengambilan Data

Skenario	Kecepatan konveyor	Jarak kamera
Skenario 1	60 rpm	10 cm
Skenario 2	70 rpm	15 m

2.5 Rancangan Sistem

Rancangan sistem ini bertujuan untuk memberikan gambaran terhadap alur kerja sistem yang akan dikembangkan serta penjelasan secara detail setiap tahap yang dilakukan dalam pembuatan sistem. Diagram rancangan sistem dapat dilihat pada Gambar 10.



Gambar 10 Flowchart Rancangan Sistem

Berdasarkan Gambar diatas, perancangan sistem terdiri dari 2 tahap, yaitu *training* dan *testing*.

2.5.1 Dataset

Data yang digunakan pada penelitian ini sebanyak 3094 data. Berikut adalah contoh data yang digunakan pada penelitian ini.



(a)



(b)

Gambar 11 Contoh Data Statis (a) Gambar Ikan Segar dan (b) Gambar Ikan Tidak Segar



(a)

(b)


Gambar 12 Contoh Data Konveyor (a) Gambar Ikan Segar dan (b) Gambar Ikan Tidak Segar

Berdasarkan gambar diatas, beberapa gambar diambil menggunakan kamera digital dan kamera pada *box* konveyor dan dilakukan dengan kondisi pencahayaan yang cukup.

Adapun data yang digunakan untuk testing dan validasi terbagi atas 512 data untuk testing dan 406 data untuk validasi dengan tujuan untuk menguji performa model.

2.5.2 Labelling Data

Labelling data adalah proses pengidentifikasian kelas pada data mentah. *Labelling* dilakukan dengan memberikan penanda dalam bentuk *bounding box* pada objek dalam citra. *Labelling* berfungsi sebagai data latih untuk model agar dapat mengidentifikasi data yang belum pernah dilihat sebelumnya berdasarkan ciri-ciri atau detail objek yang telah di label. Di tahap ini, penentuan kelas objek juga dilakukan agar memudahkan model dalam proses klasifikasi saat mendeteksi objek. Proses *labelling* dapat dilihat pada Gambar 13.



Gambar 13 Proses *Labelling* Gambar

2.5.3 Augmentasi Data

Augmentasi data adalah teknik untuk meningkatkan jumlah data dengan melakukan perubahan pada data yang ada. Augmentasi bertujuan untuk menambah variasi data pada dataset. Selain itu, augmentasi juga bertujuan untuk membantu model untuk mengenali objek dalam berbagai orientasi, yang sangat

bermanfaat dalam kasus data uji yang mungkin berbeda dari data latih. Contoh citra yang telah diaugmentasi dapat dilihat pada Gambar 14.



(a)



(b)

Gambar 14 Contoh Augmentasi Data (a) Sebelum Augmentasi dan (b) Sesudah Augmentasi

Augmentasi yang dilakukan pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 2 Parameter Augmentasi

Augmentasi	Parameter
Flip	Horizontal, Vertical
Rotation	Antara -15° dan $+15^\circ$
Saturation	Antara -25% dan +25%
Brightness	Antara -10% dan +10%
Exposure	Antara -10% dan +10%
Blur	Hingga 2.5 piksel

Setelah proses augmentasi, total data yang semula sebanyak 3094 data citra meningkat menjadi 7446 data citra dengan pembagian 6528 data train, 512 data *test*, dan 406 data validasi.

2.5.4 Preprocessing Data

Pada tahap *preprocessing*, setiap data yang digunakan pada penelitian akan di-*resize* terlebih dahulu. *Resize* yang dilakukan pada penelitian ini adalah mengubah resolusi citra data menjadi 640x640 piksel. *Resize* dilakukan karena citra data yang digunakan memiliki resolusi yang bervariasi. Selain itu, *resize* juga dapat mempercepat waktu *training* model karena data yang diinput memiliki ukuran yang lebih kecil dari sebelumnya. Contoh tampilan data sebelum dan setelah di-*resize* dapat dilihat pada Gambar 15.



(a)



(b)

Gambar 15 Contoh *Resize* Data (a) Sebelum *Resize* dan (b) Sesudah *Resize*

2.5.5 Training Model


Pada tahap *training*, model akan dilatih menggunakan algoritma YOLOv8s untuk mendeteksi kesegaran ikan pada data yang telah diproses. Model pada penelitian ini dilatih menggunakan beberapa *hyperparameter*. Selanjutnya, tiap hasil *training* akan dibandingkan untuk mencari *parameter* yang optimal dan akan digunakan pada penelitian ini. Pengaturan *hyperparameter* yang akan dilakukan percobaan pada penelitian ini dapat dilihat pada Tabel 3.

Tabel 3 Parameter *Training Model*

Parameter	Value		
Epoch	20	40	
Image Size	160	320	640
Batch Size	16	32	64
Learning Rate	0,01		
Optimizer	auto	SGD	RMSProp
Momentum	0,397		

2.5.6 Proses Deteksi

Setelah model di-*training*, model akan diuji menggunakan data validasi. Alur sistem pada saat proses deteksi dapat dilihat pada Gambar 16.



Gambar 16 Flowchart Proses Deteksi

Penjelasan secara detail tiap tahapan proses deteksi dijabarkan sebagai berikut.

1. Input data

Proses deteksi dimulai dengan penginputan data serta model yang telah di-*train*. Sebelum data diinput, akan dilakukan *preprocessing* pada data. *Preprocessing* yang dilakukan adalah *resize* dan *augmentasi*. *Resize* dilakukan agar semua data memiliki resolusi yang sama serta untuk mengurangi beban komputasi yang dipakai dalam proses deteksi. *Augmentasi* dilakukan untuk menambah variasi dari data yang telah ada dengan mengubah orientasi serta kecerahan pada data awal.

2. Proses deteksi

Setelah data diinput, sistem akan melakukan klasifikasi menggunakan model yang telah diinput. Model akan terlebih dahulu memproses citra data untuk mencari fitur-fitur yang membuktikan keberadaan objek setelah belajar dari fitur-fitur pada data latih. Selanjutnya, model akan memeriksa hasil deteksi terlebih dahulu hingga sebuah objek ditemukan pada gambar.

3. Output hasil deteksi

Jika hasil deteksi memiliki tingkat *confidence* yang melebihi batas *confidence threshold*, sistem akan menghasilkan output berupa gambar yang memiliki *bounding box* pada objek yang terdeteksi. Contoh gambar hasil prediksi yang berisi *bounding box* serta label kelas yang terdeteksi dapat dilihat pada Gambar 17 .



Gambar 17 Hasil Deteksi Model

Gambar 17 adalah contoh gambar hasil prediksi yang dilakukan oleh model. *Bounding box* akan diberikan pada objek yang terdeteksi serta label dan *confidence score*-nya.

2.5.7 Pengujian dan Evaluasi Sistem

Evaluasi dilakukan untuk menguji performa model dalam mendeteksi objek. Metrik yang digunakan untuk mengevaluasi performamodel pada penelitian ini adalah *confusion matrix*, *accuracy*, *precision*, *recall* dan *F1-score*. Metrik tersebut memberikan informasi mengenai kemampuan model saat melakukan klasifikasi. Data yang dibandingkan pada proses evaluasi adalah data konveyor dengan 30 FPS dan 60 FPS.