

DETEKSI KUALITAS DAGING SAPI LOKAL ACEH MENGUNAKAN YOLOv8 BERBASIS CITRA DIGITAL

TUGAS AKHIR

Diajukan Oleh:

**ARMIS
NIM. 210705017**

**Mahasiswa Fakultas Sains Dan Teknologi
Program Studi Teknologi Informasi**



**FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI AR-RANIRY
BANDA ACEH
2026 M /1448 H**

DETEKSI KUALITAS DAGING SAPI LOKAL ACEH MENGUNAKAN YOLOv8 BERBASIS CITRA DIGITAL

TUGAS AKHIR

Diajukan kepada Fakultas Sains dan Teknologi Universitas Islam Negeri Ar-Raniry Banda Aceh untuk Memenuhi Salah Satu Persyaratan Guna Memperoleh Gelar Strata Satu Sarjana (S1)

**ARMIS
210705017**

**Mahasiswa Fakultas Sains Dan Teknologi
Program Studi Teknologi Informasi**



**FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI AR-RANIRY
BANDA ACEH
2026 M /1448 H**

LEMBAR PERSETUJUAN

DETEKSI KUALITAS DAGING SAPI LOKAL ACEH MENGUNAKAN YOLOv8 BERBASIS CITRA DIGITAL

TUGAS AKHIR

Diajukan Kepada Fakultas Sains dan Teknologi
Universitas Islam Negeri (UIN) Ar-Raniry Banda Aceh
Sebagai Salah Satu Persyaratan Penulisan Tugas Akhir
Dalam Prodi Teknologi Informasi


Oleh:
ARMIS
NIM. 210705017

Mahasiswa Fakultas Sains dan Teknologi
Program Studi Teknologi Informasi

Disetujui Untuk di Munaqasyahkan Oleh :

Pembimbing I,

Pembimbing II,


Dr. Hendri Ahmadian, S.Si., M.I.M.

NIP. 198301042014031002


Fathiah, M.Eng.

NIP. 198606152019032010

Mengetahui,
Ketua Program Studi Teknologi Informasi


Malahayati, M.T.
NIP. 198301272015032003

LEMBAR PENGESAHAN

DETEKSI KUALITAS DAGING SAPI LOKAL ACEH MENGUNAKAN YOLOv8 BERBASIS CITRA DIGITAL

TUGAS AKHIR

Telah Diuji Oleh Panitia Ujian Munaqasyah Tugas Akhir
Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh dan Dinyatakan Lulus
Serta Diterima Sebagai Salah Satu Beban Studi Program Sarjana (S1) Dalam
Program Studi Teknologi Informasi

Pada Hari/Tanggal: Selasa, 04 Agustus 2026 M

20 Safar 1448 H

Di Darussalam Banda Aceh

Panitia Ujian Munaqasyah Tugas Akhir:

Ketua,



Dr. Hendri Ahmadian, S.Si., M.I.M.
NIP. 198301042014031002

Sekretaris,




Fathiah, M.Eng.
NIP. 198606152019032010

Penguji I,



Mahayati, M.T.
NIP.198301272015032003

Penguji II,



Khairan AR, M.Kom.
NIP.198607042014031001

جامعة الرانيري

A R - R A N I R Y

Mengetahui,

Dekan Fakultas Sains dan Teknologi
UIN Ar-Raniry Banda Aceh



Prof. Dr. dr. Muhammad Dirhamsyah, M.T., IPU
NIP.196210021988111001

SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan di bawah ini:

Nama : Armis

NIM : 210705017

Program Studi : Teknologi Informasi

Fakultas : Sains dan Teknologi

Judul : Deteksi Kualitas Daging Sapi Lokal Aceh Menggunakan YOLOv8 Berbasis Citra Digital

Dengan ini menyatakan bahwa dalam penulisan tugas akhir ini, saya:

1. Tidak menggunakan ide orang lain tanpa mampu mengembangkan dan mempertanggungjawabkan;
2. Tidak melakukan plagiasi terhadap naskah karya orang lain;
3. Tidak menggunakan karya orang lain tanpa menyebutkan sumber asli atau tanpa izin pemilik karya;
4. Tidak memanipulasi dan memalsukan data;
5. Mengerjakan sendiri karya ini dan mampu bertanggungjawab atas karya ini.

Bila dikemudian hari ada tuntutan dari pihak lain atas karya saya, dan telah melalui pembuktian yang dapat dipertanggungjawabkan dan ternyata memang ditemukan bukti bahwa saya telah melanggar pernyataan ini, maka saya siap dikenai sanksi berdasarkan aturan yang berlaku di Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh.

Demikian pernyataan ini saya buat dengan sesungguhnya dan tanpa paksaan dari pihak manapun.

A R - R A N I R Y

Banda Aceh, 04 Agustus 2026

Yang Menyatakan,



Armis

NIM. 210705017

ABSTRAK

Nama : Armis
NIM : 210705017
Program Studi : Teknologi Informasi
Judul : Deteksi Kualitas Daging Sapi Lokal Aceh
Menggunakan YOLOv8 Berbasis Citra Digital
Tanggal Sidang : Selasa, 04 Agustus 2026
Jumlah Halaman : 110 Halaman
Pembimbing I : Dr. Hendri Ahmadian, S.Si., M.I.M.
Pembimbing II : Fathiah, M.Eng.

Kualitas daging sapi merupakan salah satu faktor penting yang memengaruhi keamanan pangan dan kesehatan konsumen. Penilaian kualitas daging yang umumnya masih dilakukan secara visual dan manual berpotensi menghasilkan penilaian yang subjektif. Penelitian ini bertujuan untuk menerapkan metode YOLOv8 dalam mendeteksi kualitas daging sapi lokal Aceh berbasis citra digital, serta mengevaluasi performa model menggunakan dataset publik dan dataset lapangan. Dataset yang digunakan terdiri atas dataset publik LOCBEEF dan dataset lapangan yang telah dianotasi menggunakan Roboflow, kemudian dibagi menjadi set data *training* (70%), *validation* (15%), dan *testing* (15%). Proses pelatihan dilakukan menggunakan model YOLOv8n dengan ukuran citra 640×640 piksel serta penerapan augmentasi data berupa *brightness*, *rotation*, dan *horizontal flip*. Hasil penelitian menunjukkan bahwa model memperoleh nilai *Precision* sebesar 94,67%, *Recall* sebesar 85,62%, *F1-score* sebesar 89,92%, *mAP@0.5* sebesar 88,40%, dan *mAP@0.5:0.95* sebesar 67,13%. Hasil pengujian juga mengindikasikan bahwa dataset publik menghasilkan performa yang lebih stabil, sedangkan dataset lapangan memberikan tantangan yang lebih besar akibat variasi pencahayaan, latar belakang, dan kondisi objek. Secara keseluruhan, penelitian ini membuktikan bahwa YOLOv8 mampu mendeteksi kualitas daging sapi lokal Aceh dengan baik, sehingga berpotensi untuk dikembangkan sebagai sistem pendukung keputusan dalam penilaian kualitas daging berbasis citra digital.

Kata kunci: deteksi kualitas daging, YOLOv8, *Deep Learning*, citra digital, daging sapi lokal Aceh

ABSTRACT

Name : Armis
Student Id : 210705017
Study Program : Information Technology
Title : Detection of Local Acehnese Beef Quality Using YOLOv8 Based on Digital Images
Thesis Defense Date : Tuesday, August 4, 2026 language
Total Pages : 110 Pages
Supervisor I : Dr. Hendri Ahmadian, S.Si., M.I.M.
Supervisor II : Fathiah, M.Eng.

Beef quality is a crucial factor affecting food safety and consumer health. Conventional meat quality assessment is generally performed through manual visual inspection, which often leads to subjective judgments. This study aims to implement the YOLOv8 method to detect the quality of local Acehnese beef based on digital images and to evaluate the model's performance using both public and field datasets. The datasets consisted of the LOCBEEF public dataset and a field dataset collected directly by the researcher, which were annotated using Roboflow and divided into training (70%), validation (15%), and testing (15%) sets. The model was trained using YOLOv8n with an Image Size of 640×640 pixels and data augmentation techniques, including brightness adjustment, rotation, and horizontal flipping. The experimental results showed that the model achieved a Precision of 94.67%, Recall of 85.62%, F1-score of 89.92%, mAP@0.5 of 88.40%, and mAP@0.5:0.95 of 67.13%. Furthermore, testing revealed that the public dataset produced more stable performance, while the field dataset presented greater challenges due to variations in lighting conditions, backgrounds, and object appearance. Overall, the findings indicate that YOLOv8 effectively detects the quality of local Acehnese beef and has significant potential to be developed as a digital image-based decision support system for meat quality assessment.

Keywords: *beef quality detection, YOLOv8, Deep Learning, digital image, Acehnese local beef.*

KATA PENGANTAR

Bismillahirrahmanirrahim.

Alhamdulillahirabbil ‘alamin, segala puji dan syukur penulis panjatkan ke hadirat Allah Swt. yang telah melimpahkan rahmat, taufik, hidayah, serta inayah-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul **“Deteksi Kualitas Daging Sapi Lokal Aceh Menggunakan YOLOv8 Berbasis Citra Digital”**. Shalawat dan salam senantiasa tercurahkan kepada Nabi Muhammad saw., beserta keluarga, sahabat, dan seluruh umat beliau yang istiqamah mengikuti ajarannya hingga akhir zaman.

Tugas Akhir ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Teknologi Informasi, Fakultas Sains dan Teknologi, Universitas Islam Negeri Ar-Raniry Banda Aceh. Penelitian ini membahas penerapan metode YOLOv8 dalam mendeteksi dan mengklasifikasikan kualitas daging sapi lokal Aceh berbasis citra digital, dengan menggunakan dataset publik LOCBEEF dan dataset lapangan yang diperoleh dari pasar tradisional.

Penulis menyadari bahwa penyusunan Tugas Akhir ini tidak terlepas dari bantuan, bimbingan, dukungan, dan doa dari berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Bapak Prof. Dr. H. Mujiburrahman, M.Ag., selaku Rektor Universitas Islam Negeri Ar-Raniry Banda Aceh.
2. Bapak Dekan Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh, beserta seluruh jajaran pimpinan fakultas yang telah memberikan dukungan dalam proses perkuliahan dan penyusunan Tugas Akhir ini.
3. Ibu Malahayati, M.T., selaku Ketua Program Studi Teknologi Informasi Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh.
4. Bapak Dr. Hendri Ahmadian, S.Si., M.I.M., selaku Dosen Pembimbing I yang telah memberikan arahan, bimbingan, masukan, serta motivasi kepada penulis dalam proses penyusunan Tugas Akhir ini.

5. Ibu Fathiah, M.Eng., selaku Dosen Pembimbing II yang telah memberikan bimbingan, saran, arahan, serta masukan yang sangat berarti dalam penyempurnaan Tugas Akhir ini.
6. Seluruh dosen dan staf Program Studi Teknologi Informasi Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh yang telah memberikan ilmu, pengalaman, dan bantuan selama penulis menempuh pendidikan.
7. Kedua orang tua tercinta, keluarga, serta orang-orang terdekat yang senantiasa memberikan doa, dukungan moral, semangat, dan kasih sayang yang tidak ternilai selama penulis menjalani proses perkuliahan hingga penyusunan Tugas Akhir ini.
8. Teman-teman seperjuangan Program Studi Teknologi Informasi yang telah memberikan bantuan, semangat, dan dukungan selama proses penyusunan Tugas Akhir ini.

Penulis menyadari bahwa Tugas Akhir ini masih jauh dari kesempurnaan. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang membangun demi perbaikan dan penyempurnaan karya ilmiah ini di masa mendatang. Semoga Tugas Akhir ini dapat memberikan manfaat bagi penulis, pembaca, serta menjadi referensi bagi penelitian selanjutnya, khususnya dalam bidang pengolahan citra digital dan penerapan *Deep Learning* untuk deteksi kualitas pangan.

Banda Aceh 04 Agustus 2026
Penulis,

Armis
NIM. 210705017

DAFTAR ISI

LEMBAR PERSETUJUAN.....	iii
LEMBAR PENGESAHAN	iv
SURAT PERNYATAAN KEASLIAN TUGAS AKHIR.....	v
ABSTRAK	vi
KATA PENGANTAR.....	viii
DAFTAR ISI	x
DAFTAR TABEL.....	xii
DAFTAR GAMBAR	xiii
DAFTAR GRAFIK	xiv
DAFTAR SINGKATAN	xv
 BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	3
1.4 Batasan Masalah.....	3
1.5 Manfaat Penelitian	4
 BAB II TINJAUAN PUSTAKA	5
2.1 Penelitian Terdahulu.....	5
2.2 Landasan Teori	7
2.3 Metode Evaluasi Model	12
2.4 Kerangka Teori.....	13
2.5 Kerangka Berpikir.....	14
 BAB III METODE PENELITIAN.....	15
3.1 Jenis dan Pendekatan Penelitian.....	15
3.2 Objek dan Subjek Penelitian.....	15
3.3 Validasi Data	15
3.4 Tahapan Penelitian	17
3.5 Metode Pengumpulan Data	18
3.6 Metode Simulasi	23
3.7 Metode Analisis Data	26
 BAB IV HASIL PENELITIAN DAN PEMBAHASAN	29
4.1 Dataset Penelitian.....	29
4.2 Hasil Pra-pemrosesan dan Anotasi Data	35
4.3 Dataset dan Penerapan <i>Deep Learning</i> YOLOv8	42
4.4 Pengujian dan Evaluasi Kinerja Model.....	50

4.5 Analisis <i>Confusion matrix</i> dan Kesalahan Prediksi	64
4.6 Perbandingan Dataset Publik dan Dataset Lapangan.....	68
4.7 Pembahasan dan Interpretasi Hasil	79
BAB V KESIMPULAN DAN SARAN.....	85
5.1 Kesimpulan	85
5.2 Saran.....	86
DAFTAR PUSTAKA.....	88
LAMPIRAN.....	90



DAFTAR TABEL

Tabel 2. 1 Studi Terkait Penelitian	6
Tabel 4. 1 Distribusi Dataset Berdasarkan Sumber Data dan Kelas	32
Tabel 4. 2 Perbandingan Karakteristik Dataset Publik dan Dataset Lapangan	33
Tabel 4. 3 Pembagian Dataset	37
Tabel 4. 4 Teknik Augmentasi Data	40
Tabel 4. 5 Ringkasan Hasil Pra-pemrosesan dan Anotasi Data	41
Tabel 4. 6 Parameter Pelatihan Model YOLOv8	42
Tabel 4. 7 Ringkasan Perkembangan Pelatihan Model YOLOv8	49
Tabel 4. 8 Ringkasan Pengujian Visual Model	54
Tabel 4. 9 Hasil Evaluasi Kinerja Model YOLOv8	54
Tabel 4. 10 Ringkasan Evaluasi Kinerja Model	63
Tabel 4. 11 Perbandingan Karakteristik Dataset Publik dan Dataset Lapangan ...	70
Tabel 4. 12 Perbandingan Performa Dataset Publik dan Dataset Lapangan	73
Tabel 4. 13 Perbandingan Hasil Confusion Matrix	77
Tabel 4. 14 Perbandingan Hasil Precision-Recall Curve	78
Tabel 4. 15 Perbandingan penelitian ini dengan penelitian sebelumnya	82



DAFTAR GAMBAR


Gambar 2. 1 Arsitektur Convolutional Neural Network (CNN) [Sumber : Sena, 2022]	8
Gambar 2. 2 Arsitektur Keseluruhan YOLOv8 [Sumber : Terven & Cordova-Esparza, 2023].....	11
Gambar 2. 3 Kerangka Berpikir	14
 Gambar 3. 1 Daging Segar dan Daging Busuk	16
Gambar 3. 2 Tahapan Penelitian	17
Gambar 3. 3 Proses Pengambilan Dataset.....	18
Gambar 3. 4 Struktur File Dataset.....	19
Gambar 3. 5 Contoh Proses Resize Foto [Sumber : Roboflow. 2026.].....	20
Gambar 3. 6 Contoh gambar normalisasi [Sumber : Medium. 2024].....	21
Gambar 3. 7 Contoh Proses Augmentasi.....	21
Gambar 3. 8 Contoh Proses Anotasi	22
Gambar 3. 9 Proses Pemisahan Data.....	23
Gambar 3. 10 Flow Pengujian.....	26
 Gambar 4. 1 Contoh Dataset Publik.....	30
Gambar 4. 2 Contoh Dataset Lapangan	31
Gambar 4. 3 Proses Anotasi Dataset Menggunakan Roboflow	36
Gambar 4. 4 Struktur Dataset Format YOLO	37
Gambar 4. 5 Proses Pembagian Dataset di Roboflow.....	38
Gambar 4. 6 Proses Resize Citra.....	39
Gambar 4. 7 Contoh Hasil Augmentasi Data	40
Gambar 4. 11 Hasil Pengujian Model pada Kelas Fresh.....	51
Gambar 4. 12 Hasil Pengujian Model pada Kelas Fresh dan Rotten	52
Gambar 4. 13 Hasil Pengujian Model dengan Confidence Bervariasi.....	53
Gambar 4. 14 Contoh Kesalahan Prediksi Model.....	67

جامعة الرانري

A R - R A N I R Y

DAFTAR GRAFIK

Grafik 4. 1 Grafik Distribusi Dataset	33
Grafik 4. 2 Grafik Hasil Pelatihan Model YOLOv8	44
Grafik 4. 3 <i>Training</i> Loss	45
Grafik 4. 4 <i>Validation</i> Loss	45
Grafik 4. 5 Metric Evaluasi	46
Grafik 4. 6 Precision-Confidence Curve	59
Grafik 4. 7 Recall-Confidence Curve	60
Grafik 4. 8 F1-Confidence Curve	61
Grafik 4. 9 Precision-Recall Curve	62
Grafik 4. 10 Confusion matrix Normalized	64
Grafik 4. 11 Grafik Hasil Pelatihan Dataset Publik	72
Grafik 4. 12 Grafik Hasil Pelatihan Dataset Lapangan.....	72
Grafik 4. 13 Confusion matrix Dataset Publik.....	75
Grafik 4. 14 Confusion matrix Dataset Lapangan	76
Grafik 4. 15 Precision-Recall Curve Dataset Publik.....	77
Grafik 4. 16 Precision-Recall Curve Dataset Lapangan	78



DAFTAR SINGKATAN

Singkatan	Nama	Pemakaian pertama kali pada halaman
AI	Artificial intelligence	2
AP	Average precision	60
C2f	Cross stage partial with two convolutions	11
CNN	Convolutional neural network	5
DCT	Discrete cosine transform	6
DFL	Distribution focal loss	46
FN	False negative	14
FP	False positive	14
GLCM	Gray level co-occurrence matrix	6
GPU	Graphics processing unit	30
IoU	Intersection over union	14
mAP	Mean average precision	14
RAM	Random access memory	26
R-CNN	Region convolutional neural network	8
RGB	Red, green, blue	71
RPH	Rumah potong hewan	2
TN	True negative	14
TP	True positive	13
UIN	Universitas islam negeri	ii
YOLO	You only look once	2

BAB I

PENDAHULUAN

1.1 Latar Belakang

Daging sapi merupakan salah satu bahan pangan utama yang berperan penting dalam memenuhi kebutuhan gizi masyarakat Indonesia (Soeparno, 2021). Konsumsi daging sapi tidak hanya meningkat pada momen tertentu seperti hari besar keagamaan, tetapi juga dalam kehidupan sehari-hari (Kinter & Sherman, 2024). Kualitas daging sapi sangat menentukan nilai gizi, cita rasa, daya simpan, serta keamanan pangan bagi masyarakat (Soeparno, 2021). Oleh karena itu, penilaian kualitas daging menjadi aspek penting dalam rantai distribusi pangan.

Kebutuhan daging sapi di Provinsi Aceh menunjukkan tren yang cukup tinggi dan terus meningkat setiap tahunnya (Badan Pusat Statistik Aceh, 2024). Berdasarkan data terbaru, kebutuhan daging di Aceh mencapai sekitar 9.618 ton per tahun, dengan kebutuhan khusus pada momen tradisional seperti *meugang* mencapai sekitar 1.500 ton (Badan Pusat Statistik Aceh, 2024). Tingginya permintaan ini menunjukkan bahwa daging sapi merupakan komoditas pangan yang memiliki peran penting dalam kehidupan masyarakat Aceh.

Selain itu, aktivitas perdagangan dan distribusi daging sapi di Aceh melibatkan rantai distribusi yang cukup panjang, mulai dari produsen, pedagang grosir, hingga pedagang eceran sebelum sampai ke konsumen (Organization, World Health, 2023). Sebagian besar pasokan daging sapi di Aceh berasal dari dalam wilayah provinsi itu sendiri, dengan persentase mencapai 98,48%. Hal ini menunjukkan bahwa peredaran daging sapi di Aceh sangat aktif dan berfokus pada pemenuhan kebutuhan lokal masyarakat (Badan Pusat Statistik Aceh, 2024).

Tingginya volume perdagangan dan konsumsi daging sapi tersebut juga diiringi dengan potensi risiko keamanan pangan. Proses distribusi yang panjang serta kondisi penyimpanan yang kurang optimal dapat menyebabkan penurunan kualitas daging, bahkan berpotensi menimbulkan kasus keracunan pangan (Organization, World Health, 2023). Oleh karena itu, diperlukan suatu

sistem yang mampu membantu mendeteksi kualitas daging secara otomatis dan akurat guna meminimalisir risiko konsumsi daging yang tidak layak.

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence/AI*) dan pengolahan citra digital (*digital image processing*) membuka peluang baru dalam melakukan deteksi dan klasifikasi objek secara otomatis dan akurat. Salah satu pendekatan modern untuk deteksi objek berbasis citra adalah YOLO (*You Only Look Once*). YOLO merupakan algoritma deteksi satu tahap (*One-stage detector*) yang mampu melakukan deteksi dan klasifikasi dalam satu kali proses, sehingga menghasilkan prediksi yang cepat dan efisien (Goodfellow et al., 2021).

Versi terbaru dari algoritma ini, yaitu YOLOv8, menawarkan peningkatan signifikan dalam hal akurasi, efisiensi komputasi, stabilitas pelatihan, dan kemampuan generalisasi. Peningkatan tersebut diperoleh melalui integrasi komponen seperti Area Attention, R-ELAN, dan FlashAttention. YOLOv8 dapat bekerja dengan cepat bahkan pada perangkat dengan sumber daya terbatas, sehingga sangat potensial untuk diterapkan dalam pemeriksaan kualitas daging secara langsung di pasar.

Selain itu, penelitian ini memanfaatkan dataset gabungan, yakni dataset publik LOCBEEF dan dataset lapangan yang dikumpulkan langsung dari pasar tradisional Aceh. Pendekatan ini bertujuan untuk memastikan bahwa model yang dikembangkan tidak hanya mampu bekerja pada citra standar, tetapi juga mampu mengatasi variasi kondisi nyata seperti pencahayaan, sudut pengambilan gambar, dan latar belakang berbeda.

Dengan adanya teknologi ini, proses deteksi dan klasifikasi kualitas daging dapat dilakukan secara objektif, cepat, dan konsisten. Sistem berbasis YOLOv8 diharapkan dapat diterapkan oleh pedagang, konsumen, maupun petugas RPH untuk meningkatkan kualitas pengawasan dan mengurangi risiko kesehatan masyarakat.

Dengan latar belakang tersebut, penelitian ini menjadi penting untuk dilakukan sebagai upaya dalam meningkatkan keamanan pangan serta memberikan solusi berbasis teknologi dalam mendeteksi kualitas daging sapi di masyarakat.

Berdasarkan latar belakang di atas, maka penulis tertarik mengambil judul Deteksi Kualitas Daging Sapi Lokal Aceh Menggunakan YOLOv8 Berbasis Citra Digital.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, maka rumusan masalah dalam penelitian ini adalah:

1. Bagaimana membangun dataset gabungan yang terdiri dari dataset LOCBEEF dan dataset lapangan dari pasar tradisional Aceh?
2. Bagaimana merancang sistem deteksi dan klasifikasi kualitas daging sapi menggunakan metode YOLOv8 berbasis citra digital?
3. Bagaimana performa model YOLOv8 dalam membedakan daging sapi segar dan busuk pada dataset gabungan tersebut?

1.3 Tujuan Penelitian

Tujuan dari Penelitian ini adalah:

1. Mengumpulkan dan menyusun dataset citra kualitas daging sapi dengan menggabungkan dataset LOCBEEF dan dataset lapangan dari Aceh.
2. Merancang sistem deteksi dan klasifikasi kualitas daging sapi menggunakan metode YOLOv8 berbasis citra digital.
3. Mengevaluasi performa YOLOv8 menggunakan metrik, presisi, *Recall*, *F1-score*, dan *mAP*

1.4 Batasan Masalah

Agar penelitian lebih terarah, maka penelitian ini dibatasi pada:

1. Dataset yang digunakan adalah kombinasi dari dataset publik LOCBEEF dan dataset lapangan hasil pengambilan foto langsung di pasar tradisional Aceh.
2. Kategori yang digunakan terbatas pada dua kelas, yaitu daging sapi segar dan daging sapi busuk.
3. Metode deteksi objek yang digunakan adalah YOLOv8.
4. Penelitian hanya berfokus pada pembangunan model deteksi dan klasifikasi kualitas daging sapi berbasis citra digital, tanpa mengembangkan aplikasi khusus untuk implementasi lebih lanjut.


1.5 Manfaat Penelitian

1. Manfaat Teoritis

Penelitian ini memberikan kontribusi terhadap pengembangan ilmu pengetahuan di bidang teknologi informasi, khususnya pada penerapan *Deep Learning* dalam pengolahan citra digital. Penelitian ini juga dapat menjadi referensi bagi penelitian selanjutnya yang berfokus pada sistem deteksi dan klasifikasi kualitas daging menggunakan metode deteksi objek modern seperti YOLOv8.

2. Manfaat Praktis

Penelitian ini bermanfaat dalam membantu pedagang, konsumen, maupun petugas Rumah Potong Hewan (RPH) untuk memverifikasi kualitas daging sapi lokal Aceh secara cepat, objektif, dan efisien. Selain itu, penelitian ini juga dapat memberikan alternatif solusi dalam mendukung keamanan pangan lokal dengan memanfaatkan teknologi kecerdasan buatan.



BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian terdahulu merupakan salah satu bagian penting dalam suatu penelitian karena memberikan gambaran mengenai perkembangan metode, pendekatan, dan hasil penelitian yang telah dilakukan oleh peneliti sebelumnya.

Penelitian oleh Benny Elia dan I Dewa Made Bayu Atmaja Darmawan (2022) berjudul *Klasifikasi Kesegaran Daging Sapi Menggunakan Deep Learning Arsitektur VGG16 Dengan Augmentasi Citra* menggunakan metode VGG16 untuk mengklasifikasikan tingkat kesegaran daging sapi berdasarkan citra digital. Hasil penelitian menunjukkan bahwa model mampu memperoleh akurasi yang tinggi setelah dilakukan augmentasi citra. Namun, penelitian ini masih menggunakan pendekatan klasifikasi sehingga belum mampu mendeteksi lokasi objek secara langsung.

Penelitian oleh Teris Ekamila dkk. (2023) mengembangkan aplikasi mobile untuk mengidentifikasi kesegaran daging sapi menggunakan metode Convolutional Neural Network (CNN). Sistem yang dikembangkan mampu mengenali tingkat kesegaran daging berdasarkan citra yang diambil melalui kamera ponsel. Meskipun memberikan hasil yang baik, penelitian ini hanya melakukan klasifikasi citra dan belum menerapkan metode *object detection*.

Penelitian oleh Lutfiyatul Malikah dkk. (2025) membandingkan performa arsitektur AlexNet dan VGG16 dalam klasifikasi kualitas daging sapi. Hasil penelitian menunjukkan bahwa VGG16 memiliki performa yang lebih baik dibandingkan AlexNet dalam mengenali kualitas daging berdasarkan citra digital. Akan tetapi, penelitian ini masih terbatas pada klasifikasi citra dan belum mendukung deteksi objek secara langsung.

Penelitian oleh Joanna Andini Prabaningrum Pasya dan Muhammad Fachrie (2025) menerapkan YOLOv8 untuk mendeteksi kesegaran daging ayam berdasarkan citra digital. Hasil penelitian menunjukkan bahwa YOLOv8 mampu melakukan deteksi secara *real-time* dengan performa yang baik. Namun, objek

penelitian masih terbatas pada daging ayam sehingga memiliki karakteristik yang berbeda dengan penelitian ini.

Penelitian oleh Cakra, Samsuddin, dan Fitriani Kahar (2024) menggunakan arsitektur VGG16 untuk mengklasifikasikan tingkat kesegaran daging sapi berdasarkan citra digital. Model yang dikembangkan mampu membedakan daging segar dan tidak segar dengan hasil yang baik. Meskipun demikian, penelitian ini masih menggunakan metode klasifikasi dan belum menerapkan *object detection* seperti pada penelitian ini.

Tabel 2. 1 Studi Terkait Penelitian

No	Penulis	Metode	Objek Penelitian	Hasil
1	Benny Elia & I Dewa Made Bayu Atmaja Darmawan (2022)	VGG16 (CNN)	Kesegaran daging sapi	Berhasil mengklasifikasikan kesegaran daging sapi dengan akurasi tinggi.
2	Teris Ekamila, Fajar Rahayu, Achmad Zuchriadi, & Andhika Octa Indarso (2023)	CNN	Kesegaran daging sapi	CNN mampu mengidentifikasi kesegaran daging melalui aplikasi mobile.
3	Lutfiyatul Malikah, Wiwit Agus Triyanto, & Pratomo Setiaji (2025)	AlexNet & VGG16	Kualitas daging sapi	VGG16 memberikan performa lebih baik dibandingkan AlexNet.
4	Joanna Andini Prabaningrum Pasya & Muhammad Fachrie (2025)	YOLOv8	Kesegaran daging ayam	YOLOv8 mampu mendeteksi kesegaran daging ayam secara <i>real-time</i> .
5	Cakra, Samsuddin, & Fitriani Kahar (2024)	VGG16 (CNN)	Kesegaran daging sapi	VGG16 berhasil mengklasifikasikan kesegaran daging sapi dengan baik.

Berdasarkan Tabel 2.1, dapat diketahui bahwa penelitian mengenai klasifikasi dan deteksi kualitas daging telah mengalami perkembangan yang cukup pesat dengan memanfaatkan berbagai metode, mulai dari Convolutional Neural Network (CNN), VGG16, AlexNet, hingga YOLOv8. Hasil penelitian terdahulu menunjukkan bahwa metode *Deep Learning* mampu memberikan performa yang baik dalam mengidentifikasi kualitas daging berdasarkan citra digital. Namun, sebagian besar penelitian masih berfokus pada proses klasifikasi citra, sehingga hanya menghasilkan informasi mengenai kategori daging tanpa menunjukkan lokasi objek yang terdeteksi.

Selain itu, sebagian besar penelitian terdahulu menggunakan dataset yang berasal dari satu sumber dan belum mengombinasikan dataset publik dengan dataset lapangan. Oleh karena itu, penelitian ini menerapkan algoritma YOLOv8 untuk mendeteksi kualitas daging sapi menggunakan gabungan dataset publik LOCBEEF dan dataset lapangan yang diperoleh dari pasar tradisional di Aceh. Dengan pendekatan tersebut, sistem tidak hanya mampu mengklasifikasikan kualitas daging, tetapi juga mendeteksi lokasi objek secara *real-time* melalui *Bounding box*, sehingga diharapkan menghasilkan model yang lebih adaptif terhadap kondisi nyata.

2.2 Landasan Teori

Kualitas daging sapi merupakan tingkat kesesuaian karakteristik fisik, kimia, dan biologis daging terhadap standar keamanan pangan dan kebutuhan konsumen. Penilaian kualitas daging umumnya dilakukan berdasarkan beberapa indikator, seperti warna, tekstur, aroma, tingkat kelembapan, dan keberadaan lendir pada permukaan daging. Perubahan karakteristik tersebut dapat menjadi indikasi bahwa daging telah mengalami proses pembusukan akibat aktivitas mikroorganisme maupun faktor lingkungan selama penyimpanan dan distribusi.

2.2.1 Citra Digital

Citra digital adalah representasi visual dari suatu objek atau lingkungan yang disimpan dalam bentuk data piksel. Dalam konteks pengolahan citra, setiap piksel menyimpan informasi intensitas cahaya dalam spektrum warna tertentu. Proses pengolahan citra digital meliputi tahapan seperti akuisisi citra, pra-pemrosesan


(seperti resizing, normalisasi, dan augmentasi), ekstraksi fitur, hingga klasifikasi atau deteksi objek.

2.2.2 Deep Learning

Deep Learning merupakan cabang dari *machine learning* yang menggunakan jaringan saraf tiruan bertingkat (*deep neural network*) untuk mengekstraksi fitur dan melakukan prediksi atau klasifikasi. Dalam pengolahan citra, model *Deep Learning* seperti CNN (*Convolutional Neural Network*) telah terbukti sangat efektif untuk mengenali pola visual secara otomatis tanpa memerlukan teknik ekstraksi fitur manual.

2.2.3 Convolutional Neural Network / CNN

CNN adalah arsitektur jaringan syaraf tiruan yang secara khusus dirancang untuk memproses data visual seperti gambar. CNN mampu mengenali pola visual melalui proses ekstraksi fitur secara otomatis menggunakan operasi konvolusi. Struktur dasar CNN terdiri dari lapisan input, convolution layer, pooling layer, fully connected layer, dan output layer. CNN digunakan dalam berbagai tugas visi komputer, termasuk klasifikasi citra, deteksi objek, dan segmentasi. YOLO sendiri merupakan pengembangan lebih lanjut dari prinsip CNN yang dioptimalkan untuk deteksi objek secara *real-time*.



Gambar 2. 1 Arsitektur Convolutional Neural Network (CNN) [Sumber : Sena, 2022]

Berdasarkan gambar arsitektur *Convolutional Neural Network* (CNN) di atas, penjelasan tahapan kerjanya dapat dijabarkan secara runtut ke dalam dua bagian besar, yaitu Feature Learning dan Classification:

1. Tahap Pembelajaran Fitur (*Feature Learning*)

Tahap ini berfungsi untuk mengekstraksi pola visual, bentuk, garis, dan karakteristik penting dari citra masukan secara otomatis. Lapisan-lapisannya meliputi:

- a. Input, Citra masukan (misalnya gambar mobil) dimasukkan ke dalam jaringan dalam bentuk matriks piksel multi-saluran (seperti RGB).
- b. Convolution + ReLU, Lapisan konvolusi menerapkan filter (*kernel*) yang bergeser ke seluruh bagian gambar untuk menghasilkan *feature map* yang mendeteksi fitur-fitur dasar (seperti tepi dan sudut). Fungsi aktivasi ReLU (*Rectified Linear Unit*) kemudian diterapkan untuk menambahkan sifat non-linear, mengubah nilai negatif menjadi nol agar jaringan hanya mempelajari pola yang relevan.
- c. Pooling, Lapisan ini bertugas mereduksi dimensi atau ukuran *feature map* (pengecilan resolusi spasial) dengan tetap mempertahankan informasi fitur yang paling dominan. Hal ini bertujuan untuk mengurangi kompleksitas komputasi dan mencegah *overfitting*.

2. Tahap Klasifikasi (*Classification*)

Setelah fitur penting berhasil dipelajari oleh bagian sebelumnya, tahap ini bertugas untuk membaca pola tersebut dan menentukan kategori objek:

- a. Flatten, Mengubah matriks data dua atau tiga dimensi dari hasil *feature learning* menjadi sebuah vektor satu dimensi yang lurus (*flat vector*), agar dapat diproses oleh lapisan jaringan saraf tiruan biasa.
- b. Fully Connected, Lapisan di mana setiap neuron terhubung secara penuh ke seluruh neuron di lapisan berikutnya. Pada tahap ini, jaringan mulai menggabungkan seluruh fitur yang telah diekstrak untuk melakukan penalaran tingkat tinggi.
- c. Softmax (Output), Lapisan akhir yang menggunakan fungsi aktivasi *Softmax* untuk menghasilkan nilai probabilitas dari berbagai kelas target (seperti *Car*, *Truck*, *Van*, hingga *Bicycle*). Kelas dengan nilai probabilitas tertinggi akan dipilih sebagai hasil akhir prediksi dari model.

2.2.4 Deteksi Objek (*Object Detection*)

Deteksi objek adalah proses menemukan dan mengklasifikasikan objek dalam suatu citra beserta posisi lokasinya dalam bentuk *Bounding box*. Berbeda

dengan klasifikasi biasa yang hanya menentukan jenis objek dalam citra secara keseluruhan, deteksi objek bertugas memberikan label serta koordinat objek tersebut. Metode deteksi objek modern terbagi menjadi dua kelompok: dua tahap (*two-stage*) seperti R-CNN, dan satu tahap (*one-stage*) seperti YOLO dan SSD. Metode one-stage lebih cepat dan cocok untuk aplikasi *real-time* seperti yang digunakan dalam penelitian ini.

2.2.5 YOLO (*You Only Look Once*)

YOLO adalah algoritma *object detection* berbasis CNN, yang dirancang untuk melakukan deteksi dan klasifikasi objek dalam satu proses komputasi tunggal. Berbeda dengan metode konvensional yang memisahkan proses *region proposal* dan klasifikasi, YOLO membagi gambar ke dalam grid dan secara simultan memprediksi *Bounding box* serta kelas objek dalam satu waktu. YOLO terkenal karena kecepatan dan efisiensinya, sehingga cocok untuk aplikasi *real-time* seperti deteksi kualitas daging langsung dari kamera.

2.2.6 YOLOv8

YOLOv8 merupakan salah satu algoritma deteksi objek terbaru yang dikembangkan oleh *Ultralytics* pada tahun 2023 sebagai bagian dari keluarga YOLO (*You Only Look Once*). Model ini dirancang untuk meningkatkan akurasi dan efisiensi dalam mendeteksi objek secara *real-time* melalui pendekatan arsitektur yang lebih modern dan sederhana dibandingkan versi sebelumnya (Jocher et al., 2023.).

Salah satu perbedaan utama YOLOv8 dibandingkan versi sebelumnya adalah penggunaan pendekatan *Anchor-free*, yaitu model tidak lagi bergantung pada *anchor box* dalam memprediksi lokasi objek. Dengan pendekatan ini, proses pelatihan menjadi lebih stabil dan fleksibel terhadap variasi bentuk serta ukuran objek (Redmon et al., 2020).

Selain itu, YOLOv8 juga menerapkan *DeCoupled Head*, yaitu pemisahan antara proses klasifikasi dan regresi *Bounding box*. Pemisahan ini memungkinkan model untuk mempelajari masing-masing tugas secara lebih optimal, sehingga dapat meningkatkan akurasi dalam mendeteksi dan mengklasifikasikan objek.

Dari segi arsitektur, YOLOv8 menggunakan *backbone* dan *neck* yang telah dioptimalkan untuk meningkatkan efisiensi komputasi tanpa mengorbankan


performa. Model ini juga dirancang agar dapat berjalan dengan baik pada perangkat dengan sumber daya terbatas, sehingga sangat cocok untuk aplikasi *real-time* seperti deteksi kualitas daging berbasis citra digital.

Dalam implementasi algoritma *You Only Look Once version 8* (YOLOv8) untuk pengolahan citra digital, ukuran piksel citra masukan (*imgsz*) merupakan salah satu parameter hipermetrik (*hyperparameter*) penting yang menentukan dimensi tensor saat data diproses oleh jaringan saraf tiruan (Explore Ultralytics YOLOv8 | Ultralytics, 2023).

Standar Penggunaan (Default/Standar): Resolusi standar yang paling lazim dan direkomendasikan secara umum dalam pelatihan model dasar (seperti varian YOLOv8n) adalah 640×640 piksel. Ukuran ini dipilih karena mampu memberikan titik keseimbangan (*trade-off*) yang optimal antara tingkat akurasi deteksi objek dan efisiensi kompleksitas komputasi (Explore Ultralytics YOLOv8 | Ultralytics, 2023).

Selain itu, YOLOv8 memiliki kemampuan yang lebih luas dibandingkan versi sebelumnya, karena tidak hanya digunakan untuk deteksi objek, tetapi juga mendukung tugas lain seperti klasifikasi citra, segmentasi objek, dan pose estimation dalam satu *Framework* yang terintegrasi.

Dengan berbagai keunggulan tersebut, YOLOv8 menjadi metode yang tepat untuk digunakan dalam penelitian ini, karena mampu melakukan deteksi dan klasifikasi objek secara cepat, akurat, dan konsisten dalam kondisi lingkungan yang beragam.



Gambar 2. 2 Arsitektur Keseluruhan YOLOv8 [Sumber : Terven & Cordova-Esparza, 2023]

2.2.7 Dataset LOCBEEF dan Dataset Lapangan Aceh

Dataset LOCBEEF adalah dataset citra daging sapi lokal Aceh yang tersedia di platform Kaggle. Dataset ini berisi ribuan citra daging sapi dengan dua kategori utama: segar dan busuk. Namun, dataset ini tidak sepenuhnya mencerminkan kondisi nyata di pasar lokal.

Pada penelitian ini, dataset LOCBEEF dikombinasikan dengan dataset lapangan yang diambil langsung dari pasar tradisional Aceh. Pengambilan dataset lapangan dilakukan menggunakan kamera smartphone dengan berbagai variasi pencahayaan, latar belakang, dan sudut pengambilan gambar. Kombinasi dua sumber data ini membuat model lebih robust dan mampu mendeteksi kondisi daging dalam lingkungan nyata.

2.3 Metode Evaluasi Model

Evaluasi model dalam *machine learning* merupakan langkah penting untuk mengukur kinerja sistem dalam mengklasifikasikan data (Padilla et al., 2021). Dalam penelitian ini, evaluasi dilakukan untuk mengetahui seberapa baik model YOLO dalam membedakan antara daging sapi segar dan busuk berdasarkan citra digital. Metode evaluasi dilakukan menggunakan sejumlah metrik umum yang digunakan dalam klasifikasi dan deteksi objek.

Berikut adalah metode evaluasi yang digunakan:

2.3.1 Presisi (*Precision*)

Presisi mengukur berapa banyak prediksi positif yang benar-benar relevan. Artinya, dari semua prediksi “busuk”, berapa yang benar-benar busuk.

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

Presisi tinggi berarti kesalahan *false positive* rendah. Dalam konteks ini, berarti sistem tidak terlalu sering salah mengklasifikasikan daging segar sebagai busuk.

2.3.2 Recall (*Sensitivity*)

Recall mengukur berapa banyak data positif yang berhasil dikenali oleh model. Artinya, dari semua daging busuk yang ada, berapa yang berhasil dideteksi oleh sistem.

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

Recall tinggi menunjukkan kemampuan model dalam mendeteksi seluruh kasus positif (busuk)

2.3.3 *F1-score*

F1-score adalah rata-rata harmonis antara presisi dan *Recall*. Cocok digunakan ketika distribusi kelas tidak seimbang.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Nilai F1 berada antara 0 hingga 1, di mana 1 menunjukkan performa terbaik. *F1-score* ideal jika presisi dan *Recall* seimbang.

2.3.4 *Confusion matrix*

Confusion matrix adalah representasi visual dari performa model deteksi dan klasifikasi dalam bentuk tabel 2×2 (untuk dua kelas). Tabel ini menunjukkan jumlah kasus benar dan salah untuk masing-masing kelas. Contohnya:

	Prediksi Segar	Prediksi Busuk
Sebenarnya Segar →	TN	FP
Sebenarnya Busuk →	FN	TP

Dengan *confusion matrix*, kita bisa memahami jenis kesalahan yang dilakukan oleh model dan memperbaikinya.

2.3.5 *Mean Average Precision (mAP)*

Untuk model deteksi objek seperti YOLO, digunakan metrik *Mean Average Precision (mAP)*, yang mempertimbangkan kombinasi dari presisi dan *Recall* pada berbagai tingkat ambang batas *Intersection over Union (IoU)*. Biasanya *mAP* dihitung pada nilai $IoU \geq 0.5$ ($mAP@0.5$) atau $mAP@0.5:0.95$.

mAP dihitung berdasarkan area di bawah kurva *Precision-Recall* dan mewakili akurasi deteksi model dalam berbagai situasi.

2.4 Kerangka Teori


Kerangka teori dalam penelitian ini dibangun dari konsep dasar pengolahan citra digital, klasifikasi berbasis *Deep Learning*, dan pendekatan *object detection* dengan algoritma YOLO. Teori-teori ini menjadi dasar dalam merancang sistem

deteksi dan klasifikasi kualitas daging berbasis visual, mulai dari akuisisi data, proses pelatihan model, hingga evaluasi performa.

Sistem yang dibangun memanfaatkan data citra sebagai masukan, kemudian diproses melalui model YOLO untuk mengidentifikasi apakah citra tersebut termasuk dalam kategori daging segar atau busuk. Dengan menerapkan teori ini, diharapkan sistem mampu melakukan deteksi dan klasifikasi secara otomatis dan akurat sesuai dengan karakteristik daging sapi lokal Aceh.

2.5 Kerangka Berpikir

Kerangka pemikiran dalam penelitian ini disusun untuk menjelaskan alur logika dan tahapan sistematis dari permasalahan hingga solusi yang ditawarkan melalui metode YOLO. Adapun langkah-langkah kerangka pemikiran tersebut dijabarkan sebagai berikut:



Gambar 2. 3 Kerangka Berpikir

BAB III

METODE PENELITIAN

3.1 Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif eksperimental dengan pendekatan rekayasa perangkat lunak (*software engineering*). Penelitian dilakukan dengan merancang dan mengembangkan Sistem deteksi dan klasifikasi kualitas daging sapi berbasis citra digital menggunakan algoritma YOLOv8. Pendekatan ini bertujuan untuk membangun model deteksi yang mampu membedakan daging segar dan busuk secara otomatis berdasarkan data citra dari dataset gabungan yang digunakan.

Secara konseptual, pendekatan rekayasa perangkat lunak ini dipilih untuk memastikan bahwa seluruh tahapan pembangunan sistem mulai dari akuisisi citra, pra-pemrosesan, pelatihan arsitektur jaringan saraf tiruan, hingga tahap pengujian performa dieksekusi secara sistematis, terukur, dan berstandar ilmiah. Melalui pemanfaatan kerangka kerja *Deep Learning* modern, simulasi komputasi ini dirancang agar mampu menghasilkan model deteksi yang tidak hanya memiliki tingkat akurasi tinggi, tetapi juga reliabilitas yang optimal dalam mengenali karakteristik visual objek secara konsisten pada berbagai skenario pengujian

3.2 Objek dan Subjek Penelitian

Objek dalam penelitian ini adalah sistem deteksi dan klasifikasi kualitas daging sapi berbasis citra digital yang dikembangkan menggunakan metode YOLOv8. Subjek penelitian adalah dataset citra daging sapi yang terdiri dari dua sumber, yaitu dataset publik LOCBEEF dari Kaggle dan dataset lapangan hasil pengambilan foto langsung di pasar tradisional Aceh. Kedua dataset ini memiliki dua kategori utama, yaitu daging segar (*Fresh*) dan daging busuk (*Rotten*).

3.3 Validasi Data

Validasi data merupakan tahapan penting dalam penelitian ini untuk memastikan bahwa label pada dataset, khususnya dataset lapangan, memiliki tingkat keakuratan yang dapat dipertanggungjawabkan secara ilmiah. Hal ini dilakukan karena penentuan kualitas daging secara visual tidak dapat hanya

didasarkan pada persepsi peneliti, melainkan perlu melibatkan pihak yang memiliki kompetensi dalam bidang kesehatan hewan dan kualitas daging.

Pada penelitian ini, validasi label dataset lapangan dilakukan dengan melibatkan pihak yang berkompeten, yaitu petugas Rumah Potong Hewan (RPH). Pihak tersebut memiliki pengetahuan dan pengalaman dalam menilai kondisi daging berdasarkan karakteristik fisik seperti warna, tekstur, aroma, dan kondisi permukaan daging. Dengan adanya validasi dari pihak yang kompeten, proses pelabelan data menjadi lebih objektif dan tidak hanya bergantung pada penilaian subjektif peneliti.

Validasi dilakukan terhadap citra daging yang dikumpulkan dari pasar tradisional. Setiap citra dikategorikan ke dalam dua kelas, yaitu daging segar (*Fresh*) dan daging busuk (*Rotten*). Penentuan kelas dilakukan dengan memperhatikan ciri-ciri visual daging serta mempertimbangkan hasil penilaian dari validator. Apabila terdapat citra yang meragukan atau sulit dikategorikan, maka citra tersebut diperiksa kembali sebelum dimasukkan ke dalam dataset akhir. Adapun kriteria umum yang digunakan dalam proses validasi label adalah sebagai berikut:



Gambar 3. 1 Daging Segar dan Daging Busuk

1. Daging segar (*Fresh*)

Daging dikategorikan sebagai segar apabila memiliki warna merah cerah atau merah alami, tekstur masih kenyal, permukaan tidak berlendir, dan tidak menunjukkan tanda-tanda pembusukan.

2. Daging busuk (*Rotten*)


Daging dikategorikan sebagai busuk apabila menunjukkan perubahan warna menjadi pucat, kecoklatan, kehitaman, memiliki tekstur lembek, permukaan

berlendir, serta menunjukkan indikasi penurunan kualitas yang dapat diamati secara visual.

Melalui proses validasi ini, dataset yang digunakan dalam penelitian memiliki tingkat kepercayaan yang lebih baik karena label kelas tidak hanya ditentukan berdasarkan pengamatan peneliti, tetapi juga melalui pertimbangan pihak yang memiliki kompetensi di bidang kualitas daging. Dengan demikian, proses validasi ini bertujuan untuk mengurangi subjektivitas dalam pelabelan dan meningkatkan integritas dataset yang digunakan dalam pelatihan model YOLOv8.

3.4 Tahapan Penelitian

Tahapan penelitian ini disusun secara sistematis untuk memandu proses pengembangan dan evaluasi sistem deteksi dan klasifikasi kualitas daging sapi menggunakan metode YOLO. Adapun langkah-langkah yang dilakukan dalam penelitian ini adalah sebagai berikut:



Gambar 3. 2 Tahapan Penelitian

3.5 Metode Pengumpulan Data

Metode pengumpulan data dalam penelitian ini dilakukan melalui pendekatan dokumentasi dan pemanfaatan dataset sekunder berbasis citra digital. Adapun proses pengumpulan data dilaksanakan dalam beberapa tahapan sebagai berikut:

3.5.1 Pengunduhan Dataset LOCBEEF

Dataset yang digunakan adalah LOCBEEF, yang diunduh melalui platform Kaggle. Dataset ini terdiri dari citra daging sapi segar dan busuk yang berasal dari pasar dan rumah pemotongan hewan di wilayah Aceh.

3.5.2 Pengambilan Dataset Lapangan

Penelitian ini menambahkan dataset lapangan berupa citra daging sapi yang diambil secara langsung dari pasar tradisional di wilayah Aceh. Proses pengambilan data dilakukan menggunakan kamera smartphone dengan mempertimbangkan kondisi nyata di lapangan, seperti variasi pencahayaan alami, sudut pengambilan gambar, serta latar belakang yang tidak seragam.

Untuk memperkuat keabsahan data, proses pengambilan dataset juga didokumentasikan dalam bentuk foto kegiatan di lapangan, sebagaimana ditunjukkan pada Gambar 3.3.



Gambar 3. 3 Proses Pengambilan Dataset

Dokumentasi pada Gambar 3.3 memberikan bukti visual mengenai proses akuisisi data yang dilakukan secara langsung di lingkungan pasar tradisional. Pengambilan data ini bertujuan untuk mendapatkan representasi citra yang mencakup variasi kondisi nyata, seperti perbedaan posisi potong daging, sudut pengambilan gambar oleh peneliti, serta kondisi lingkungan pasar yang dinamis.


Dengan melakukan pengambilan data langsung ke lapangan, diharapkan model YOLOv8 yang dibangun nantinya memiliki tingkat ketahanan (*robustness*) yang lebih baik dalam mengenali objek daging di luar dataset publik yang terkontrol, sehingga sistem dapat memberikan hasil deteksi yang lebih akurat saat diimplementasikan pada skenario penggunaan yang sesungguhnya.

3.5.3 Klasifikasi dan Dokumentasi Data

Setelah proses pengumpulan dataset selesai, langkah selanjutnya adalah melakukan klasifikasi dan dokumentasi data. Pada tahap ini, seluruh citra daging sapi dikategorikan ke dalam dua kelas utama, yaitu daging segar (*Fresh*) dan daging busuk (*Rotten*), sesuai dengan karakteristik visual yang terlihat pada citra.

Proses klasifikasi dilakukan berdasarkan label pada dataset publik LOCBEEF serta hasil identifikasi manual pada dataset lapangan. Untuk dataset lapangan, penentuan label dilakukan dengan mengamati ciri-ciri visual daging, seperti warna, tekstur, dan tingkat kesegaran permukaan. Citra yang memiliki warna merah cerah dan tekstur yang masih baik dikategorikan sebagai *Fresh*, sedangkan citra dengan warna cenderung gelap, pucat, atau menunjukkan indikasi pembusukan dikategorikan sebagai *Rotten*.

Setelah proses klasifikasi, dataset didokumentasikan secara sistematis dalam struktur folder yang terorganisir. Struktur penyimpanan data dibagi berdasarkan kategori kelas, sehingga memudahkan proses pelatihan model. Adapun struktur dataset disusun sebagai berikut:



Gambar 3. 4 Struktur File Dataset

Pengorganisasian dataset ini bertujuan untuk memastikan bahwa setiap citra berada pada kategori yang tepat dan siap digunakan dalam proses pelatihan, validasi, dan pengujian model YOLOv8.

Selain itu, dokumentasi dataset juga dilakukan dengan mencatat jumlah citra pada setiap kelas serta sumber data (LOCBEEF dan lapangan). Dokumentasi ini penting untuk memastikan keseimbangan data (*data balance*) dan menghindari bias model terhadap salah satu kelas.


3.5.4 Pra-pemrosesan dan Anotasi Dataset

Pra-pemrosesan dataset merupakan tahap penting dalam penelitian ini yang bertujuan untuk mempersiapkan data citra agar sesuai dengan kebutuhan model YOLOv8. Tahap ini dilakukan untuk meningkatkan kualitas data serta memastikan konsistensi format input yang digunakan dalam proses pelatihan.

Adapun tahapan pra-pemrosesan yang dilakukan adalah sebagai berikut:

1. *Resize* Citra


Seluruh citra diubah ukurannya menjadi resolusi standar, yaitu 640×640 piksel. Penyeragaman ukuran ini bertujuan agar seluruh data memiliki dimensi yang sama dan sesuai dengan input model YOLOv8.



Gambar 3. 5 Contoh Proses *Resize* Foto [Sumber : Roboflow. 2026.]

2. Normalisasi Piksel

Nilai piksel pada citra dinormalisasi ke dalam rentang $[0,1]$ secara otomatis untuk mempercepat proses konvergensi saat pelatihan model serta meningkatkan stabilitas pembelajaran.




Gambar 3. 6 Contoh gambar normalisasi [Sumber : Medium. 2024]

3. Augmentasi Data

Untuk meningkatkan variasi dataset dan menghindari overfitting, dilakukan augmentasi data dengan beberapa teknik, antara lain:

- Rotasi
- Flip horizontal*
- Penyesuaian kecerahan (*brightness*)

Augmentasi ini bertujuan untuk mensimulasikan kondisi nyata di lapangan, seperti perubahan sudut kamera dan pencahayaan.




Gambar 3. 7 Contoh Proses Augmentasi

4. Anotasi *Bounding box*

Setiap citra diberi anotasi menggunakan metode *Bounding box* untuk menandai lokasi objek daging. Proses ini dilakukan menggunakan *tools*

seperti *LabelImg* atau Roboflow, sehingga model dapat mengenali posisi dan kategori objek secara bersamaan.



Gambar 3. 8 Contoh Proses Anotasi

5. Validasi Data

Setelah seluruh proses pra-pemrosesan selesai, dilakukan pengecekan ulang terhadap dataset untuk memastikan tidak terdapat data yang rusak, label yang salah, atau anotasi yang tidak sesuai.

Dengan melalui tahapan pra-pemrosesan ini, dataset yang dihasilkan menjadi lebih terstruktur, berkualitas, dan siap digunakan dalam proses pelatihan model *Deep Learning*. Proses pra-pemrosesan dataset dilakukan setelah tahap anotasi selesai. Dataset awal yang berjumlah sekitar 1480 citra kemudian diproses lebih lanjut untuk meningkatkan kualitas dan variasi data. Hasil dari proses augmentasi ini meningkatkan menjadi 2638 citra, yang selanjutnya digunakan dalam proses pelatihan, validasi, dan pengujian model.

3.5.5 Pemisahan Data

Dataset dibagi menjadi tiga bagian secara proporsional untuk proses pelatihan dan pengujian model, yaitu:

1. *Training set* (70%) untuk melatih model YOLO,
2. *Validation set* (15%) untuk memantau akurasi selama pelatihan,
3. *Testing set* (15%) untuk menguji performa akhir model.

The screenshot shows a web interface for data splitting. At the top, there is a 'Method' dropdown menu set to 'Split Images Between Train/Valid/Test'. Below this, the 'Distribution' section shows three sliders: 'Train' at 70%, 'Valid' at 15%, and 'Test' at 15%. Below the sliders, the counts are displayed: 'Train: 685 images', 'Valid: 147 images', and 'Test: 147 images'. At the bottom, there are two buttons: 'Submit for Review' and 'Add 979 Images'.

Gambar 3. 9 Proses Pemisahan Data

3.6 Metode Simulasi

Pemilihan metode simulasi ini didasarkan pada kebutuhan untuk memvalidasi performa algoritma YOLOv8 dalam kondisi lingkungan yang menyerupai skenario nyata penggunaan di lapangan. Simulasi tidak hanya berfungsi sebagai sarana pelatihan model, tetapi juga sebagai mekanisme untuk menguji stabilitas deteksi terhadap variasi input citra yang berasal dari dataset gabungan (lokal dan publik). Dengan pendekatan simulasi ini, peneliti dapat melakukan iterasi pengujian dengan parameter yang terkontrol, sehingga hasil yang diperoleh dapat dianalisis secara objektif sebelum ditarik menjadi kesimpulan penelitian.

Simulasi dilakukan secara terstruktur dalam dua tahapan utama, yaitu Perumusan Konsep Penelitian dan Implementasi Metode dan Arsitektur. Berikut adalah penjelasan masing-masing tahap:

3.6.1 Perumusan Konsep Penelitian

Pada tahap ini, peneliti menyusun dasar teori, pendekatan teknis, serta strategi pengolahan data dan algoritma yang akan digunakan. Kegiatan yang dilakukan meliputi:

1. Studi Literatur: Mengkaji referensi terkait pengolahan citra, metode deteksi dan klasifikasi berbasis *Deep Learning*, YOLO, dan penerapannya dalam bidang pangan.
2. Identifikasi Permasalahan: Merumuskan masalah utama yaitu ketidakakuratan penilaian kualitas daging secara manual di pasar tradisional.

3. Penentuan Metode: Menentukan bahwa metode YOLOv8 merupakan pilihan utama karena memiliki kemampuan deteksi dan klasifikasi objek secara *real-time*.
4. Penentuan dataset gabungan (LOCBEEF + lapangan).
5. Perencanaan Arsitektur Sistem: Menyusun alur sistem, mulai dari input citra, pra-pemrosesan, pelatihan model, hingga prediksi dan evaluasi hasil.

3.6.2 Implementasi Metode dan Arsitektur

Tahap ini merupakan tahap pelaksanaan teknis simulasi berdasarkan perencanaan sebelumnya. Aktivitas yang dilakukan pada tahap ini antara lain:

1. Pengumpulan dan Pra-pemrosesan Data

Dataset LOCBEEF diunduh dan juga data dari lapangan daging sapi di Aceh, diatur ulang strukturnya, lalu dilakukan *resize*, augmentasi, dan labeling *Bounding box* agar kompatibel dengan format YOLO.

2. Pelatihan Model (*Training*)

Model YOLOv8 dilatih menggunakan dataset *training* dengan konfigurasi parameter tertentu (jumlah *epoch*, *Batch size*, *Learning rate*, dan resolusi input citra).

3. Validasi dan Pengujian (*Testing*)

Model divalidasi dengan dataset *validation* dan diuji dengan dataset *testing* untuk mengukur kemampuannya mengenali citra baru.

4. Konfigurasi dan *Hyperparameter tuning*

Untuk memastikan model YOLOv8 yang digunakan dalam penelitian ini menghasilkan performa optimal, dilakukan pengaturan dan pengujian hyperparameter secara sistematis. Meskipun YOLOv8 merupakan model berbasis *black-box* dari pustaka *Ultralytics YOLO*, proses tuning tetap diperlukan untuk menyesuaikan model dengan karakteristik dataset dan keterbatasan perangkat keras yang digunakan.

Hyperparameter yang diatur dalam penelitian ini meliputi:

- a. *Batch size*

Batch size menentukan jumlah data yang diproses dalam satu iterasi pelatihan. Nilai *Batch size* yang digunakan dalam penelitian ini adalah 16, yang disesuaikan dengan keterbatasan perangkat keras berupa

prosesor Ryzen 7 4000 series dan RAM 16 GB. Pemilihan *Batch size* dilakukan untuk menemukan keseimbangan antara efisiensi komputasi dan stabilitas pelatihan.

b. Jumlah *Epoch*

Jumlah *epoch* yang digunakan berada pada 100 *epoch*, dengan penerapan mekanisme *Early stoppingg* apabila tidak terjadi peningkatan performa pada data validasi.

c. Ukuran Input Citra

Ukuran input citra yang digunakan dalam penelitian ini adalah 640 × 640 piksel. Ukuran tersebut dipilih karena umum digunakan pada pelatihan YOLOv8 dan mampu mempertahankan informasi visual seperti warna, tekstur, serta bentuk objek. Dengan ukuran citra yang seragam, proses pelatihan model dapat berjalan lebih stabil dan konsisten.

d. Metode Tuning

Proses tuning dilakukan menggunakan pendekatan trial-and-error dengan mengevaluasi performa model pada data validasi menggunakan metrik seperti *mAP*, *Precision*, *Recall*, dan *F1-score*.

Dengan adanya proses *Hyperparameter tuning* ini, penelitian tidak hanya bergantung pada konfigurasi default model, tetapi juga memastikan bahwa hasil yang diperoleh merupakan hasil optimasi yang sesuai dengan kondisi dataset dan perangkat keras yang digunakan. Hal ini menunjukkan bahwa eksperimen dilakukan secara sistematis dan memiliki validitas ilmiah yang kuat.

5. Evaluasi Kinerja Model

Hasil simulasi dianalisis menggunakan metrik:


- a. Presisi, *Recall*, dan *F1-score*,
- b. *mAP@0.5* dan *mAP@0.5:0.95* untuk mengukur kualitas deteksi,
- c. *Confusion matrix* untuk melihat distribusi kesalahan prediksi.

6. Visualisasi dan Interpretasi

Menampilkan grafik performa (akurasi vs *epoch*), citra hasil deteksi dengan *Bounding box*, dan evaluasi numerik.

3.6.3 Alur Pengujian Model

Setelah proses pelatihan selesai, model terbaik (best.pt) yang dihasilkan digunakan untuk melakukan pengujian terhadap data uji (*testing set*). Pengujian dilakukan untuk mengetahui kemampuan model dalam mendeteksi kualitas daging sapi pada data yang belum pernah digunakan selama proses pelatihan. Hasil prediksi kemudian dibandingkan dengan *Ground truth* untuk menghitung nilai metrik evaluasi, seperti *Precision*, *Recall*, *F1-score*, *Confusion Matrix*, dan *Mean Average Precision (mAP)*. Tahapan pengujian model pada penelitian ini ditunjukkan pada Gambar 3.10.



Gambar 3. 10 Flow Pengujian

3.7 Metode Analisis Data

Analisis data dilakukan untuk menilai kinerja model YOLOv8 dalam mendeteksi dan mengklasifikasikan kualitas daging sapi. Evaluasi model dilakukan menggunakan metrik akurasi, presisi, *Recall*, *F1-score*, dan *Mean Average Precision (mAP)*. Analisis ini bertujuan untuk mengukur ketepatan prediksi model dalam mendeteksi dan mengklasifikasikan daging segar dan busuk.

Selain itu, analisis hasil juga dilengkapi dengan visualisasi grafik, tabel evaluasi, dan *confusion matrix* untuk mengetahui distribusi kesalahan prediksi. Dengan demikian, dapat dilihat secara objektif apakah model sudah layak diterapkan atau masih memerlukan perbaikan.

3.7.1 Evaluasi Model

Setelah model YOLOv8 dilatih menggunakan dataset LOCBEEF dan Lapangan, evaluasi dilakukan terhadap hasil prediksi model pada data pengujian. Evaluasi ini bertujuan untuk mengukur kemampuan model dalam mendeteksi dan mengklasifikasikan daging sapi ke dalam dua kategori, yaitu segar dan busuk. Hasil prediksi dianalisis dengan menggunakan beberapa metrik klasifikasi yang umum dalam penelitian *machine learning*, antara lain:

1. Presisi, yang mengukur seberapa tepat model dalam mengidentifikasi daging busuk (positif).
2. *Recall*, yang menunjukkan sejauh mana model mampu menemukan semua daging busuk yang sebenarnya.
3. *F1-score*, yang merupakan rata-rata harmonis dari presisi dan *Recall*, berguna untuk menangani ketidakseimbangan kelas.
4. Selain itu, karena YOLOv8 merupakan algoritma deteksi objek, maka evaluasi juga dilakukan menggunakan *Mean Average Precision (mAP)* yang mengukur ketepatan deteksi *Bounding box* dibandingkan dengan *Ground truth*, pada ambang batas *Intersection over Union (IoU)* seperti $mAP@0.5$ dan $mAP@0.5:0.95$.

3.7.2 Alat Bantu Penelitian

Untuk melaksanakan pelatihan, pengujian, dan analisis model secara menyeluruh, digunakan beberapa perangkat keras dan perangkat lunak pendukung, antara lain:

1. Laptop
 - a. Prosesor Ryzen 7 4000 Series
 - b. GPU NVIDIA GeForce RTX 3050 Laptop GPU
 - c. RAM 16 GB
2. Iphone 12
 - a. Kamera

Perangkat lunak yang digunakan dalam penelitian ini mencakup Python 3.10 sebagai bahasa pemrograman utama dan Google Colab sebagai lingkungan pengembangan berbasis cloud. Pelatihan dan pengujian model dilakukan menggunakan YOLOv8 dari pustaka *Ultralytics* yang berjalan di atas *Framework PyTorch*. Untuk pelabelan dan augmentasi citra digunakan Roboflow.



BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

4.1 Dataset Penelitian

Dataset merupakan komponen utama dalam penelitian berbasis *Deep Learning*, karena kualitas dan karakteristik data sangat mempengaruhi kemampuan model dalam melakukan pembelajaran. Pada penelitian ini, dataset yang digunakan terdiri dari dua sumber utama, yaitu dataset publik LOCBEEF dan dataset lapangan yang dikumpulkan secara langsung dari pasar tradisional di Aceh. Penggunaan dua jenis dataset ini bertujuan untuk membangun model yang tidak hanya mampu mengenali citra pada kondisi yang terkontrol, tetapi juga mampu menghadapi kondisi nyata di lapangan. Dataset publik digunakan sebagai data yang relatif lebih terstruktur, sedangkan dataset lapangan digunakan untuk memberikan variasi visual yang lebih realistis, seperti perbedaan pencahayaan, sudut pengambilan gambar, jarak kamera, dan latar belakang.


4.1.1 Dataset Publik LOCBEEF

Dataset publik yang digunakan dalam penelitian ini adalah dataset LOCBEEF, yaitu dataset citra daging sapi yang diperoleh dari sumber terbuka. Dataset ini memiliki dua kategori utama, yaitu daging segar (*Fresh*) dan daging busuk (*Rotten*).

Dataset LOCBEEF digunakan sebagai salah satu sumber data karena memiliki citra daging yang relatif jelas dan terstruktur. Secara umum, citra pada dataset publik memiliki pencahayaan yang lebih stabil, posisi objek yang lebih mudah dikenali, serta latar belakang yang tidak terlalu kompleks. Kondisi tersebut memudahkan model dalam mempelajari ciri visual utama dari daging segar dan daging busuk.

Pada kelas *Fresh*, citra daging umumnya memiliki warna merah yang lebih cerah dan tekstur yang terlihat lebih padat. Sementara itu, pada kelas *Rotten*, citra daging cenderung menunjukkan perubahan warna menjadi lebih gelap atau kusam. Perbedaan visual tersebut menjadi salah satu dasar bagi model YOLOv8 dalam mempelajari pola klasifikasi kualitas daging.

Meskipun dataset publik memiliki kualitas citra yang baik, dataset ini belum sepenuhnya merepresentasikan kondisi nyata di pasar. Oleh karena itu, dataset publik perlu dikombinasikan dengan dataset lapangan agar model memiliki kemampuan generalisasi yang lebih baik.



Gambar 4. 1 Contoh Dataset Publik

Gambar 4.1 menampilkan contoh citra dataset publik LOCBEEF yang terdiri dari kelas *Fresh* dan *Rotten*. Citra pada dataset publik terlihat lebih terkontrol, baik dari sisi pencahayaan maupun latar belakang, sehingga objek daging lebih mudah dikenali oleh model.

4.1.2 Dataset Lapangan


Selain menggunakan dataset publik, penelitian ini juga menggunakan dataset lapangan yang dikumpulkan secara langsung dari pasar tradisional di Aceh. Dataset lapangan digunakan untuk merepresentasikan kondisi nyata yang lebih kompleks dibandingkan dataset publik.

Citra pada dataset lapangan diambil menggunakan kamera smartphone dengan kondisi pencahayaan alami. Kondisi pengambilan gambar tidak diatur secara khusus, sehingga data yang diperoleh memiliki variasi yang lebih tinggi. Variasi tersebut mencakup perubahan intensitas cahaya, bayangan, posisi objek, jarak pengambilan gambar, serta latar belakang seperti meja, piring, plastik, dan lingkungan pasar.

Karakteristik dataset lapangan ini penting karena dapat menguji kemampuan model dalam menghadapi kondisi nyata. Model yang hanya dilatih atau diuji pada dataset yang bersih dan terkontrol berpotensi mengalami penurunan performa

ketika digunakan pada data nyata. Oleh sebab itu, penggunaan dataset lapangan menjadi salah satu bagian penting dalam penelitian ini.

Dataset lapangan juga memiliki tantangan tersendiri. Pada beberapa citra, warna daging segar dapat terlihat lebih gelap karena pencahayaan, sehingga menyerupai daging busuk. Sebaliknya, beberapa daging yang mengalami penurunan kualitas dapat terlihat masih cukup terang apabila terkena cahaya. Kondisi ini dapat mempengaruhi hasil prediksi model dan menjadi salah satu penyebab terjadinya kesalahan klasifikasi.



Gambar 4. 2 Contoh Dataset Lapangan

Gambar 4.2 menunjukkan contoh citra dataset lapangan yang diambil secara langsung pada kondisi nyata. Berbeda dengan dataset publik, citra lapangan memiliki variasi pencahayaan dan latar belakang yang lebih kompleks, sehingga memberikan tantangan lebih besar bagi model.

4.1.3 Distribusi Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari dua kelas utama, yaitu *Fresh* dan *Rotten*. Kelas *Fresh* merepresentasikan citra daging yang masih segar, sedangkan kelas *Rotten* merepresentasikan citra daging yang menunjukkan ciri-ciri pembusukan.

Berdasarkan data yang tercantum pada dokumen, jumlah citra dataset terdiri dari 440 citra *Fresh* LOCBEEF, 440 citra *Rotten* LOCBEEF, 300 citra *Fresh* lapangan, dan 300 citra *Rotten* lapangan. Dengan demikian, total citra yang digunakan adalah 1480 citra. Angka ini diperoleh dari jumlah seluruh data pada masing-masing kategori.

Tabel 4. 1 Distribusi Dataset Berdasarkan Sumber Data dan Kelas

No	Sumber Dataset	Kelas	Jumlah Citra	Persentase
1	LOCBEEF	<i>Fresh</i>	440	29,73%
2	LOCBEEF	<i>Rotten</i>	440	29,73%
3	Lapangan	<i>Fresh</i>	300	20,27%
4	Lapangan	<i>Rotten</i>	300	20,27%
Total			1480	100%


Berdasarkan Tabel 4.1, dataset yang digunakan memiliki distribusi kelas yang relatif seimbang antara *Fresh* dan *Rotten*. Jumlah data *Fresh* adalah 740 citra, sedangkan jumlah data *Rotten* juga 740 citra. Keseimbangan ini penting karena dapat mengurangi risiko bias model terhadap salah satu kelas.

Dari sisi sumber data, dataset LOCBEEF berjumlah 880 citra, sedangkan dataset lapangan berjumlah 600 citra. Dataset LOCBEEF memberikan dasar pembelajaran dari citra yang lebih terkontrol, sementara dataset lapangan memberikan variasi kondisi nyata yang lebih kompleks. Kombinasi keduanya diharapkan dapat membantu model dalam mempelajari pola visual yang lebih beragam.

Keberagaman karakteristik citra pada dataset diharapkan dapat meningkatkan kemampuan model dalam melakukan deteksi objek secara akurat. Dengan adanya variasi kondisi pengambilan gambar, model dapat belajar mengenali pola visual yang lebih kompleks sehingga menghasilkan performa yang lebih baik pada data baru.

Selain jumlah data yang seimbang, kualitas dan keberagaman dataset juga menjadi faktor penting dalam proses pelatihan model YOLOv8. Penggunaan dataset yang berasal dari dua sumber berbeda memungkinkan model mempelajari karakteristik daging sapi pada berbagai kondisi lingkungan, baik pada citra yang terkontrol maupun citra yang diambil secara langsung di lapangan. Dengan demikian, model diharapkan memiliki kemampuan generalisasi yang lebih baik

sehingga dapat memberikan hasil deteksi yang lebih andal ketika diterapkan pada kondisi nyata.



Grafik 4. 1 Grafik Distribusi Dataset

Grafik 4.1 menunjukkan distribusi dataset berdasarkan sumber data dan kelas. Grafik tersebut dapat digunakan untuk memperlihatkan bahwa jumlah kelas *Fresh* dan *Rotten* berada dalam kondisi seimbang, sehingga model tidak terlalu condong pada salah satu kelas.

4.1.4 Karakteristik Dataset Publik dan Dataset Lapangan

Dataset publik dan dataset lapangan memiliki karakteristik yang berbeda. Dataset publik cenderung memiliki kualitas citra yang lebih stabil, sedangkan dataset lapangan memiliki variasi visual yang lebih tinggi.

Perbedaan tersebut dapat dilihat dari beberapa aspek, seperti pencahayaan, latar belakang, posisi objek, dan kompleksitas citra. Pada dataset publik, objek daging lebih mudah dikenali karena latar belakang relatif bersih dan pencahayaan lebih merata. Sebaliknya, pada dataset lapangan, objek daging sering berada pada lingkungan yang lebih kompleks, sehingga model harus mampu membedakan objek utama dari latar belakang.

Tabel 4. 2 Perbandingan Karakteristik Dataset Publik dan Dataset Lapangan

Aspek	Dataset Publik LOCBEEF	Dataset Lapangan
Kondisi pencahayaan	Relatif stabil	Bervariasi

Aspek	Dataset Publik LOCBEEF	Dataset Lapangan
Latar belakang	Lebih sederhana	Lebih kompleks
Posisi objek	Cenderung lebih jelas	Bervariasi
Variasi warna	Lebih terkontrol	Lebih beragam
Tingkat kesulitan	Lebih rendah	Lebih tinggi
Fungsi dalam penelitian	Membantu model belajar pola dasar	Menguji kemampuan model pada kondisi nyata

Berdasarkan Tabel 4.2, dapat disimpulkan bahwa dataset lapangan memiliki tingkat kompleksitas yang lebih tinggi dibandingkan dataset publik. Hal ini menjadi tantangan bagi model, tetapi juga penting untuk meningkatkan kemampuan generalisasi. Dengan adanya dataset lapangan, model tidak hanya belajar dari kondisi ideal, tetapi juga dari kondisi nyata yang lebih mendekati lingkungan implementasi.

4.1.5 Peran Dataset terhadap Penelitian

Dataset dalam penelitian ini memiliki peran penting dalam membangun model deteksi kualitas daging. Dataset publik membantu model dalam mempelajari pola visual dasar, sedangkan dataset lapangan membantu model menghadapi variasi kondisi nyata.

Kombinasi kedua dataset tersebut menjadi salah satu kekuatan penelitian ini. Dengan menggunakan dataset gabungan, model diharapkan tidak hanya menghasilkan performa yang baik pada citra yang terkontrol, tetapi juga mampu mendeteksi kualitas daging pada kondisi yang lebih realistis.

Namun demikian, penggunaan dataset lapangan juga dapat menyebabkan performa model menjadi lebih fluktuatif. Hal ini disebabkan oleh variasi pencahayaan, perbedaan latar belakang, dan kondisi objek yang tidak selalu konsisten. Oleh karena itu, karakteristik dataset perlu dipahami dengan baik sebelum masuk ke tahap pra-pemrosesan, pelatihan, dan evaluasi model.

Secara keseluruhan, dataset yang digunakan dalam penelitian ini sudah cukup representatif untuk membangun sistem deteksi kualitas daging berbasis citra digital.

Dataset yang seimbang antara kelas *Fresh* dan *Rotten* memberikan dasar yang baik bagi model YOLOv8 dalam mempelajari perbedaan kualitas daging.

4.2 Hasil Pra-pemrosesan dan Anotasi Data

Pra-pemrosesan dan anotasi data merupakan tahap lanjutan setelah dataset penelitian dikumpulkan dan diklasifikasikan berdasarkan sumber serta kelasnya. Tahap ini bertujuan untuk memastikan bahwa seluruh citra yang digunakan telah memiliki format yang sesuai dengan kebutuhan model YOLOv8. Pada penelitian berbasis *object detection*, data tidak hanya membutuhkan label kelas, tetapi juga membutuhkan informasi posisi objek dalam citra melalui *Bounding box*.


Pada bagian ini, pembahasan difokuskan pada hasil dari proses pra-pemrosesan data, meliputi proses anotasi menggunakan Roboflow, pembagian dataset, penyesuaian ukuran citra, serta augmentasi data (Roboflow, 2026). Tahapan ini penting karena kualitas data yang digunakan dalam pelatihan sangat berpengaruh terhadap kemampuan model dalam mendeteksi dan mengklasifikasikan objek.

4.2.1 Hasil Anotasi Data Menggunakan Roboflow

Proses anotasi dilakukan untuk memberikan informasi lokasi objek daging pada setiap citra. Dalam penelitian ini, anotasi dilakukan menggunakan platform Roboflow dengan metode *Bounding box*. Setiap objek daging pada citra diberi kotak pembatas yang mengelilingi area objek, kemudian diberi label sesuai kelasnya, yaitu *Fresh* atau *Rotten*.

Hasil anotasi ini menghasilkan pasangan data berupa citra dan file label. File label berisi informasi kelas objek serta koordinat *Bounding box* yang digunakan oleh model YOLOv8 selama proses pelatihan. Dengan adanya anotasi, model dapat mempelajari dua hal secara bersamaan, yaitu mengenali kelas objek dan menentukan lokasi objek pada citra.

Ketelitian dalam proses anotasi menjadi faktor penting karena kesalahan pemberian *Bounding box* dapat mempengaruhi performa model. Jika *Bounding box* terlalu besar, model dapat ikut mempelajari area latar belakang sebagai bagian dari objek. Sebaliknya, jika *Bounding box* terlalu kecil, model tidak memperoleh informasi objek secara utuh. Oleh karena itu, anotasi dilakukan dengan memastikan bahwa kotak pembatas mencakup area daging secara proporsional.



Gambar 4. 3 Proses Anotasi Dataset Menggunakan Roboflow

Gambar 4.3 menunjukkan proses anotasi dataset menggunakan Roboflow. Pada gambar tersebut terlihat objek daging diberi *Bounding box* dan label kelas. Proses ini memastikan bahwa setiap citra memiliki informasi lokasi objek dan kategori kelas yang sesuai untuk kebutuhan pelatihan model YOLOv8.


4.2.2 Hasil Struktur Dataset Format YOLO

Setelah proses anotasi selesai, dataset diekspor dalam format YOLO. Format YOLO digunakan karena sesuai dengan kebutuhan model YOLOv8 dalam membaca citra dan label. Setiap citra memiliki file label dengan nama yang sama, tetapi menggunakan ekstensi .txt.

File label tersebut berisi informasi berupa nomor kelas, koordinat titik tengah objek, lebar, dan tinggi *Bounding box*. Nilai koordinat yang digunakan dalam format YOLO bersifat ter-normalisasi, sehingga nilainya berada dalam rentang 0 sampai 1. Format ini memungkinkan model membaca posisi objek secara konsisten meskipun ukuran citra berbeda.

Dataset kemudian disusun ke dalam tiga folder utama, yaitu train, valid, dan test. Folder *train* digunakan untuk pelatihan model, folder *valid* digunakan untuk memantau performa model selama pelatihan, sedangkan folder *test* digunakan untuk pengujian akhir model.

Penyusunan dataset dalam format dan struktur yang sesuai merupakan tahapan penting sebelum proses pelatihan model dilakukan. Struktur dataset yang terorganisir dengan baik membantu YOLOv8 membaca data secara efisien.



Gambar 4. 4 Struktur Dataset Format YOLO

Gambar 4.4 menampilkan struktur dataset dalam format YOLO yang terdiri dari folder citra dan label. Struktur ini diperlukan agar proses pelatihan, validasi, dan pengujian dapat berjalan secara terpisah dan sistematis.

4.2.3 Pembagian Dataset

Dataset yang telah dianotasi kemudian dibagi menjadi tiga bagian, yaitu data pelatihan, data validasi, dan data pengujian. Pembagian ini dilakukan agar model dapat dilatih dan diuji secara objektif. Pada penelitian ini, pembagian dataset dilakukan dengan proporsi 70% data *training*, 15% data *validation*, dan 15% data *testing*.


Data *training* digunakan untuk melatih model agar mampu mengenali pola visual dari citra daging. Data *validation* digunakan untuk memantau performa model selama proses pelatihan berlangsung. Sementara itu, data *testing* digunakan untuk menguji kemampuan model pada data yang tidak digunakan dalam proses *training*.

Tabel 4. 3 Pembagian Dataset

No	Jenis Data	Persentase	Fungsi
1	<i>Training set</i>	70%	Digunakan untuk melatih model YOLOv8

No	Jenis Data	Persentase	Fungsi
2	<i>Validation set</i>	15%	Digunakan untuk memantau performa model selama pelatihan
3	<i>Testing set</i>	15%	Digunakan untuk menguji performa akhir model

Berdasarkan Tabel 4.3, pembagian dataset dilakukan secara proporsional agar model memiliki data yang cukup untuk proses pelatihan, tetapi tetap memiliki data validasi dan pengujian yang memadai. Pembagian ini penting untuk menghindari model hanya menghafal data pelatihan dan untuk memastikan model dapat diuji pada data baru.



Gambar 4. 5 Proses Pembagian Dataset di Roboflow


Gambar 4.5 menunjukkan proses pembagian dataset ke dalam data *training*, *validation*, dan *testing*. Pembagian ini dilakukan agar proses pelatihan dan evaluasi model dapat dilakukan secara lebih terukur.

4.2.4 Penyesuaian Ukuran dan Format Citra

Sebelum digunakan dalam proses pelatihan, citra perlu disesuaikan agar memiliki format yang seragam. Penyeragaman ini dilakukan untuk memastikan bahwa seluruh data dapat diproses oleh model secara konsisten. Pada tahap pra-pemrosesan di Roboflow, citra disiapkan agar sesuai dengan kebutuhan format YOLO, termasuk penyesuaian ukuran citra dan format label.

Penyesuaian ukuran citra penting karena model YOLO membutuhkan input dengan dimensi tertentu selama proses *training*. Citra yang memiliki ukuran berbeda-beda dapat menyebabkan proses pelatihan menjadi kurang stabil apabila

tidak diseragamkan terlebih dahulu. Selain itu, penyesuaian format citra juga membantu mengurangi kemungkinan kesalahan saat dataset dibaca oleh sistem.



Gambar 4. 6 Proses Resize Citra

Gambar 4.6 menunjukkan proses penyesuaian ukuran citra sebelum dataset digunakan dalam pelatihan model. Proses ini dilakukan agar seluruh citra memiliki format yang seragam dan dapat diproses oleh model YOLOv8

4.2.5 Hasil Augmentasi Data


Augmentasi data dilakukan untuk meningkatkan variasi citra tanpa harus mengambil data baru. Pada penelitian ini, augmentasi yang digunakan terdiri dari tiga teknik utama, yaitu *brightness*, *rotation*, dan *flip horizontal*.

1. Teknik *brightness* digunakan dengan rentang perubahan kecerahan sebesar -15% hingga +15%. Augmentasi ini bertujuan untuk mensimulasikan kondisi pencahayaan yang berbeda, seperti citra yang lebih gelap atau lebih terang. Hal ini sesuai dengan kondisi lapangan, di mana pencahayaan tidak selalu stabil.
2. Teknik *rotation* digunakan dengan rentang rotasi sebesar -15° hingga $+15^{\circ}$. Augmentasi ini bertujuan untuk membantu model mengenali objek dari sudut pengambilan gambar yang berbeda. Dalam kondisi nyata, kamera tidak selalu berada pada posisi tegak lurus terhadap objek, sehingga variasi sudut perlu diperkenalkan dalam dataset.

3. Teknik *flip horizontal* digunakan untuk membalik citra secara *horizontal*. Teknik ini membantu model mengenali objek dengan orientasi yang berbeda, sehingga model tidak terlalu bergantung pada posisi objek tertentu.

Tabel 4. 4 Teknik Augmentasi Data

No	Teknik Augmentasi	Nilai/Rentang	Tujuan
1	<i>Brightness</i>	-15% sampai +15%	Mensimulasikan variasi pencahayaan
2	<i>Rotation</i>	-15° sampai +15°	Mensimulasikan variasi sudut kamera
3	<i>Flip Horizontal</i>	Aktif	Menambah variasi orientasi objek



Gambar 4. 7 Contoh Hasil Augmentasi Data

Gambar 4.7 menunjukkan contoh citra asli dan citra hasil augmentasi. Pada gambar tersebut terlihat adanya perubahan kecerahan, rotasi, dan pembalikan *horizontal*. Augmentasi ini membantu model mempelajari variasi citra yang lebih beragam, sehingga diharapkan dapat meningkatkan kemampuan generalisasi model terhadap data baru.

4.2.6 Validasi Hasil Pra-pemrosesan dan Anotasi

Setelah proses anotasi, pembagian dataset, penyesuaian format, dan augmentasi selesai dilakukan, dataset diperiksa kembali untuk memastikan tidak terdapat kesalahan yang dapat mempengaruhi proses pelatihan. Pemeriksaan dilakukan terhadap kesesuaian antara citra dan label, posisi *Bounding box*, serta konsistensi kelas *Fresh* dan *Rotten*.

Validasi ini diperlukan karena kesalahan kecil pada dataset dapat berdampak besar terhadap hasil pelatihan. Misalnya, label yang tertukar antara *Fresh* dan *Rotten* dapat menyebabkan model mempelajari pola yang salah. Demikian juga,

Bounding box yang tidak tepat dapat membuat model kesulitan menentukan lokasi objek.

Hasil validasi menunjukkan bahwa dataset telah disusun dalam format yang sesuai untuk pelatihan YOLOv8. Dataset yang telah melalui proses pra-pemrosesan dan anotasi ini kemudian digunakan pada tahap pelatihan model.

4.2.7 Ringkasan Hasil Pra-pemrosesan Data

Untuk memperjelas hasil pra-pemrosesan data, berikut disajikan ringkasan tahapan yang telah dilakukan.

Tabel 4. 5 Ringkasan Hasil Pra-pemrosesan dan Anotasi Data

No	Tahapan	Hasil
1	Anotasi data	Setiap objek daging diberi <i>Bounding box</i> dan label kelas
2	Format dataset	Dataset diekspor dalam format YOLO
3	Pembagian dataset	Data dibagi menjadi <i>training</i> 70%, <i>validation</i> 15%, dan <i>testing</i> 15%
4	Penyesuaian citra	Citra disesuaikan agar seragam dan sesuai kebutuhan model
5	Augmentasi	Menggunakan <i>brightness</i> , <i>rotation</i> , dan <i>flip horizontal</i>
6	Validasi dataset	Dataset diperiksa untuk memastikan kesesuaian citra, label, dan <i>Bounding box</i>

Berdasarkan Tabel 4.5, seluruh tahapan pra-pemrosesan telah dilakukan untuk memastikan dataset siap digunakan dalam proses pelatihan model YOLOv8. Tahapan ini menghasilkan dataset yang lebih terstruktur, memiliki label yang sesuai, serta memiliki variasi citra yang lebih baik melalui proses augmentasi.

Berdasarkan hasil pra-pemrosesan dan anotasi data, dataset penelitian telah siap digunakan untuk proses pelatihan model YOLOv8. Proses anotasi memberikan informasi lokasi objek melalui *Bounding box*, pembagian dataset memastikan proses pelatihan dan pengujian dilakukan secara objektif, sedangkan augmentasi data membantu meningkatkan variasi citra. Dengan demikian, tahap pra-

pemrosesan dan anotasi menjadi fondasi penting sebelum model memasuki tahap pelatihan.

4.3 Dataset dan Penerapan *Deep Learning* YOLOv8

Setelah proses pra-pemrosesan dan anotasi data selesai dilakukan, tahap selanjutnya adalah menerapkan metode *Deep Learning* YOLOv8 untuk melakukan deteksi kualitas daging sapi. Pada penelitian ini, model yang digunakan adalah YOLOv8n (*Nano*) dengan dua kelas objek, yaitu *Fresh* dan *Rotten*.

Penerapan YOLOv8 dilakukan melalui tahapan konfigurasi model, proses pelatihan, pemantauan perkembangan nilai loss dan metrik evaluasi, serta analisis hasil pelatihan. Dataset yang telah dibagi menjadi data *training*, *validation*, dan *testing* digunakan sesuai dengan fungsi masing-masing. Data *training* digunakan untuk membentuk parameter model, data *validation* digunakan untuk memantau perkembangan model selama proses pelatihan, sedangkan data *testing* digunakan pada tahap pengujian akhir.

YOLOv8 termasuk metode object detection, sehingga model tidak hanya menentukan kelas objek, tetapi juga menentukan lokasi objek daging melalui *Bounding box*. Dengan demikian, keluaran model terdiri atas lokasi objek, kelas objek, dan nilai *Confidence* dari hasil prediksi.

4.3.1 Konfigurasi Pelatihan Model

Sebelum proses pelatihan dilakukan, model YOLOv8n dikonfigurasi menggunakan parameter yang disesuaikan dengan karakteristik dataset dan kemampuan perangkat keras penelitian. Konfigurasi pelatihan yang digunakan ditunjukkan pada Tabel 4.6.

Tabel 4. 6 Parameter Pelatihan Model YOLOv8

Parameter	Nilai
Model	YOLOv8n
<i>Framework</i>	<i>Ultralytics</i> YOLOv8
Bahasa Pemrograman	Python 3.10
<i>Image Size</i>	640 × 640 piksel

Parameter	Nilai
<i>Epoch</i>	100
<i>Batch size</i>	16
<i>Optimizer</i>	Auto
<i>Learning rate</i>	Otomatis (ditentukan <i>Ultralytics</i>)
<i>Patience</i>	100
Dataset Split	<i>Train 70% – Validation 15% – Test 15%</i>
Augmentasi	<i>Rotation, Brightness, Horizontal Flip</i>
<i>Confidence Threshold</i>	0,25
<i>IoU Threshold</i>	0,70
<i>Device</i>	GPU NVIDIA GeForce RTX 3050 Laptop GPU
Jumlah Kelas	2 (<i>Fresh</i> dan <i>Rotten</i>)

Berdasarkan Tabel 4.6, proses pelatihan menggunakan model YOLOv8n dengan ukuran input citra 640×640 piksel dan jumlah pelatihan sebanyak 100 *epoch*. *Batch size* yang digunakan adalah 16, sedangkan *Optimizer* menggunakan pengaturan Auto yang disediakan oleh *Framework Ultralytics*.

Penggunaan 100 *epoch* memberikan kesempatan kepada model untuk melakukan pembelajaran secara lebih bertahap. Selama proses pelatihan, performa model dipantau menggunakan nilai *training loss*, *validation loss*, *Precision*, *Recall*, *mAP@0.5*, dan *mAP@0.5:0.95*.

4.3.2 Proses Pelatihan Model

Proses pelatihan dilakukan dengan memasukkan dataset *training* ke dalam model YOLOv8n. Pada setiap *epoch*, model mempelajari karakteristik visual objek daging sapi berdasarkan dua kelas, yaitu *Fresh* dan *Rotten*. Model menghasilkan prediksi berupa lokasi *Bounding box* dan kelas objek, kemudian hasil tersebut dibandingkan dengan anotasi *Ground truth* untuk menghitung nilai *loss*.


Pada YOLOv8, nilai loss selama pelatihan terdiri atas box loss, class loss, dan DFL loss. Box loss menunjukkan kesalahan dalam menentukan posisi *Bounding box*, sedangkan class loss menunjukkan kesalahan dalam menentukan kelas objek. Sementara itu, DFL loss berkaitan dengan proses regresi lokasi *Bounding box* agar posisi objek dapat diprediksi secara lebih tepat.

Selama proses pelatihan, parameter model diperbarui secara bertahap melalui proses optimasi. Secara umum, semakin kecil nilai loss menunjukkan bahwa kesalahan prediksi model semakin berkurang. Selain itu, nilai *Precision*, *Recall*, dan mAP digunakan untuk melihat peningkatan kemampuan model dalam mendeteksi objek.

Pada penelitian ini, proses pelatihan dilakukan selama 100 *epoch*. Hasil pelatihan menunjukkan bahwa nilai *training loss* secara umum mengalami penurunan dari awal hingga akhir pelatihan. Hal tersebut menunjukkan bahwa model semakin mampu mempelajari karakteristik visual objek dari dataset *training*.

Selain memantau penurunan *training loss*, proses pelatihan juga secara simultan mengevaluasi *validation loss* pada setiap *epoch* menggunakan data validasi. Pemantauan ganda ini sangat krusial untuk memastikan bahwa model tidak mengalami *overfitting*, yaitu suatu kondisi di mana jaringan saraf tiruan terlalu menghafal detail dan *noise* dari data latih, namun kehilangan kemampuannya untuk mengenali pola pada data baru. Selama 100 *epoch* pelatihan tersebut, model secara otomatis mencari titik keseimbangan terbaik antara akurasi pengenalan fitur dan kemampuan generalisasi.


4.3.3 Grafik Hasil Pelatihan Model



Grafik 4. 2 Grafik Hasil Pelatihan Model YOLOv8


Grafik 4.2 menunjukkan perkembangan proses pelatihan model YOLOv8 selama 100 *epoch*. Grafik terdiri atas komponen *training loss*, *validation loss*, *Precision*, *Recall*, *mAP@0.5*, dan *mAP@0.5:0.95*.

1. Pada bagian *training loss*, terlihat bahwa *train/box_loss*, *train/cls_loss*, dan *train/dfl_loss* cenderung mengalami penurunan selama proses pelatihan. *Train/box_loss* menurun hingga sekitar 0,67, *train/cls_loss* hingga sekitar 0,33, sedangkan *train/dfl_loss* mencapai sekitar 1,02 pada akhir pelatihan.



Grafik 4. 3 Training Loss


2. Pada *validation loss*, penurunan juga terlihat pada *val/box_loss* dan *val/cls_loss*, meskipun terdapat fluktuasi selama proses pelatihan. Sementara itu, *val/dfl_loss* mengalami penurunan pada tahap awal dan pertengahan, kemudian kembali meningkat pada beberapa *epoch* terakhir. Kondisi tersebut menunjukkan bahwa peningkatan performa model tidak berlangsung secara sepenuhnya linear.



Grafik 4. 4 Validation Loss

3. Pada sisi metrik evaluasi, *Precision* mengalami peningkatan dan mencapai 94,67% pada *epoch* ke-100. *Recall* pada akhir pelatihan mencapai 85,62%.

Sementara itu, nilai $mAP@0.5$ mencapai 87,95% dan $mAP@0.5:0.95$ mencapai 67,13%.



Grafik 4. 5 Metric Evaluasi

Secara keseluruhan, grafik menunjukkan bahwa model mengalami proses pembelajaran yang cukup baik. *Training loss* terus menurun, sedangkan metrik evaluasi meningkat pada tahap awal dan kemudian cenderung stabil pada *epoch-epoch* berikutnya.

4.3.4 Analisis *Training Loss*

Training loss digunakan untuk mengetahui tingkat kesalahan model pada data *training*. Pada penelitian ini, *training loss* terdiri atas train box loss, train class loss, dan train DFL loss.

1. Berdasarkan hasil *training*, train box loss pada *epoch* pertama sebesar 1,29854 dan menurun menjadi 0,66953 pada *epoch* ke-100. Penurunan tersebut menunjukkan bahwa model semakin baik dalam mempelajari posisi objek dan menentukan *Bounding box* pada citra daging.
2. Train class loss mengalami penurunan yang lebih besar, yaitu dari 2,11159 pada *epoch* pertama menjadi 0,32742 pada *epoch* ke-100. Penurunan ini menunjukkan bahwa model semakin mampu membedakan dua kelas objek, yaitu *Fresh* dan *Rotten*.

3. Sementara itu, train DFL loss turun dari 1,39613 pada *epoch* pertama menjadi 1,02117 pada *epoch* ke-100. Penurunan tersebut menunjukkan adanya peningkatan kemampuan model dalam melakukan regresi dan memperkirakan posisi *Bounding box*.

Dengan demikian, ketiga komponen *training loss* menunjukkan kecenderungan menurun selama proses pelatihan. Kondisi ini menunjukkan bahwa model berhasil melakukan pembelajaran terhadap data *training* dan mengurangi kesalahan prediksi secara bertahap.

4.3.5 Analisis *Validation Loss*

Validation loss digunakan untuk mengetahui kemampuan model dalam mempertahankan performanya terhadap data validasi yang tidak digunakan secara langsung untuk memperbarui bobot model.

1. Pada hasil pelatihan, val box loss sebesar 1,31780 pada *epoch* pertama dan mencapai 1,03353 pada *epoch* ke-100. Nilai terendahnya mencapai sekitar 0,98728 pada *epoch* ke-64, kemudian mengalami sedikit peningkatan pada beberapa *epoch* berikutnya.
2. Val class loss pada *epoch* pertama sebesar 2,26318 dan turun menjadi 0,67839 pada *epoch* ke-100. Nilai terendah tercatat sekitar 0,65917 pada *epoch* ke-73. Penurunan tersebut menunjukkan bahwa model semakin mampu mengenali perbedaan karakteristik kelas *Fresh* dan *Rotten* pada data validasi.
3. Sementara itu, val DFL loss sebesar 1,43976 pada *epoch* pertama dan mencapai 1,33714 pada *epoch* ke-100. Nilai terendah berada sekitar 1,22303 pada *epoch* ke-51, kemudian mengalami peningkatan pada tahap akhir pelatihan.

Fluktuasi *validation loss* pada beberapa *epoch* terakhir menunjukkan bahwa penambahan *epoch* tidak selalu menghasilkan peningkatan performa validasi secara terus-menerus. Kondisi tersebut perlu diperhatikan karena model dapat terus mengalami penurunan *training loss*, sementara sebagian metrik validasi mulai stabil atau berfluktuasi.

Oleh karena itu, hasil *training* menunjukkan bahwa model telah memperoleh pembelajaran yang baik, tetapi *epoch* terakhir tidak selalu menjadi kondisi performa

terbaik model. Pemilihan model terbaik perlu mempertimbangkan metrik validasi, terutama mAP , bukan hanya nilai *loss training*.

4.3.6 Analisis Perkembangan *Precision*, *Recall*, dan mAP Selama *Training*

Selain nilai *loss*, perkembangan model juga diamati melalui *Precision*, *Recall*, $mAP@0.5$, dan $mAP@0.5:0.95$. Keempat metrik tersebut memberikan gambaran mengenai kemampuan model dalam menghasilkan prediksi yang tepat serta mendeteksi objek secara menyeluruh.

1. Pada *epoch* pertama, model memperoleh *Precision* sebesar 76,79%, *Recall* sebesar 79,63%, $mAP@0.5$ sebesar 83,63%, dan $mAP@0.5:0.95$ sebesar 54,85%. Nilai tersebut menunjukkan bahwa model telah mampu menghasilkan deteksi sejak tahap awal, tetapi masih mengalami proses penyesuaian terhadap data.
2. Pada perkembangan berikutnya, nilai *Precision* meningkat. Pada *epoch* ke-50, *Precision* mencapai 93,18%, sedangkan *Recall* berada pada 82,97%. Pada *epoch* ke-100, *Precision* meningkat menjadi 94,67% dan *Recall* menjadi 85,62%.
3. Nilai $mAP@0.5$ pada *epoch* ke-100 mencapai 87,95%, sedangkan $mAP@0.5:0.95$ mencapai 67,13%. Nilai $mAP@0.5$ yang lebih tinggi dibandingkan $mAP@0.5:0.95$ menunjukkan bahwa model memiliki kemampuan deteksi yang baik pada ambang IoU 0,5, tetapi ketepatan lokasi *Bounding box* masih lebih menantang ketika dievaluasi menggunakan rentang IoU yang lebih ketat.

Menariknya, nilai metrik tidak selalu meningkat secara monoton. Nilai $mAP@0.5$ tertinggi mencapai 89,73% pada *epoch* ke-49, sedangkan $mAP@0.5:0.95$ tertinggi mencapai 68,47% sekitar *epoch* ke-84.

Dengan demikian, proses *training* 100 *epoch* tidak berarti bahwa *epoch* ke-100 merupakan titik performa terbaik untuk seluruh metrik. Hasil ini memperlihatkan pentingnya penggunaan model terbaik berdasarkan performa validasi, terutama $mAP@0.5:0.95$, untuk tahap pengujian selanjutnya.

4.3.7 Ringkasan Perkembangan Pelatihan Model

Untuk memperjelas perkembangan model selama proses pelatihan, berikut disajikan ringkasan hasil pada beberapa *epoch*.

Tabel 4. 7 Ringkasan Perkembangan Pelatihan Model YOLOv8

<i>Epoch</i>	<i>Train Box Loss</i>	<i>Train Class Loss</i>	<i>Val Box Loss</i>	<i>Val Class Loss</i>	<i>Precision</i>	<i>Recall</i>	<i>mAP@0.5</i>	<i>mAP@0.5:0.95</i>
1	1,29854	2,11159	1,31780	2,26318	76,79%	79,63%	83,63%	54,85%
10	1,21475	0,80906	1,27738	0,89925	85,64%	85,74%	87,25%	59,31%
20	1,10478	0,68474	1,09500	0,88232	85,54%	84,06%	86,40%	63,82%
30	1,04738	0,62591	1,06366	0,77242	91,89%	86,53%	88,65%	66,08%
40	0,99171	0,58969	1,03877	0,75196	90,31%	84,67%	88,00%	65,41%
50	0,96092	0,55978	1,09986	0,78305	93,18%	82,97%	88,75%	64,35%
75	0,84481	0,47301	1,01857	0,72467	92,79%	85,51%	88,45%	68,21%
85	0,79001	0,44663	1,03983	0,73960	96,08%	83,93%	88,01%	67,53%
100	0,66953	0,32742	1,03353	0,67839	94,67%	85,62%	87,95%	67,13%

Berdasarkan Tabel 4.7, nilai *training loss* secara umum mengalami penurunan dari *epoch* pertama hingga *epoch* ke-100. Train box loss turun dari 1,29854 menjadi

0,66953, sedangkan train class loss turun dari 2,11159 menjadi 0,32742. Hal ini menunjukkan bahwa model semakin baik dalam mempelajari lokasi dan kelas objek pada data *training*.

Dari sisi *validation* loss, val box loss dan val class loss juga menunjukkan kecenderungan lebih rendah dibandingkan kondisi awal meskipun mengalami fluktuasi pada beberapa *epoch*. Fluktuasi tersebut menunjukkan bahwa performa model pada data validasi tidak selalu meningkat secara linear.

Pada metrik evaluasi,

1. *Precision* meningkat dari 76,79% pada *epoch* pertama menjadi 94,67% pada *epoch* ke-100.
2. *Recall* meningkat dari 79,63% menjadi 85,62%.
3. Sementara itu, *mAP@0.5* meningkat dari 83,63% menjadi 87,95%.
4. Sedangkan *mAP@0.5:0.95* meningkat dari 54,85% menjadi 67,13%.

Hasil tersebut menunjukkan bahwa model mengalami proses pembelajaran yang baik selama 100 *epoch*. Namun, beberapa metrik mencapai nilai terbaik pada *epoch* yang berbeda. *Precision* tertinggi mencapai 96,08% pada *epoch* ke-85, sedangkan *mAP@0.5:0.95* mencapai nilai tertinggi sekitar 68,47% pada *epoch* ke-84. Oleh karena itu, evaluasi pada tahap berikutnya perlu menggunakan model terbaik hasil *training*, bukan semata-mata menggunakan bobot pada *epoch* terakhir.

4.4 Pengujian dan Evaluasi Kinerja Model

Setelah proses pelatihan model selesai dilakukan, tahap selanjutnya adalah pengujian dan evaluasi kinerja model. Pengujian dilakukan untuk mengetahui kemampuan model YOLOv8 dalam mendeteksi objek daging sapi pada citra baru yang tidak digunakan secara langsung dalam proses pelatihan. Pada tahap ini, model menghasilkan keluaran berupa *Bounding box*, label kelas, dan nilai *Confidence score*.

Bounding box menunjukkan lokasi objek daging yang berhasil dideteksi oleh model, label kelas menunjukkan hasil klasifikasi objek ke dalam kategori *Fresh* atau *Rotten*, sedangkan *Confidence score* menunjukkan tingkat keyakinan model terhadap prediksi yang diberikan. Dengan demikian, pengujian model tidak hanya menilai apakah model mampu memberikan label yang benar, tetapi juga apakah model mampu menunjukkan posisi objek secara tepat pada citra.


Evaluasi kinerja model dilakukan menggunakan metrik yang umum digunakan dalam tugas *object detection*, yaitu *Precision*, *Recall*, *F1-score*, *Mean Average Precision* atau mAP, serta kurva evaluasi seperti *Precision-Confidence Curve*, *Recall-Confidence Curve*, *F1-Confidence Curve*, dan *Precision-Recall Curve*.

4.4.1 Hasil Pengujian Visual Model

Pengujian visual dilakukan untuk melihat secara langsung bagaimana model YOLOv8 memberikan prediksi pada citra uji. Hasil pengujian divisualisasikan dalam bentuk gambar yang menampilkan *Bounding box*, label kelas, dan nilai *Confidence score*.

Pada penelitian ini, hasil pengujian visual ditampilkan menggunakan beberapa citra hasil prediksi, merujuk pada *batch* pengujian (*val_batch0_pred.jpg*, *val_batch1_pred.jpg*, dan *val_batch2_pred.jpg*). Pemilihan contoh tersebut bertujuan untuk menunjukkan bahwa performa model dapat berbeda tergantung pada kondisi citra, pencahayaan, ukuran objek, dan kompleksitas latar belakang.

1. Hasil Pengujian pada Kelas *Fresh*




Gambar 4. 8 Hasil Pengujian Model pada Kelas *Fresh*

Gambar 4.8 menunjukkan hasil pengujian model terhadap beberapa citra daging dengan kelas *Fresh*. Berdasarkan gambar tersebut, model

mampu mendeteksi objek daging dengan sangat baik. Hal ini terlihat dari munculnya *Bounding box* pada objek daging, disertai label *Fresh* dan nilai *Confidence score* yang konsisten di angka 0,8 hingga 0,9. Nilai tersebut menunjukkan bahwa model memiliki tingkat keyakinan yang kuat dalam mengenali karakteristik visual daging segar, seperti warna merah yang cerah dan tekstur yang lebih padat.

2. Hasil Pengujian Campuran Kelas *Fresh* dan *Rotten* (*Confidence* Tinggi)




Gambar 4. 9 Hasil Pengujian Model pada Kelas *Fresh* dan *Rotten*

Gambar 4.9 menunjukkan hasil pengujian model terhadap citra daging kelas *Fresh* dan *Rotten* dalam satu *batch*. Pada gambar tersebut, model mampu mendeteksi dan membedakan objek daging busuk dan segar dengan *Confidence* yang sangat tinggi, yaitu rata-rata berada di angka 0,9. Hal ini membuktikan bahwa model dapat bekerja dengan baik dan stabil dalam mengklasifikasikan kelas ketika objek memiliki ciri visual yang kuat dan cukup kontras terhadap latar belakangnya.

Keberhasilan model dalam mencapai tingkat *Confidence* yang tinggi pada pengujian campuran ini sangat bergantung pada kualitas ekstraksi fitur oleh lapisan konvolusional pada arsitektur YOLOv8. Daging segar (*fresh*) secara konsisten menampilkan distribusi warna merah yang cerah, sementara daging busuk (*rotten*) menunjukkan degradasi warna menjadi

lebih gelap atau kecoklatan. Perbedaan visual yang sangat tegas ini menciptakan kontras inter-kelas yang tinggi. Kondisi tersebut memudahkan model untuk menarik batas keputusan (*decision boundary*) yang akurat, sehingga sistem dapat mengenali dua objek dengan kelas yang berlawanan dalam satu bingkai (*frame*) yang sama tanpa mengalami kebingungan.

3. Hasil Pengujian dengan *Confidence* Bervariasi



Gambar 4. 10 Hasil Pengujian Model dengan *Confidence* Bervariasi

Gambar 4.10 menunjukkan hasil pengujian model pada beberapa citra dengan nilai *Confidence* yang lebih bervariasi, termasuk adanya deteksi di angka 0,3 pada salah satu objek. Nilai *Confidence* yang lebih rendah menunjukkan bahwa model sesekali mengalami keraguan akibat kondisi citra yang lebih kompleks. Kondisi ini dapat dipengaruhi oleh pencahayaan yang kurang merata, sudut objek, maupun tekstur latar belakang yang mengganggu proses pengenalan visual model.

Hasil ini menunjukkan bahwa meskipun model masih mampu mendeteksi objek, tingkat keyakinan model dapat menurun pada kondisi citra yang lebih kompleks. Oleh karena itu, hasil pengujian visual perlu dilanjutkan dengan evaluasi kuantitatif untuk mengetahui performa model secara lebih objektif.

4.4.2 Ringkasan Pengujian Visual

Untuk memperjelas hasil pengujian visual, berikut disajikan ringkasan dari beberapa gambar hasil prediksi model.

Tabel 4. 8 Ringkasan Pengujian Visual Model

No	Gambar Acuan	Kelas Dominan	Rentang Confidence	Keterangan
1	val_batch0_pred.jpg	<i>Fresh</i>	0,8 – 0,9	Deteksi kelas <i>Fresh</i> sangat stabil dengan keyakinan tinggi.
2	val_batch2_pred.jpg	<i>Fresh & Rotten</i>	0,9	Model berhasil membedakan kedua kelas secara tepat dengan <i>Confidence</i> tinggi.
3	val_batch1_pred.jpg	<i>Fresh</i>	0,3 – 0,9	<i>Confidence</i> bervariasi karena model merespons kondisi citra yang lebih menantang/kompleks.

4.4.3 Hasil Evaluasi Kinerja Model

Setelah pengujian visual dilakukan, performa model dievaluasi secara kuantitatif menggunakan metrik *Precision*, *Recall*, *F1-score*, *mAP@0.5*, dan *mAP@0.5:0.95*.

Tabel 4. 9 Hasil Evaluasi Kinerja Model YOLOv8

No	Metrik Evaluasi	Nilai	Interpretasi
1	<i>Precision</i>	94,67%	Prediksi model memiliki tingkat ketepatan yang sangat tinggi.
2	<i>Recall</i>	85,62%	Model mampu mendeteksi sebagian besar objek dengan baik.
3	<i>F1-score</i>	89,92%	Keseimbangan antara <i>Precision</i> dan <i>Recall</i> tergolong sangat baik.

No	Metrik Evaluasi	Nilai	Interpretasi
4	$mAP@0.5$	88,40%	Performa deteksi pada batas IoU 0,5 tergolong sangat baik.
5	$mAP@0.5:0.95$	67,13%	Ketepatan perbatasan <i>Bounding box</i> pada standar ketat cukup baik.

4.4.4 Perhitungan Metrik Evaluasi

Perhitungan metrik evaluasi dilakukan untuk mengetahui tingkat keberhasilan model YOLOv8 dalam mendeteksi dan mengklasifikasikan kualitas daging sapi ke dalam kelas *Fresh* dan *Rotten*. Metrik yang digunakan dalam penelitian ini meliputi *Precision*, *Recall*, *F1-score*, $mAP@0.5$, dan $mAP@0.5:0.95$.

Metrik tersebut digunakan karena model YOLOv8 tidak hanya melakukan klasifikasi kelas, tetapi juga melakukan deteksi lokasi objek melalui *Bounding box*. Oleh karena itu, evaluasi tidak cukup hanya menggunakan akurasi, tetapi perlu menggunakan metrik yang dapat menilai ketepatan prediksi kelas dan ketepatan lokasi objek.

Berdasarkan hasil evaluasi model, diperoleh nilai *Precision* sebesar 94,67%, *Recall* sebesar 85,62%, *F1-score* sebesar 89,92%, $mAP@0.5$ sebesar 88,40%, dan $mAP@0.5:0.95$ sebesar 67,13%.

1. *Precision*

Precision digunakan untuk mengukur tingkat ketepatan prediksi model. Metrik ini menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan seluruh prediksi yang diberikan model.

Rumus *Precision* adalah:

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

Keterangan:

TP (*True Positive*) adalah jumlah prediksi benar pada objek yang sesuai dengan kelas sebenarnya.

FP (*False positive*) adalah jumlah prediksi salah, yaitu ketika model mendeteksi objek sebagai kelas tertentu, tetapi sebenarnya bukan kelas tersebut.

Berdasarkan hasil evaluasi, nilai *Precision* model adalah:

$$Precision = \frac{9.466}{9.466 + 534} = 0,94666 \text{ (94,67\%)}$$

$$Precision = 94,67\%$$

Nilai ini membuktikan bahwa prediksi yang diberikan oleh model sangat minim *false positive*. Artinya, ketika model mengklasifikasikan sebuah objek sebagai daging *Fresh* atau *Rotten*, tingkat kebenaran prediksi tersebut sangat dapat diandalkan.

Dalam konteks penelitian ini, nilai *Precision* yang tinggi penting karena kesalahan dalam memprediksi kualitas daging dapat berdampak pada pengambilan keputusan.

2. Recall

Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh objek yang seharusnya terdeteksi. Metrik ini menunjukkan seberapa banyak objek yang benar-benar ada berhasil dikenali oleh model.

Rumus *Recall* adalah:

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

Keterangan:

TP (*True Positive*) adalah jumlah objek yang benar-benar terdeteksi sesuai kelasnya.

FN (*False Negative*) adalah jumlah objek yang seharusnya terdeteksi, tetapi tidak berhasil dikenali oleh model.

Berdasarkan hasil evaluasi, nilai *Recall* model adalah:

$$Recall = \frac{8.562}{8.562 + 1.438} = 0,8562 \text{ (85,62\%)}$$

$$Recall = 85,62\%$$

Nilai tersebut menunjukkan model mampu mendeteksi mayoritas objek daging. Sedikitnya jeda antara nilai *Precision* dan *Recall* menandakan masih

terdapat sebagian kecil objek (misalnya yang berukuran terlalu kecil atau tertutup bayangan) yang terlewat oleh model (*false negative*).

Namun, nilai *Recall* yang lebih rendah dibandingkan *Precision* menunjukkan bahwa masih terdapat sebagian objek yang belum berhasil terdeteksi secara optimal. Hal ini dapat terjadi karena beberapa faktor, seperti pencahayaan yang kurang stabil, ukuran objek yang kecil, latar belakang yang kompleks, atau kemiripan visual antara daging segar dan daging busuk.

3. *F1-score*

F1-score digunakan untuk melihat keseimbangan antara *Precision* dan *Recall*. Metrik ini penting karena model yang memiliki *Precision* tinggi belum tentu memiliki *Recall* yang tinggi, begitu pula sebaliknya.

Rumus *F1-score* adalah:

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

Hasil penelitian :

$$Precision = 0,94666$$

$$Recall = 0,85623$$

Berdasarkan hasil evaluasi, Maka perhitungan *F1-score* adalah:

$$F1\text{-Score} = 2 \times \frac{0,94666 \times 0,85623}{0,94666 + 0,85623}$$

$$F1\text{-Score} = 2 \times \frac{0,81061}{1,80289}$$

$$F1\text{-Score} = 2 \times 0,449589 \approx 0,8992$$

Jika dikonversi ke dalam persen:

$$F1 = 89,92\%$$

Nilai F1 sebesar 89,92% menegaskan bahwa model YOLOv8 mencapai keseimbangan yang solid, tidak hanya tajam dalam memberikan prediksi, tetapi juga tidak banyak melewatkan objek aslinya.

4. *IoU (Intersection over Union)*

Sebelum menghitung *mAP*, perlu memahami *IoU*.

IoU (Intersection over Union) digunakan untuk mengukur seberapa tepat posisi *Bounding box* hasil prediksi dibandingkan dengan *Bounding box* sebenarnya.

Rumus:

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$

Sederhananya:

- a. Jika *Bounding box* prediksi sangat dekat dengan *Bounding box* asli, maka *IoU* tinggi.
- b. Jika *Bounding box* prediksi jauh dari *Bounding box* asli, maka *IoU* rendah.

Contoh:

Jika $IoU \geq 0,5$, maka prediksi dianggap benar pada metrik $mAP@0.5$.

5. Average Precision (AP) dan $mAP@0.5$

Average Precision (AP) dan $mAP@0.5$ Berdasarkan kurva *Precision-Recall* untuk ambang batas *IoU* 0,5, nilai Average Precision (AP) per kelas didapatkan sebagai berikut:

AP kelas *Fresh* = 0,995

AP kelas *Rotten* = 0,774

Rata-rata dari AP kedua kelas tersebut menghasilkan nilai Mean Average Precision (mAP):

$$\underline{mAP@0.5 = 88,40\%}$$


Nilai ini menunjukkan model mendeteksi objek daging secara keseluruhan dengan sangat baik, di mana kelas *Fresh* dikenali nyaris sempurna, sementara kelas *Rotten* menyumbang angka yang sedikit lebih rendah akibat karakteristik visualnya yang sangat variatif.

6. $mAP@0.5:0.95$

Nilai ini dievaluasi dengan rentang standar *IoU* yang lebih ketat (dari 0,5 hingga 0,95). Pada penelitian ini diperoleh angka 67,13%. Penurunan angka dari $mAP@0.5$ ke $mAP@0.5:0.95$ adalah wajar. Hal ini mengindikasikan bahwa sistem model telah sukses besar mendeteksi "keberadaan" objek daging, namun presisi ukuran kotaknya (*Bounding box*) untuk menyesuaikan persis dengan tepi objek asli kadang masih kurang rapat.

4.4.5 Analisis *Precision-Confidence Curve*

Kurva *Precision-Confidence* merupakan salah satu instrumen evaluasi visual yang sangat penting dalam model deteksi objek. Analisis pada kurva ini bertujuan untuk melihat sejauh mana tingkat ketepatan prediksi model (kemampuannya dalam meminimalkan *False Positive*) dapat dipertahankan atau ditingkatkan ketika ambang batas keyakinan (*Confidence Threshold*) digeser. Melalui kurva ini, dapat dievaluasi apakah model mampu memberikan prediksi yang benar-benar akurat saat dituntut untuk memiliki tingkat keyakinan yang tinggi. Visualisasi dan pergerakan kurva untuk model YOLOv8 yang telah dilatih dapat dilihat lebih rinci pada grafik berikut.



Grafik 4. 6 *Precision-Confidence Curve*


Kurva ini memvisualisasikan hubungan antara nilai *Confidence Threshold* dan *Precision*. Berdasarkan grafik, *Precision* untuk semua kelas mampu menyentuh angka sempurna 1.00 pada tingkat *Confidence* 0.906.

Artinya, jika sistem diatur agar hanya menerima prediksi dengan tingkat keyakinan di atas 90,6%, maka setiap tebakan yang dikeluarkan oleh model dipastikan 100% akurat dan terhindar dari salah tebak (misalnya, menebak piring sebagai daging). Tren kurva yang menanjak ini membuktikan bahwa *Confidence score* yang dihasilkan oleh YOLOv8 berkorelasi lurus dengan kualitas fiturnya; semakin tinggi keyakinan model, semakin tepat klasifikasinya. Meski demikian, pengaturan *Threshold* yang kelewat tinggi (mendekati 1.00) akan membuat sistem

menjadi terlalu kaku (konservatif), yang berimbas pada penolakan prediksi-prediksi benar yang kebetulan memiliki *Confidence* menengah.

4.4.6 Analisis *Recall-Confidence Curve*

Selain mengevaluasi ketepatan tebakan melalui *precision*, kinerja model juga wajib dinilai dari tingkat kepekaannya dalam menemukan seluruh objek target, yang direpresentasikan oleh kurva *Recall-Confidence*. Analisis pada bagian ini difokuskan untuk mengamati seberapa jauh metrik *recall* bertahan sebelum akhirnya mengalami penurunan ketika sistem dipaksa menjadi lebih konservatif dengan menaikkan *Confidence Threshold*. Evaluasi ini sangat krusial untuk memastikan bahwa model tidak terlalu banyak melewatkan objek asli di lapangan (meminimalkan *False Negative*).




Grafik 4. 7 *Recall-Confidence Curve*

Grafik ini menyoroti kemampuan model menemukan objek. Tercatat bahwa tingkat *Recall* maksimum berada di angka 0.90 pada *Confidence* 0.000. Kurva kelas *Fresh* (biru tipis) dan *Rotten* (oranye tipis) mengalami penurunan bertahap saat *Threshold* diperketat, karena prediksi-prediksi berskala *Confidence* rendah mulai ditolak oleh sistem.

Penurunan garis kurva seiring dengan peningkatan nilai *Confidence Threshold* merupakan karakteristik alami. Ketika ambang batas diperketat, sistem menolak prediksi dengan *Confidence* rendah, sehingga beberapa objek nyata luput dari deteksi (*missed detection*). Jika diamati lebih detail, kurva kelas *fresh* (biru

tipis) mampu bertahan mendatar pada tingkat *recall* tinggi dan baru anjlok ketika *Confidence* melewati 0,8. Sebaliknya, kurva kelas *rotten* (oranye tipis) menurun lebih cepat. Fenomena ini membuktikan bahwa variasi visual ekstrem pada daging busuk seperti warna yang menghitam atau pucat yang menyatu dengan latar belakang membuat model sering kali memberikan skor *Confidence* yang lebih rendah dibandingkan saat mendeteksi daging segar yang warnanya merah kontras.

4.4.7 Analisis *F1-Confidence Curve*




Grafik 4. 8 *F1-Confidence Curve*

F1-Confidence Curve dimanfaatkan untuk melacak *Threshold* paling seimbang. Hasil analisis kurva ini memperlihatkan nilai optimal F1 gabungan semua kelas berada di 0.89 pada *Confidence* 0.428. Kelas *Fresh* tampak sangat dominan mendatar tinggi di atas, sedangkan bentuk kurva *Rotten* yang sedikit lebih rendah menunjukkan model butuh pengenalan tekstur yang lebih variatif untuk daging busuk.

Titik puncak pada *Confidence* 0.428 ini adalah "titik manis" (*sweet spot*) operasional model. Di titik ini, model berhasil mencapai kompromi terbaik: cukup ketat untuk membuang deteksi palsu (*False Positive*), namun cukup sensitif untuk tidak melewatkan objek daging yang sebenarnya (*False Negative*). Dari kurva juga terlihat dominasi kelas *fresh* yang nyaris menyentuh 1.0, sedangkan kurva *rotten* menahan rata-rata gabungan (garis biru tebal) untuk tidak naik lebih tinggi. Hal ini memberikan implikasi teknis bahwa jika model ini kelak diimplementasikan ke

dalam aplikasi *real-time*, pengaturan parameter $\text{conf}=0.42$ hingga 0.45 adalah pilihan yang paling direkomendasikan.

4.4.8 Analisis *Precision-Recall Curve* dan *mAP*



Grafik 4. 9 *Precision-Recall Curve*

Kurva *Precision-Recall* (PR Curve) digunakan untuk memvisualisasikan performa menyeluruh model tanpa terikat pada satu nilai *Threshold* tertentu. Luas area di bawah kurva ini merepresentasikan metrik evaluasi utama, yaitu $mAP@0.5$, yang tercatat sebesar 0.884 (88,40%).

Analisis per kelas pada kurva ini memberikan temuan yang sangat kontras. Garis lengkung kelas *fresh* (dengan *Average Precision* / AP sebesar 0.995) nyaris membentuk sudut siku sempurna di kanan atas grafik. Ini mengindikasikan bahwa YOLOv8 telah bekerja layaknya pendeteksi (*classifier* dan *locator*) yang nyaris sempurna untuk daging segar. Di sisi lain, garis kelas *rotten* (AP sebesar 0.774) mengalami penurunan *precision* lebih dini seiring bertambahnya *recall*. Celah yang cukup lebar antara performa *fresh* dan *rotten* ini membuktikan bahwa degradasi biokimia pada daging busuk menciptakan inkonsistensi visual (baik tekstur maupun pantulan warna) yang sangat menantang bagi jaringan konvolusional.

4.4.9 Ringkasan Evaluasi Kinerja Model

Untuk memperjelas hasil evaluasi, berikut disajikan ringkasan hasil pengujian dan evaluasi model.

Tabel 4. 10 Ringkasan Evaluasi Kinerja Model

No	Aspek Evaluasi	Hasil	Interpretasi
1	<i>Precision</i>	94,67%	Ketepatan tebakan model sangat presisi dan andal.
2	<i>Recall</i>	85,62%	Model mampu menjangkau sebagian besar objek daging dengan baik.
3	<i>F1-score</i>	89,92%	Tingkat keseimbangan antara <i>Precision</i> dan <i>Recall</i> tergolong sangat solid.
4	<i>mAP@0.5</i>	88,40%	Kinerja pendeteksian <i>Bounding box</i> secara general (IoU 0.5) memuaskan.
5	<i>mAP@0.5:0.95</i>	67,13%	Model menemukan area objek dengan baik, walau ketepatan tepian <i>Bounding box</i> bisa ditingkatkan.
6	<i>AP Fresh</i>	0,995	Kemampuan deteksi kelas daging segar nyaris sempurna.
7	<i>AP Rotten</i>	0,774	Deteksi kelas daging busuk cukup baik, walau lebih menantang secara visual.
8	F1 terbaik	0.89 pada conf 0.428	Model bekerja paling seimbang pada ambang <i>Confidence</i> menengah.
9	<i>Precision</i> terbaik	1.00 pada conf 0.906	Model 100% tepat sasaran jika memprediksi dengan tingkat keyakinan tinggi.


Berdasarkan Tabel 4.10, dapat disimpulkan bahwa model YOLOv8 memiliki performa yang baik secara keseluruhan dalam mendeteksi kualitas daging sapi. Model mampu memberikan prediksi dengan nilai *Precision* yang tinggi, sehingga sebagian besar hasil deteksi yang dihasilkan merupakan prediksi yang benar. Selain itu, model juga mampu mendeteksi sebagian besar objek pada dataset dengan baik, yang ditunjukkan oleh nilai *Recall* yang tinggi. Hasil tersebut menunjukkan bahwa model tidak hanya akurat dalam mengklasifikasikan objek, tetapi juga memiliki

kemampuan deteksi yang konsisten, sehingga layak digunakan untuk mendukung proses identifikasi kualitas daging sapi secara otomatis.

4.5 Analisis *Confusion matrix* dan Kesalahan Prediksi

Analisis *confusion matrix* digunakan untuk mengevaluasi kinerja model klasifikasi dan deteksi secara lebih terperinci dengan memetakan perbandingan antara label sebenarnya (*True / Ground truth*) dengan label hasil prediksi model (*Predicted*). Melalui matriks ini, performa model YOLOv8 dievaluasi tidak hanya dari persentase akurasi globalnya, tetapi juga dari distribusi jumlah kasus mentah (angka riil) pada masing-masing kelas, sehingga pola *True Positive* (TP), *False Positive* (FP), dan *False Negative* (FN) dapat diidentifikasi secara spesifik.

4.5.1 Analisis *Confusion matrix*



Grafik 4. 10 *Confusion matrix Normalized*

Berdasarkan *confusion matrix* yang dihasilkan, model menunjukkan performa ekstraksi fitur yang sangat optimal pada kelas *Fresh*. Dari total 117 sampel daging segar yang diuji (kolom *True Fresh*), model berhasil memprediksi dengan benar sebanyak 108 citra (92%). Terdapat 9 kasus (8%) di mana daging segar disalahartikan sebagai daging busuk (*Rotten*), dan model sama sekali tidak kehilangan objek pada kelas ini (0 kasus *False Negative* ke *background*).

Pada kelas *Rotten*, model berhasil mengidentifikasi 107 dari total 138 sampel dengan benar, merepresentasikan tingkat akurasi kelas (*class-wise accuracy*) sebesar 78%. Kesalahan klasifikasi pada kelas ini terbagi menjadi dua: 10 kasus

(7%) di mana daging busuk ditebak sebagai daging segar, dan 21 kasus (15%) di mana objek daging busuk gagal terdeteksi oleh sistem sehingga terhitung sebagai latar belakang (*background*).

Matriks ini juga mengungkap metrik *False Positive* pada area *background* (kolom *True background*). Terdapat 578 kejadian di mana model keliru mendeteksi area non-objek (seperti tepian piring, bayangan, atau pantulan cahaya pada meja) sebagai daging, atau di mana *Bounding box* prediksi memiliki nilai *Intersection over Union* (IoU) yang terlalu rendah terhadap *Ground truth*. Dari total 578 kesalahan *false positive* ini, mayoritas condong ke kelas *Rotten* dengan 471 kasus (81%), sedangkan 107 kasus sisanya (19%) diprediksi sebagai *Fresh*.

4.5.2 Analisis Kesalahan pada Kelas *Fresh*

Kelas *Fresh* memiliki performa terbaik dan paling stabil dengan nilai prediksi benar mencapai 92% (108 dari 117 kasus). Secara teknis, karakteristik visual daging segar memiliki varians intra-kelas (*intra-class variance*) yang sangat rendah. Daging segar umumnya memiliki spektrum warna merah yang spesifik, cerah, seragam, serta batas tepi (*edge*) yang sangat kontras dengan lingkungan sekitarnya. Hal ini memudahkan lapisan konvolusi (*convolutional layers*) pada arsitektur YOLOv8 untuk mengekstraksi peta fitur (*feature maps*) yang kuat dan konsisten.

Sebagian kecil kesalahan (8%) terjadi ketika model mengklasifikasikan daging segar sebagai daging busuk. Kondisi ini dipicu oleh gangguan iluminasi atau pencahayaan yang kurang optimal. Area daging segar yang tertutup bayangan (*shadows*) akan mengalami penurunan intensitas piksel, menggeser ruang warna citra menjadi lebih gelap. Model *Deep Learning* secara matematis akan membaca pergeseran nilai piksel ini sebagai fitur yang mendekati kelas *Rotten*.

4.5.3 Analisis Kesalahan pada Kelas *Rotten*

Performa pengenalan kelas *Rotten* tercatat di angka 78%. Walaupun cukup andal, tingkat kesulitan deteksi pada kelas ini terbukti lebih tinggi akibat fenomena degradasi fisik dan biokimiawi daging yang menciptakan varians visual yang sangat lebar.

Daging yang membusuk mengalami oksidasi mioglobin menjadi metmioglobin, yang mengubah warna daging secara tidak beraturan mulai dari merah gelap, kecoklatan, kehitaman, hingga memucat. Spektrum warna yang sangat

luas ini membuat model kesulitan menemukan pola fitur yang konsisten. Akibatnya, terdapat 7% kasus di mana model menganggap area daging busuk yang terpapar cahaya terang sebagai daging *Fresh*.

Lebih lanjut, terdapat 15% (21 kasus) objek *Rotten* yang luput dari deteksi (*false negative*) dan jatuh ke kategori *background*. Kegagalan lokalisasi ini terjadi karena nilai kontras antara daging busuk (yang berwarna gelap) dengan latar belakang (misalnya meja kayu yang juga gelap) sangat rendah. Model gagal menemukan gradien tepi objek, sehingga *Confidence score* turun di bawah ambang batas (*Threshold*) atau *Bounding box* tidak terbentuk sama sekali.


4.5.4 Analisis Kesalahan terhadap *Background*

Analisis nilai pada baris *Predicted* kelas *Fresh* dan *Rotten* terhadap kolom *True background* memberikan pemahaman krusial terkait kelemahan deteksi (*False Positive*). Terlihat jelas bahwa ketika model keliru mendeteksi area latar belakang sebagai objek, 81% dari kesalahan tersebut dialokasikan ke kelas *Rotten*.

Tingginya proporsi bias ini sangat logis mengingat rentang warna dan tekstur daging busuk yang tidak beraturan sangat mirip dengan berbagai elemen di lingkungan sekitar (kemiripan inter-kelas / *inter-class similarity*). area gelap di bawah piring, bercak kotoran, memiliki distribusi warna kusam yang secara komputasi menyerupai fitur kelas *Rotten*. Sebaliknya, ciri visual kelas *Fresh* yang dominan merah cerah membuatnya jauh lebih eksklusif, sehingga model jarang salah menebak elemen latar belakang sebagai daging segar. Hal ini juga mengindikasikan bahwa selama proses *training*, anotasi *Bounding box* mungkin terlalu longgar (*loose*), sehingga jaringan saraf tiruan ikut mempelajari piksel latar belakang sebagai bagian dari definisi "daging busuk".

4.5.5 Contoh Kesalahan Prediksi Model

Analisis terhadap kesalahan prediksi bertujuan untuk mengidentifikasi faktor-faktor yang memengaruhi penurunan performa model, seperti kondisi pencahayaan yang kurang baik, sudut pengambilan citra yang bervariasi, kualitas citra, maupun kemiripan karakteristik visual antara daging segar dan daging busuk. Dengan melakukan analisis ini, dapat diketahui keterbatasan model sekaligus menjadi bahan evaluasi untuk meningkatkan performa model pada penelitian selanjutnya.



Gambar 4. 11 Contoh Kesalahan Prediksi Model

Gambar 4.11 memvisualisasikan bagaimana kondisi lingkungan nyata mendisrupsi kinerja model. Terdapat beberapa objek yang nilai *Confidence*-nya turun drastis hingga angka 0,3. Penurunan tingkat keyakinan ini merupakan representasi dari ketidakpastian model (*model uncertainty*) ketika menghadapi gangguan (*noise*) pada citra.

Beberapa kendala visual yang dapat diamati meliputi:

1. Refleksi Spekular (*Specular Reflection*): Pantulan cahaya pada permukaan daging yang basah atau pada piring menciptakan bercak putih (piksel *overexposed*). Hal ini merusak informasi tekstur asli daging, sehingga model ragu menentukan kelasnya.
2. Oklusi dan Skala Objek: Beberapa potongan daging berukuran relatif kecil atau diletakkan dengan sudut perspektif tertentu.
3. Pola Latar Belakang yang Dominan: Motif garis pada meja atau lekukan pada piring memicu munculnya batas tepi semu (*false edges*) yang mengacaukan algoritma prediksi *Bounding box*.

4.5.6 Faktor Penyebab Kesalahan Prediksi

Secara komprehensif, penurunan metrik akurasi dan munculnya kesalahan klasifikasi maupun lokalisasi dipicu oleh empat faktor teknis:

1. Ketidakstabilan Iluminasi (*Illumination Variance*): Pencahayaan yang fluktuatif di lapangan mengubah nilai intensitas matriks piksel RGB (Red, Green, Blue) secara drastis, menyebabkan *overlap* fitur antara daging segar yang tertutup bayangan dengan daging busuk.
2. Varians Intra-Kelas yang Tinggi pada Kelas *Rotten*: Rentang degradasi visual daging busuk yang sangat luas menyulitkan model untuk membentuk batas keputusan (*decision boundary*) yang tegas di dalam ruang fitur.
3. Kemiripan Inter-Kelas dengan Background: Elemen pasar tradisional (piring kusam, meja kayu, bercak noda) memiliki distribusi tekstur yang menyerupai daging busuk, memicu tingginya angka *False Positive*.
4. Presisi Anotasi (*Ground truth Quality*): Kesalahan *Bounding box* memprediksi *background* (578 kasus) mengindikasikan perlunya anotasi piksel yang lebih ketat (menempel pas pada tepi daging) agar fitur latar belakang tidak ikut masuk ke dalam kalkulasi *loss function* saat *training*.

4.5.7 Implikasi dan Rekomendasi Teknis

Temuan analisis kesalahan ini memberikan fondasi penting untuk optimasi sistem ke depan. Dominasi kesalahan pada lokalisasi dan bias kelas *Rotten* menuntut adanya perbaikan pada strategi prapemrosesan dan hiperparameter model.

1. Optimasi Dataset: Diperlukan penambahan variasi citra daging busuk dengan kondisi pencahayaan dan latar belakang ekstrem (*hard examples*) agar model belajar mendiskriminasi fitur dengan lebih baik.
2. Augmentasi Lanjutan: Penerapan teknik augmentasi seperti *Mosaic* atau *Random Erasing* dapat memaksa model mengenali objek dari sebagian kecil fitur tanpa terlalu bergantung pada warna global atau latar belakang.
3. Pengetatan Anotasi: Penarikan garis *Bounding box* (*labelling*) harus dilakukan lebih presisi, memastikan seminimal mungkin piksel piring atau meja yang masuk ke dalam kotak deteksi.

4.6 Perbandingan Dataset Publik dan Dataset Lapangan

Perbandingan performa model YOLOv8 ketika berhadapan dengan dua jenis dataset yang digunakan dalam penelitian, yaitu dataset publik LOCBEED dan dataset lapangan. Analisis ini dilakukan untuk mengetahui sejauh mana model

mampu mempertahankan performanya ketika diuji pada data yang memiliki karakteristik berbeda.

Sebelumnya telah dijelaskan bahwa model YOLOv8 memperoleh hasil evaluasi yang cukup baik secara keseluruhan. Namun, hasil tersebut perlu dianalisis lebih lanjut berdasarkan karakteristik dataset, karena performa model *Deep Learning* sangat dipengaruhi oleh kualitas, variasi, dan distribusi data yang digunakan.

Dataset publik LOCBEEF memiliki kondisi citra yang relatif lebih terkontrol, sedangkan dataset lapangan memiliki kondisi yang lebih kompleks karena diambil langsung dari lingkungan pasar tradisional. Perbedaan ini menjadi penting karena model yang baik tidak hanya harus mampu bekerja pada data yang bersih, tetapi juga harus mampu beradaptasi dengan data nyata yang memiliki variasi pencahayaan, latar belakang, posisi objek, dan kualitas citra.

4.6.1 Karakteristik Dataset Publik dan Dataset Lapangan

Dataset publik LOCBEEF memiliki karakteristik yang lebih stabil. Citra pada dataset ini cenderung memiliki pencahayaan yang lebih merata, objek yang lebih jelas, serta latar belakang yang tidak terlalu kompleks. Kondisi tersebut memudahkan model dalam mengenali pola visual utama dari daging sapi, baik pada kelas *Fresh* maupun *Rotten*.

Sebaliknya, dataset lapangan memiliki variasi yang lebih tinggi. Citra lapangan diambil pada kondisi nyata di pasar tradisional, sehingga terdapat banyak faktor yang dapat mempengaruhi kualitas gambar. Faktor tersebut meliputi pencahayaan alami yang tidak selalu stabil, adanya bayangan, latar belakang berupa meja, piring, plastik, serta sudut pengambilan gambar yang berbeda-beda.

Perbedaan karakteristik tersebut menyebabkan dataset lapangan memiliki tingkat kesulitan yang lebih tinggi dibandingkan dataset publik. Variasi pencahayaan, latar belakang, sudut pengambilan gambar, serta kondisi lingkungan yang tidak seragam membuat proses deteksi menjadi lebih menantang bagi model. Oleh karena itu, pengujian pada dataset lapangan menjadi sangat penting untuk mengevaluasi kemampuan model dalam menghadapi kondisi nyata (*real-world conditions*), bukan hanya pada data yang diperoleh dari lingkungan yang terkontrol. Hasil pengujian ini juga memberikan gambaran mengenai tingkat generalisasi

model YOLOv8, sehingga dapat diketahui sejauh mana model mampu mempertahankan performanya ketika diterapkan pada situasi operasional yang sesungguhnya.

Tabel 4. 11 Perbandingan Karakteristik Dataset Publik dan Dataset Lapangan

No	Aspek	Dataset Publik LOCBEEF	Dataset Lapangan
1	Kondisi pencahayaan	Relatif stabil	Bervariasi dan alami
2	Latar belakang	Lebih sederhana	Lebih kompleks
3	Posisi objek	Cenderung jelas	Bervariasi
4	Variasi warna	Lebih terkontrol	Lebih beragam
5	Tingkat kesulitan	Lebih rendah	Lebih tinggi
6	Representasi kondisi nyata	Terbatas	Lebih realistis
7	Fungsi dalam penelitian	Membantu model mempelajari pola dasar	Menguji kemampuan model pada kondisi nyata

Berdasarkan Tabel 4.11, dataset lapangan memiliki kompleksitas yang lebih tinggi dibandingkan dataset publik. Kompleksitas ini dapat mempengaruhi performa model, khususnya pada kelas *Rotten* yang memiliki variasi visual lebih besar dibandingkan kelas *Fresh*.

4.6.2 Perbandingan Performa pada Dataset Publik dan Lapangan

Perbandingan performa model pada dataset publik dan dataset lapangan dilakukan untuk mengetahui pengaruh karakteristik data terhadap kemampuan model YOLOv8 dalam mendeteksi kualitas daging sapi. Dataset publik memiliki kondisi citra yang relatif lebih terkontrol, sedangkan dataset lapangan memiliki kondisi yang lebih kompleks karena diambil langsung pada lingkungan nyata.


Pada bagian ini, perbandingan dilakukan berdasarkan grafik hasil pelatihan, nilai metrik evaluasi, *confusion matrix*, serta kurva *Precision-Recall*. Dengan menggunakan beberapa indikator tersebut, performa model dapat dianalisis secara lebih menyeluruh, baik dari sisi proses pelatihan maupun hasil evaluasi model.

Perlu dicatat bahwa pada tahap perbandingan ini, pelatihan model untuk dataset publik dan dataset lapangan secara terpisah dilakukan menggunakan parameter sebanyak 50 *epoch*. Hal ini berbeda dengan pelatihan model utama (dataset gabungan) yang dilatih hingga 100 *epoch*. Pemilihan 50 *epoch* untuk studi komparatif ini dinilai sudah cukup memadai karena tujuan utamanya adalah untuk mengamati tren pembelajaran awal, karakteristik dasar, serta letak perbedaan performa ketika model berhadapan dengan dua kondisi citra yang berbeda (terkontrol vs lingkungan nyata). Di sisi lain, pelatihan 100 *epoch* diterapkan pada dataset gabungan karena volume data dan kompleksitas variansinya jauh lebih besar, sehingga model membutuhkan iterasi pembelajaran yang lebih panjang untuk dapat mencapai titik konvergensi yang optimal.


Perbedaan karakteristik antara dataset publik (LOCBEEF) dan dataset lapangan sebagaimana tercantum pada tabel di atas berimplikasi langsung pada proses pelatihan model. Dataset publik cenderung memiliki pencahayaan yang stabil dan latar belakang seragam (*controlled environment*), sehingga memudahkan model dalam mempelajari fitur dasar daging. Sebaliknya, dataset lapangan dari pasar tradisional di Aceh memiliki tantangan berupa tingkat pencahayaan yang bervariasi, distorsi warna akibat penggunaan lampu, serta variasi sudut pandang pengambilan citra. Kehadiran variasi ini sangat penting untuk meningkatkan kemampuan generalisasi model YOLOv8 agar siap diterapkan pada skenario dunia nyata (*real-world deployment*).

Selain itu, hasil perbandingan antara kedua dataset juga memberikan gambaran mengenai tingkat robustness model terhadap variasi kondisi pengambilan citra. Model yang dilatih menggunakan dataset publik umumnya menunjukkan proses konvergensi yang lebih cepat serta nilai evaluasi yang lebih tinggi karena karakteristik datanya lebih homogen. Sebaliknya, model pada dataset lapangan memerlukan proses pembelajaran yang lebih menantang akibat tingginya variasi lingkungan. Meskipun demikian, performa yang diperoleh pada dataset lapangan menjadi indikator penting bahwa model tidak hanya mampu bekerja pada kondisi ideal, tetapi juga memiliki kemampuan adaptasi terhadap kondisi operasional di lapangan. Oleh karena itu, analisis perbandingan ini menjadi dasar untuk menilai

efektivitas penggunaan dataset gabungan sebagai strategi dalam meningkatkan akurasi sekaligus kemampuan generalisasi model YOLOv8.



Grafik 4.11 Grafik Hasil Pelatihan Dataset Publik



Grafik 4.12 Grafik Hasil Pelatihan Dataset Lapangan

Berdasarkan proses pelatihan, model yang menggunakan dataset publik menunjukkan proses konvergensi yang baik. Hal ini terlihat dari penurunan nilai *training loss* dan *validation loss* secara bertahap hingga akhir pelatihan. Pada *epoch* ke-50, model menghasilkan nilai *Precision* sebesar 92,72%, *Recall* sebesar 86,45%, *mAP@0.5* sebesar 88,63%, dan *mAP@0.5:0.95* sebesar 70,87%. Nilai tersebut menunjukkan bahwa model memiliki kemampuan yang tinggi dalam mendeteksi objek daging sapi pada dataset publik.

Pada dataset lapangan, grafik hasil pelatihan menunjukkan bahwa nilai *training loss* juga mengalami penurunan secara jelas. Namun, grafik validasi

menunjukkan fluktuasi yang lebih besar, terutama pada *val/cls_loss*, *val/dfl_loss*, *Precision*, dan *mAP*. Fluktuasi ini menunjukkan bahwa model menghadapi data yang lebih bervariasi dan kompleks pada dataset lapangan. Kondisi pencahayaan, latar belakang, posisi objek, dan ukuran objek yang berbeda-beda menyebabkan proses validasi menjadi lebih menantang.

Berdasarkan hasil akhir *epoch* ke-50, perbandingan metrik dataset publik dan dataset lapangan dapat dilihat pada tabel berikut.

Tabel 4. 12 Perbandingan Performa Dataset Publik dan Dataset Lapangan

No	Metrik	Dataset Publik	Dataset Lapangan	Interpretasi
1	Train Box loss	0,74826	0,65506	Dataset lapangan memiliki train box loss lebih rendah
2	Train Class loss	0,41089	0,43723	Dataset lapangan sedikit lebih rendah pada class loss training
3	Train DFL loss	1,10161	1,01225	Dataset publik lebih baik pada ketepatan distribusi Bounding box
4	Validation Box loss	0,98004	0,90938	Dataset lapangan sedikit lebih rendah pada val box loss
5	Validation Class loss	0,72445	0,80635	Dataset publik lebih stabil dalam klasifikasi validasi
6	Validation DFL loss	1,25805	1,35521	Dataset publik lebih baik pada ketepatan Bounding box validasi
7	Precision	92,72%	72,47%	Dataset publik memiliki prediksi lebih tepat
8	Recall	86,45%	87,72%	Dataset lapangan mendeteksi lebih banyak objek
9	<i>mAP@0.5</i>	88,63%	83,87%	Dataset publik sedikit lebih unggul
10	<i>mAP@0.5:0.95</i>	70,87%	59,43%	Dataset publik lebih baik pada standar <i>IoU</i> ketat

Berdasarkan Tabel 4.12, model YOLOv8 menunjukkan performa yang baik pada dataset publik maupun dataset lapangan. Pada tahap pelatihan, dataset publik menghasilkan nilai Train Class Loss yang lebih rendah, sedangkan dataset lapangan

memiliki nilai Train Box Loss dan Train DFL Loss yang lebih kecil. Hal ini menunjukkan bahwa model pada dataset publik lebih baik dalam mempelajari klasifikasi objek, sementara dataset lapangan sedikit lebih baik dalam mempelajari lokasi dan distribusi *Bounding box*.

Pada tahap validasi, dataset publik memperoleh *Validation Class Loss* dan *Validation DFL Loss* yang lebih rendah dibandingkan dataset lapangan, sedangkan *Validation Box Loss* pada dataset lapangan masih sedikit lebih kecil. Kondisi ini menunjukkan bahwa model yang dilatih menggunakan dataset publik memiliki kemampuan yang lebih stabil dalam mengklasifikasikan objek dan mempertahankan kualitas prediksi *Bounding box* pada data validasi.

Dari sisi evaluasi kinerja, dataset publik memperoleh *Precision* sebesar 92,72%, jauh lebih tinggi dibandingkan dataset lapangan sebesar 72,47%. Hal ini menunjukkan bahwa model menghasilkan prediksi yang lebih tepat dengan jumlah kesalahan deteksi (*false positive*) yang lebih sedikit pada dataset publik. Sebaliknya, dataset lapangan memperoleh *Recall* sebesar 87,72%, sedikit lebih tinggi dibandingkan dataset publik sebesar 86,45%, yang menunjukkan bahwa model mampu mendeteksi lebih banyak objek pada kondisi lapangan.


Selain itu, nilai $mAP@0.5$ sebesar 88,63% dan $mAP@0.5:0.95$ sebesar 70,87% pada dataset publik juga lebih tinggi dibandingkan dataset lapangan yang masing-masing memperoleh 83,87% dan 59,43%. Hasil tersebut menunjukkan bahwa model memiliki performa deteksi yang lebih baik pada dataset publik karena kualitas citra yang lebih seragam, pencahayaan yang lebih konsisten, serta proses akuisisi data yang lebih terkontrol. Meskipun demikian, hasil pada dataset lapangan tetap menunjukkan performa yang baik, sehingga dapat disimpulkan bahwa model YOLOv8 yang dikembangkan mampu melakukan generalisasi dan tetap efektif ketika diterapkan pada citra daging sapi yang diperoleh langsung dari kondisi nyata di lapangan.

4.6.3 Analisis *Confusion matrix* Dataset Publik dan Lapangan

Confusion Matrix digunakan untuk menganalisis kemampuan model YOLOv8 dalam membedakan objek daging sapi segar (*Fresh*) dan daging sapi busuk (*Rotten*). Melalui *Confusion Matrix*, dapat diketahui jumlah prediksi yang benar maupun kesalahan klasifikasi yang dilakukan model pada masing-masing

kelas. Analisis ini memberikan gambaran mengenai tingkat akurasi model dalam mengenali setiap kelas serta kemampuan model dalam meminimalkan kesalahan prediksi.


Selain itu, analisis *confusion matrix* juga memungkinkan identifikasi terhadap pola kesalahan spesifik, seperti *false positive* (kesalahan model mendeteksi latar belakang atau kelas lain sebagai objek) dan *false negative* (objek yang gagal terdeteksi oleh sistem). Dengan mengevaluasi distribusi kesalahan ini secara komprehensif, dapat diketahui bagian mana dari model yang masih memerlukan perbaikan, sehingga langkah pengoptimalan seperti penyesuaian anotasi atau penambahan variasi data dapat dilakukan secara lebih terarah.



Grafik 4. 13 *Confusion matrix Dataset Publik.*

Berdasarkan Grafik 4.10, model berhasil mengidentifikasi kelas *Fresh* dengan tingkat prediksi benar sebesar 94%, sedangkan kelas *Rotten* berhasil dikenali dengan tingkat prediksi benar sebesar 81%. Nilai tersebut menunjukkan bahwa sebagian besar objek pada dataset publik berhasil diklasifikasikan dengan benar, sehingga mengindikasikan bahwa model memiliki kemampuan yang baik dalam membedakan kedua kelas pada kondisi citra yang relatif terkontrol. Kesalahan klasifikasi antara kedua kelas relatif kecil, yaitu sekitar 6% objek *Fresh* diprediksi sebagai *Rotten* dan sekitar 5% objek *Rotten* diprediksi sebagai *Fresh*. Kesalahan ini kemungkinan disebabkan oleh adanya kemiripan karakteristik visual

pada beberapa sampel, seperti tekstur dan warna daging yang menyerupai satu sama lain. Secara keseluruhan, hasil confusion matrix menunjukkan bahwa model YOLOv8 memiliki tingkat konsistensi prediksi yang tinggi pada dataset publik, sehingga dapat dikatakan mampu melakukan deteksi kualitas daging sapi dengan performa yang baik pada kondisi data yang terkontrol.



Grafik 4. 14 Confusion matrix Dataset Lapangan

Sementara itu, berdasarkan Grafik 4.11, model pada dataset lapangan mampu mengidentifikasi kelas *Fresh* dengan tingkat prediksi benar sebesar 82%, sedangkan kelas *Rotten* dikenali dengan tingkat prediksi benar sebesar 78%. Dibandingkan dataset publik, tingkat kesalahan klasifikasi pada dataset lapangan masih lebih tinggi. Hal ini disebabkan oleh variasi kondisi nyata, seperti perubahan pencahayaan, tekstur permukaan daging, sudut pengambilan gambar, serta latar belakang yang lebih kompleks sehingga menyulitkan model dalam membedakan objek.

Perbandingan kedua *Confusion Matrix* menunjukkan bahwa model memberikan performa yang lebih baik pada dataset publik dibandingkan dataset lapangan. Hal ini terlihat dari nilai prediksi benar (*true positive*) yang lebih tinggi pada kedua kelas, terutama kelas *Fresh* yang mencapai 94% pada dataset publik dibandingkan 82% pada dataset lapangan. Selain itu, jumlah kesalahan klasifikasi


pada dataset publik juga lebih rendah sehingga menghasilkan nilai *Precision* dan *mAP* yang lebih tinggi sebagaimana ditunjukkan pada hasil evaluasi sebelumnya.

Tabel 4. 13 Perbandingan Hasil Confusion Matrix

Kelas	Dataset Publik	Dataset Lapangan
<i>Fresh</i> terdeteksi benar	94%	82%
<i>Rotten</i> terdeteksi benar	81%	78%
Kesalahan klasifikasi	Rendah	Lebih tinggi
Kondisi dataset	Terkontrol	Kondisi nyata


4.6.4 Analisis *Precision-Recall Curve* Dataset Publik dan Lapangan

Precision-Recall Curve digunakan untuk menganalisis hubungan antara nilai *Precision* dan *Recall* pada berbagai nilai *Confidence Threshold*. Kurva ini menunjukkan kemampuan model dalam mempertahankan tingkat ketepatan prediksi (*Precision*) ketika berusaha mendeteksi sebanyak mungkin objek (*Recall*). Semakin luas area di bawah kurva (*Average Precision/AP*), maka semakin baik performa model dalam mendeteksi objek.



Grafik 4. 15 *Precision-Recall Curve* Dataset Publik

Berdasarkan Grafik 4.15, model pada dataset publik menghasilkan AP sebesar 99,5% untuk kelas *Fresh* dan 77,8% untuk kelas *Rotten*, dengan $mAP@0.5$ sebesar 88,63%. Kurva kelas *Fresh* yang mendekati sudut kanan atas menunjukkan bahwa model mampu mempertahankan *Precision* dan *Recall* secara optimal. Meskipun kelas *Rotten* memiliki AP yang lebih rendah akibat variasi visual yang kompleks, performa keseluruhan model tetap tergolong sangat baik dalam mendeteksi daging sapi segar.



Grafik 4. 16 Precision-Recall Curve Dataset Lapangan

Pada Grafik 4.13, hasil pengujian menggunakan dataset lapangan menunjukkan nilai Average *Precision* (AP) sebesar 93,8% untuk kelas *Fresh* dan 79,8% untuk kelas *Rotten*, dengan nilai $mAP@0.5$ sebesar 86,8%. Bentuk kurva masih menunjukkan hubungan yang baik antara *Precision* dan *Recall*, namun terjadi penurunan performa dibandingkan dataset publik. Penurunan tersebut dipengaruhi oleh variasi kondisi pengambilan citra di lapangan, seperti perbedaan pencahayaan, tekstur daging, sudut pengambilan gambar, dan latar belakang yang lebih kompleks dibandingkan dataset publik.

Tabel 4. 14 Perbandingan Hasil Precision-Recall Curve

Parameter	Dataset Publik	Dataset Lapangan
<i>AP Fresh</i>	99,5%	93,8%
<i>AP Rotten</i>	77,8%	79,8%
<i>mAP@0.5</i>	88,63%	86,8%
Interpretasi	Performa keseluruhan lebih baik	Generalisasi baik pada kondisi nyata

Jika dibandingkan, dataset publik memiliki nilai *mAP@0.5* yang sedikit lebih tinggi, yaitu 88,63%, dibandingkan 86,8% pada dataset lapangan. Selain itu, nilai AP pada kelas *Fresh* juga meningkat dari 93,8% menjadi 99,5%, menunjukkan bahwa model mampu mengenali objek daging segar dengan tingkat ketepatan yang sangat tinggi pada dataset publik. Sebaliknya, nilai AP kelas *Rotten* pada dataset publik (77,8%) sedikit lebih rendah dibandingkan dataset lapangan (79,8%). Hal ini mengindikasikan bahwa karakteristik visual daging busuk masih lebih bervariasi sehingga menjadi tantangan bagi model dalam proses deteksi.

Secara keseluruhan, analisis *Precision-Recall Curve* menunjukkan bahwa model YOLOv8 memiliki kemampuan deteksi yang sangat baik pada kedua dataset. Dataset publik memberikan performa yang lebih tinggi karena memiliki kualitas citra yang lebih seragam dan kondisi pengambilan gambar yang terkontrol. Sementara itu, hasil pada dataset lapangan menunjukkan bahwa model tetap mampu mempertahankan performa yang baik pada kondisi nyata, sehingga model memiliki kemampuan generalisasi yang baik dan layak digunakan untuk mendeteksi kualitas daging sapi di lingkungan lapangan.

4.7 Pembahasan dan Interpretasi Hasil

Pembahasan dan Interpretasi berfungsi untuk menginterpretasikan seluruh hasil penelitian secara menyeluruh. Pembahasan dilakukan berdasarkan hasil dataset, pra-pemrosesan, pelatihan, pengujian, evaluasi kinerja model, analisis kesalahan prediksi, serta perbandingan performa pada dataset publik dan dataset lapangan.

Tujuannya adalah untuk memberikan pemaknaan terhadap hasil yang telah diperoleh, bukan sekadar mengulang angka evaluasi. Dengan demikian, pada tahap ini menjelaskan apakah model YOLOv8 yang digunakan sudah mampu menjawab tujuan penelitian dan sejauh mana model dapat diterapkan dalam konteks deteksi kualitas daging sapi lokal Aceh berbasis citra digital.

4.7.1 Interpretasi Umum Hasil Penelitian

Berdasarkan hasil penelitian, model YOLOv8n mampu mendeteksi dan mengklasifikasikan kualitas daging sapi ke dalam dua kelas, yaitu *Fresh* dan *Rotten*. Model mampu menghasilkan *Bounding box*, label kelas, dan nilai *Confidence* pada citra uji. Hal ini menunjukkan bahwa model tidak hanya mampu melakukan klasifikasi, tetapi juga mampu menentukan lokasi objek dalam citra.

Dari hasil pelatihan, model menunjukkan proses pembelajaran yang cukup baik. Hal ini terlihat dari penurunan nilai *training loss* dan *validation loss* selama proses *training*. Penurunan loss menunjukkan bahwa model semakin mampu mempelajari pola visual dari dataset.

Hasil evaluasi menunjukkan bahwa model memperoleh *Precision* sebesar 94,67%, *Recall* sebesar 85,62%, *F1-score* sebesar 89,92%, *mAP@0.5* sebesar 88,40%, dan *mAP@0.5:0.95* sebesar 67,13%. Nilai tersebut menunjukkan bahwa model memiliki performa yang baik secara keseluruhan dalam mendeteksi kualitas daging sapi.

Namun demikian, hasil evaluasi juga menunjukkan adanya perbedaan performa antara kelas *Fresh* dan *Rotten*. Kelas *Fresh* memiliki performa yang lebih tinggi dibandingkan kelas *Rotten*. Hal ini menunjukkan bahwa karakteristik visual daging segar lebih mudah dikenali oleh model dibandingkan daging busuk.

4.7.2 Generalisasi Model terhadap Data Baru

Generalisasi model mengacu pada kemampuan model dalam mempertahankan performa ketika dihadapkan pada data baru yang tidak digunakan dalam proses *training*. Dalam penelitian ini, kemampuan generalisasi model diuji melalui penggunaan dataset lapangan yang memiliki kondisi lebih kompleks dibandingkan dataset publik.

Hasil penelitian menunjukkan bahwa model masih mampu mendeteksi objek pada dataset lapangan, meskipun *Confidence* dan performanya lebih bervariasi. Hal

ini menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik, tetapi belum sepenuhnya optimal.

Penurunan performa pada data lapangan dapat disebabkan oleh adanya perbedaan distribusi data antara dataset publik dan dataset lapangan. Dataset publik cenderung lebih terkontrol, sedangkan dataset lapangan memiliki kondisi pencahayaan, latar belakang, dan posisi objek yang lebih bervariasi.

Dengan demikian, model dapat dikatakan sudah memiliki kemampuan generalisasi dasar, tetapi masih memerlukan peningkatan agar lebih stabil dalam kondisi nyata. Peningkatan tersebut dapat dilakukan dengan menambah variasi dataset lapangan, memperbaiki kualitas anotasi, dan menggunakan ukuran citra yang lebih sesuai untuk menangkap detail objek.

4.7.3 Perbandingan dengan Penelitian Sebelumnya

Penelitian ini dilakukan untuk mengembangkan sistem deteksi kualitas daging sapi berbasis citra digital menggunakan algoritma YOLOv8. Berbeda dengan sebagian besar penelitian sebelumnya yang masih menggunakan metode klasifikasi citra seperti Convolutional Neural Network (CNN), VGG16, maupun AlexNet, penelitian ini menerapkan metode *object detection* sehingga sistem tidak hanya mampu mengklasifikasikan kualitas daging, tetapi juga mendeteksi lokasi objek secara langsung melalui *Bounding box*. Pendekatan ini memberikan informasi yang lebih lengkap dan memudahkan pengguna dalam mengidentifikasi objek yang terdeteksi.

Selain penggunaan metode YOLOv8, penelitian ini juga memiliki perbedaan pada dataset yang digunakan. Dataset penelitian merupakan gabungan antara dataset publik LOCBEEF dan dataset lapangan yang diperoleh dari pasar tradisional di Aceh. Penggunaan dataset gabungan tersebut memberikan variasi data yang lebih beragam dibandingkan penelitian sebelumnya yang umumnya hanya menggunakan satu sumber dataset atau citra dengan kondisi yang lebih terkontrol. Dengan demikian, model yang dihasilkan diharapkan memiliki kemampuan generalisasi yang lebih baik ketika digunakan pada kondisi nyata.

Tabel 4.15 menyajikan perbandingan penelitian ini dengan beberapa penelitian sebelumnya berdasarkan metode yang digunakan dan hasil utama yang diperoleh.

Tabel 4. 15 Perbandingan penelitian ini dengan penelitian sebelumnya

No	Peneliti	Metode	Hasil Utama
1	Elia & Darmawan (2022)	VGG16 (CNN)	Berhasil mengklasifikasikan kesegaran daging sapi menggunakan citra digital.
2	Ekamila dkk. (2023)	CNN	Mengembangkan aplikasi mobile untuk klasifikasi kesegaran daging sapi.
3	Malikhah dkk. (2025)	AlexNet & VGG16	VGG16 memberikan performa klasifikasi yang lebih baik dibandingkan AlexNet.
4	Pasya & Fachrie (2025)	YOLOv8	Berhasil mendeteksi kesegaran daging ayam secara <i>real-time</i> menggunakan YOLOv8.
5	Penelitian ini (2026)	YOLOv8	Precision 94,67%, Recall 85,62%, <i>mAP@0.5</i> 88,40%, serta mampu melakukan <i>object detection</i> kualitas daging sapi menggunakan dataset publik dan dataset lapangan.

Berdasarkan Tabel 4.15, dapat disimpulkan bahwa penelitian ini memiliki beberapa keunggulan dibandingkan penelitian sebelumnya. Selain menggunakan algoritma YOLOv8 yang mampu melakukan *object detection* secara *real-time*, penelitian ini juga memanfaatkan kombinasi dataset publik LOCBEEF dan dataset lapangan sehingga model dilatih menggunakan data yang lebih beragam. Hasil evaluasi menunjukkan nilai Precision sebesar 94,67%, Recall sebesar 85,62%, dan *mAP@0.5* sebesar 88,40%, yang menunjukkan bahwa model mampu mendeteksi kualitas daging sapi dengan performa yang baik. Dengan demikian, sistem yang dikembangkan tidak hanya menghasilkan klasifikasi kualitas daging, tetapi juga memberikan informasi lokasi objek melalui *Bounding box*, sehingga lebih aplikatif untuk diimplementasikan pada aplikasi berbasis web dalam proses inspeksi kualitas daging sapi.

4.7.4 Keterbatasan Penelitian

1. Keterbatasan Pertama adalah variasi dataset lapangan yang masih dapat ditingkatkan. Meskipun dataset lapangan sudah merepresentasikan kondisi

nyata, jumlah dan variasinya masih dapat diperluas agar model lebih kuat dalam menghadapi berbagai kondisi pasar.

2. Keterbatasan kedua berkaitan dengan kelas *Rotten*. Hasil evaluasi menunjukkan bahwa kelas *Rotten* memiliki performa lebih rendah dibandingkan kelas *Fresh*. Hal ini menunjukkan bahwa model membutuhkan lebih banyak variasi data busuk dengan kondisi visual yang berbeda-beda.
3. Keterbatasan ketiga adalah kemungkinan kesalahan pada *background*. Pada beberapa citra, *background* dapat terdeteksi sebagai objek daging, terutama ketika memiliki warna atau tekstur menyerupai daging. Hal ini menunjukkan bahwa anotasi dan variasi data latar belakang masih perlu diperbaiki.

4.7.5 Implikasi Penelitian

Hasil penelitian ini memiliki implikasi dalam bidang pengolahan citra digital dan keamanan pangan. Dari sisi akademik, penelitian ini menunjukkan bahwa YOLOv8 dapat digunakan untuk mendeteksi kualitas daging sapi berbasis citra digital. Model tidak hanya mampu memberikan label kelas, tetapi juga mampu menunjukkan lokasi objek melalui *Bounding box*.

Dari sisi praktis, penelitian ini dapat menjadi dasar pengembangan sistem deteksi kualitas daging secara otomatis. Sistem seperti ini berpotensi membantu pedagang, konsumen, maupun petugas pengawas pangan dalam melakukan identifikasi kualitas daging secara lebih cepat dan objektif.

Namun, sebelum diterapkan secara langsung di lapangan, model masih perlu dikembangkan lebih lanjut. Peningkatan dapat dilakukan dengan memperbesar variasi dataset, menggunakan resolusi citra yang lebih tinggi, memperbaiki kualitas anotasi, dan melakukan pengujian pada lebih banyak kondisi pasar.

Berdasarkan keseluruhan hasil pembahasan, model YOLOv8 mampu digunakan untuk mendeteksi kualitas daging sapi lokal Aceh berbasis citra digital. Model dapat menghasilkan *Bounding box*, label kelas, dan nilai *Confidence score* untuk membedakan daging *Fresh* dan *Rotten*. Hasil evaluasi menunjukkan bahwa model memiliki performa yang baik, meskipun masih terdapat beberapa keterbatasan pada kelas *Rotten*, kondisi citra lapangan, dan latar belakang yang

kompleks. Dengan demikian, penelitian ini menunjukkan bahwa YOLOv8 berpotensi digunakan sebagai dasar pengembangan sistem deteksi kualitas daging secara otomatis.



BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai deteksi kualitas daging sapi lokal Aceh menggunakan YOLOv8 berbasis citra digital, dapat ditarik kesimpulan sebagai berikut:

1. Pembangunan dataset gabungan

Dataset gabungan dalam penelitian ini berhasil dibangun dengan mengombinasikan dataset publik LOCBEEF dan dataset lapangan hasil pengambilan foto langsung di pasar tradisional Aceh. Dataset publik memberikan citra dengan kondisi pencahayaan dan latar belakang yang lebih terkontrol, sedangkan dataset lapangan memberikan variasi visual yang lebih realistis (pencahayaan alami, sudut pengambilan gambar, dan latar belakang yang beragam). Kedua sumber data melalui tahap anotasi menggunakan Roboflow, pembagian data, dan augmentasi, sehingga menghasilkan dataset gabungan yang lebih representatif terhadap kondisi nyata di lapangan dibandingkan jika hanya menggunakan satu sumber data saja.

2. Perancangan sistem deteksi dan klasifikasi

Sistem deteksi dan klasifikasi kualitas daging sapi berhasil dirancang menggunakan metode YOLOv8 berbasis citra digital, melalui tahapan pengumpulan dataset, anotasi, pembagian data, augmentasi, pelatihan model, pengujian, hingga evaluasi kinerja. Model yang dihasilkan mampu mendeteksi objek daging melalui *Bounding box* serta memberikan label kelas *Fresh* dan *Rotten* disertai nilai *Confidence score*, sehingga sistem ini dapat digunakan sebagai alat bantu deteksi kualitas daging berbasis citra digital.

3. Performa model YOLOv8

Performa model YOLOv8 dalam membedakan daging *Fresh* dan *Rotten* pada dataset gabungan menunjukkan hasil yang baik, dengan nilai *Precision* sebesar 94,67%, *Recall* sebesar 85,62%, *F1-score* sebesar 89,92%,

$mAP@0.5$ sebesar 88,40%, dan $mAP@0.5:0.95$ sebesar 67,13%. Namun, kelas *Rotten* masih lebih sulit dikenali dibandingkan kelas *Fresh* karena variasi warna, tekstur, dan kondisi visual yang lebih kompleks. Dari sisi sumber data, dataset publik menghasilkan *Precision* lebih tinggi (92,72%) karena kondisi citranya lebih terkontrol, sedangkan dataset lapangan menghasilkan *Recall* lebih tinggi (87,72%) meskipun *Precision*-nya lebih rendah (72,47%), yang menunjukkan model mampu mendeteksi lebih banyak objek pada kondisi nyata namun dengan risiko kesalahan prediksi yang lebih besar.

Secara keseluruhan, penelitian ini membuktikan bahwa YOLOv8 dapat diterapkan secara efektif untuk mendeteksi kualitas daging sapi lokal Aceh berbasis citra digital, meskipun masih memerlukan peningkatan pada variasi dataset lapangan, kualitas anotasi, serta kemampuan model dalam mengenali kelas *Rotten* dan objek dengan latar belakang kompleks.

5.2 Saran

Berdasarkan kesimpulan di atas, beberapa saran yang dapat diberikan untuk pengembangan penelitian selanjutnya adalah:

1. Penambahan variasi dataset lapangan. Jumlah dan variasi dataset lapangan perlu ditambah, mencakup berbagai lokasi, waktu, kondisi pencahayaan, sudut pengambilan gambar, dan latar belakang, agar model lebih mampu mengenali kondisi nyata yang beragam.
2. Penyeimbangan data kelas *Rotten*. Data pada kelas *Rotten* perlu diperbanyak karena memiliki variasi visual yang lebih kompleks dibandingkan kelas *Fresh*. Penambahan variasi data daging busuk diharapkan dapat meningkatkan konsistensi model dalam mengenali kelas tersebut.
3. Peningkatan kualitas anotasi. Proses anotasi perlu dilakukan dengan lebih teliti dan konsisten agar *Bounding box* benar-benar mencakup area objek daging secara tepat, sehingga mengurangi kesalahan deteksi terhadap *background*.
4. Eksplorasi varian model yang lebih besar. Penelitian selanjutnya dapat mencoba varian YOLOv8 yang lebih besar, seperti YOLOv8s atau

YOLOv8m, untuk membandingkan performa dan menentukan model paling optimal.

5. Pengembangan menjadi aplikasi terapan. Sistem deteksi dapat dikembangkan menjadi aplikasi berbasis web atau mobile agar dapat digunakan secara langsung oleh konsumen, pedagang, atau petugas pengawas pangan sebagai alat bantu menilai kualitas daging secara cepat dan objektif.



DAFTAR PUSTAKA


- Aceh, B. P. S. (2024). *Provinsi Aceh Dalam Angka 2024*. Badan Pusat Statistik Provinsi Aceh.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2023). Understanding of a Convolutional Neural Network. In *international Conference on Engineering and Technology (ICET)*.
- Dharma, T. M., Adriman, R., & Saddami, K. (2022). *LOCBEEF: BEEF quality image dataset for Deep Learning models (Version 1) [Data set]*.
- Gonzalez, R. C., & Woods, R. E. (2024). *Digital Image Processing, Fourth Edition*. Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2021). *Deep Learning*. MIT Press.
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLO Documentation*. Ultralytics.
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLO [Computer software]*. Ultralytics.
- Organization, F. and A. (2022). *Meat Processing Technology for Small- to Medium-Scale Producers*. FAO.
- Organization, W. H. (2023). *Food Safety*. World Health Organization.
- Padilla, R., Netto, S. L., & Silva, E. A. B. (2021). *A Survey on Performance Metrics for Object-Detection Algorithms*.
- Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., & da Silva, E. A. B. (2021). A Comparative Analysis of Object detection Metrics with a Companion Open-Source Toolkit. *Electronics*, 10(3).
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., & Chanan, G. (2022). PyTorch: An Imperative Style, High-Performance Deep Learning Library. *Advances in Neural Information Processing Systems*, 32.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2020). *You Only Look Once : Unified , Real-Time Object Detection*.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2020). You Only Look Once: Unified, Real-time Object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Roboflow. (2026). *Roboflow documentation*. Roboflow.
- Sena, S. (2022). *Pengenalan Deep Learning Part 7: Convolutional Neural Network (CNN)*.

- Shorten, C., & Khoshgoftaar, T. M. (2020). A Survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(60).
- Soeparno. (2021). *Ilmu dan Teknologi Daging*. Gadjah Mada University Press.
- Statistik, B. P. (2024). *Statistik Indonesia 2024*. Badan Pusat Statistik.
- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications. Second Edition*. Springer.
- Terven, J., & Cordova-Esparza, D. M. (2023a). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*, 5(4).
- Terven, J., & Cordova-Esparza, D. M. (2023b). *Detailed Architecture of YOLOv8 Showcasing the Backbone Network's Multiple Convolutional Layers*. ResearchGate.





LAMPIRAN

1. Lampiran 1. Grafik dan Kurva Hasil Pelatihan Model Dataset Gabungan




2. Lampiran 2. Grafik dan Kurva Hasil Pelatihan Model Dataset Publik










3. Lampiran 3. Grafik dan Kurva Hasil Pelatihan Model Dataset Lapangan




4. Lampiran 4. *Confusion Matrix* dan Hasil Pengujian Visual Prediksi Model (*Bounding box*) Dataset Gabungan






5. Lampiran 5. *Confusion Matrix* dan Hasil Pengujian Visual Prediksi Model (*Bounding box*) Dataset Publik





6. Lampiran 6. *Confusion Matrix* dan Hasil Pengujian Visual Prediksi Model (*Bounding box* Dataset Lapangan)



7. Lampiran 7. *Source Code* YOLOv8 (Kode Program)

```

# Install ultralytics
!pip install ultralytics
import ultralytics
ultralytics.checks()

# System Information
print('System Information:')
print('-----')
print(f'OS: {os.name} {os.version} {os.release} {os.arch}')
print(f'Python: {sys.version}')
print(f'PyTorch: {torch.__version__}')
print(f'Ultralytics: {ultralytics.__version__}')
print(f'CUDA: {torch.cuda.get_device_name(0)} {torch.cuda.get_device_capability(0)}')
print(f'GPU: {torch.cuda.get_device_name(0)} {torch.cuda.get_device_count(0)}')
print(f'CPU: {os.cpu_count()} {os.cpu_count() * 1000 / 1024} GB')
print(f'RAM: {psutil.virtual_memory().total / 1024 / 1024} GB')
print(f'Disk: {psutil.disk_usage('/').total / 1024 / 1024} GB')
print('-----')

```



```

downloading https://s3.amazonaws.com/amazon-ml-models/jar/easy/conda/conda-1.0.0-ubuntu16.04 to yolov3m.pt | 100% | 4.7MB 12.7MB/s 0.4s
INFO: checks passed
train: fast image access (img: 0.4mb/0.4m, read: 1739.02880/5 MB/s, size: 40.5 KB)
train: Scanning /content/dataset/train/labels... 2372 images, 20 backgrounds, 0 corrupt: 100% | 2172/2172 2.161r/s 1.8s
train: New cache created: /content/dataset/train/labels.cache
Observations: Elapsed: 0.4s, blur_limit(s, 7)), NetModule(0.4s, blur_limit(s, 7)), totary(p=0.01, method='weighted_average', num_output_channels), class(p=0.01, clip_limit(s=1.0, 4.0), tile_grid_size(s, 0))
val: fast image access (img: 0.4mb/0.4m, read: 625.95480/5 MB/s, size: 43.9 KB)
val: Scanning /content/dataset/val/labels... 233 images, 3 backgrounds, 0 corrupt: 100% | 233/233 1.061r/s 0.2s
val: New cache created: /content/dataset/val/labels.cache
optimizer: 'optimizer=adam' found, ignoring 'lr=0.01' and 'momentum=0.9' and determining best 'optimizer', 'lr' and 'momentum' automatically...
optimizer: AdamW(lr=0.0001, momentum=0.9) with parameter groups 52 weight(decay=0.0), 44 bias(decay=0.0)
Flattening labels to /content/runs/detect/yolov3_dataset_run/labels.jpg...
Image size 640 train, 640 val
Using 2 dataloader workers
Logging results to /content/runs/detect/yolov3_dataset_run
Starting training for 100 epochs...

Epoch   GPU mem   box_loss   cls_loss   dfl_loss   Instances   Size
1/100    25        1.290      2.112      1.390      17          640/1005 136/136 3.511r/s 38.6s

Report shuttl
# Unzip folder hasil training menjadi zip
shutil.make_archive('/content/hasil_training', 'zip', '/content/runs/detect/yolov3_dataset_run')
# Upload file zip ke Google Drive
shutil.copy('/content/hasil_training.zip', '/content/drive/MyDrive/hasil_training_yolov3_1.zip')
print("Folder hasil training berhasil di zip dan diupload ke Drive!")
Folder hasil training berhasil di zip dan diupload ke Drive!

```

