

**EVALUASI ALGORITMA YOLOv8 DAN YOLOv11 DALAM
KLASIFIKASI OTOMATIS TINGKAT KEMATANGAN TANDAN BUAH
SEGAR KELAPA SAWIT**

Skripsi

Oleh :

BELLA AMELIA

NPM. 2115031025



JURUSAN TEKNIK ELEKTRO

FAKULTAS TEKNIK

UNIVERSITAS LAMPUNG

2024

**EVALUASI ALGORITMA YOLOv8 DAN YOLOv11 DALAM
KLASIFIKASI OTOMATIS TINGKAT KEMATANGAN TANDAN BUAH
SEGAR KELAPA SAWIT**

Oleh :

BELLA AMELIA

NPM. 2115031025

SKRIPSI

**Sebagai Salah Satu Syarat Untuk Mencapai Gelar Sarjana Teknik Pada
Jurusan Teknik Elektro Fakultas Teknik Universitas Lampung**



JURUSAN TEKNIK ELEKTRO

FAKULTAS TEKNIK

UNIVERSITAS LAMPUNG

2024

ABSTRAK

EVALUASI ALGORITMA YOLOV8 DAN YOLOV11 DALAM KLASIFIKASI OTOMATIS TINGKAT KEMATANGAN TANDAN BUAH SEGAR KELAPA SAWIT

Oleh

Bella Amelia

Tingkat kematangan tandan buah segar (TBS) menentukan rendemen, asam lemak bebas (ALB), dan stabilitas mutu minyak sawit. Ketidaktepatan panen menimbulkan kerugian nilai dan inefisiensi proses. Penilaian manual terhadap tandan sawit yang akan dipanen masih bersifat subjektif, dipengaruhi pencahayaan, oklusi pelepah, serta variabilitas varietas dan lokasi kebun. Karena itu, algoritma *computer vision* berbasis *one-stage detector* menawarkan otomasi yang konsisten dan cepat untuk operasional berskala besar. Penelitian ini mengkaji kelayakan dua *backbone computer vision* yaitu YOLOv8 dan YOLOv11, untuk klasifikasi otomatis tingkat kematangan TBS, sekaligus mengevaluasi ketahanan lintas domain data. Eksperimen dilakukan pada dua himpunan data yaitu data *image* dari Roboflow (8.400 citra teranotasi kualitas dan anotasi tertata) dan *dataset* lapangan (625 citra hasil augmentasi) yang merepresentasikan variasi kondisi nyata. Evaluasi model mencakup *precision*, *recall*, F1-score, *mean Average Precision* (mAP), akurasi, serta kecepatan inferensi (FPS). Uji keadilan ukuran sampel dilakukan dengan menyetarakan jumlah data (625 citra) antara subset Roboflow dan *dataset* lapangan. Hasil menunjukkan YOLOv8 lebih stabil dan seimbang di beragam skenario. Pada Roboflow, YOLOv8s menjadi pilihan utama dengan akurasi 87,8%, *precision* (90,5%), *recall* (90,8%), F1-score 90,7%, mAP 94,8%, dan kecepatan 1.123 FPS. Keunggulan Roboflow ada pada volume besar, kualitas gambar yang lebih baik, dan anotasi rapi. Saat jumlah data disetarakan menjadi 625 citra, subset Roboflow tetap unggul pada mAP (95,2%) dan *precision* (94,3%), sementara *dataset* lapangan lebih baik pada *recall* (87,6%), akurasi (78,1%), dan kecepatan (1.079 FPS), menandakan adaptasi model terhadap kondisi kebun yang beragam. Kelebihan spesifik turut teridentifikasi: YOLOv8m unggul pada *precision* dan mAP di subset Roboflow, namun nilai *recall* tinggi untuk *dataset* lapangan; dilain pihak, YOLOv11s menonjol pada *recall* dan mAP untuk *dataset* lapangan meski konsistensinya lebih rendah. Secara keseluruhan, YOLOv8s direkomendasikan untuk implementasi praktis karena konsistensi dan keseimbangan kinerja, sementara YOLOv8m atau YOLOv11s layak dipilih bila prioritasnya presisi maksimum atau cakupan deteksi dalam kondisi tertentu.

Kata kunci: Kelapa Sawit, Klasifikasi, YOLOv8, YOLOv11, Deep Learning

ABSTRACT

EVALUATION OF YOLOV8 AND YOLOV11 ALGORITHMS IN AUTOMATIC CLASSIFICATION OF RUITNESS LEVEL OF FRESH OIL PALM FRUIT BUNCHES

By

Bella Amaelia

Fresh fruit bunch (FFB) ripeness strongly determines palm-oil yield, free-fatty-acid formation, and product stability; misgrading at harvest depresses value and propagates inefficiencies downstream. Manual inspection is inherently subjective and sensitive to lighting, frond occlusion, and cultivar/site variability. Consequently, computer vision based on one-stage detectors provides consistent, high-throughput automation for estate-scale operations. This study assesses two state-of-the-art backbones i.e., YOLOv8 and YOLOv11, for automatic FFB ripeness classification and examines cross-domain robustness. This study evaluate two datasets: Roboflow (8,400 annotated images with high visual quality and curated labels) and a field dataset (625 augmented images) representing real-world variability. Metrics include precision, recall, F1-score, mean Average Precision (mAP), accuracy, and inference speed (FPS). A fair-size test is conducted by equalizing sample counts (625 images) between a Roboflow subset and the field dataset. Results indicate that YOLOv8 delivers more stable, balanced performance across scenarios. On Roboflow, YOLOv8s emerges as the primary choice, achieving 87.8% accuracy, 90.7% F1-score, 94.8% mAP, and 1,123 FPS. The advantages of Roboflow, large volume, higher image quality, and clean annotations, resulted into strong precision (90.5%), recall (90.8%), and mAP (94.8%) for YOLOv8s. When data volume is equalized to 625 images, the Roboflow subset still leads in mAP (95.2%) and precision (94.3%), whereas the field dataset yields higher recall (87.6%), accuracy (78.1%), and speed (1,079 FPS), indicating model adaptability to diverse on-farm conditions. Model-specific strengths also emerge: YOLOv8m excels in precision and mAP on the Roboflow subset and delivers high recall in the field dataset, while YOLOv11s stands out for recall and mAP in field dataset tests despite lower overall consistency. Overall, YOLOv8s is recommended for practical deployment due to its consistent, well-balanced performance, whereas YOLOv8m or YOLOv11s are viable when the priority is maximum precision or broader detection coverage under specific operating conditions.

Keywords: Oil Palm, Classification, YOLOv8, YOLOv11, Deep Learning

Judul Skripsi

: EVALUASI ALGORITMA YOLOv8 DAN
YOLOv11 DALAM KLASIFIKASI OTOMATIS
TINGKAT KEMATANGAN TANDAN BUAH
SEGAR KELAPA SAWIT

Nama Mahasiswa

: *Bella Amelia*

Nomor Pokok Mahasiswa : 2115031025

Jurusan

: Teknik Elektro

Fakultas

: Teknik



[Signature]
Ing. Melvi, S.T., M.T., Ph.D.
NIP. 197301182000032001

[Signature]
Aryanto, S.T., M.T.
NIP.199006212019031011

2. Mengetahui

Ketua Jurusan Teknik Elektro

Ketua Program Studi Teknik Elektro

[Signature]
Herlinawati, S.T., M.T.
NIP. 197103141999032001

[Signature]
Sumadi, S.T., M.T.
NIP. 197311042000031001

MENGESAHKAN

1. Tim Penguji


Ketua : Ing. Ardian Ulvan, S.T., M.Sc., Ph.D.



Sekretaris : Aryanto, S.T., M.T.



Penguji : Ing. Melvi, S.T., M.T., Ph.D.



2. Dekan Fakultas Teknik



Dr. Eng. Ir. Helmy Fitriawan, S.T., M.Sc.)
NIP. 197509282001121002

Tanggal Lulus Ujian Skripsi: 30 Juli 2025

SURAT PERNYATAAN

Yang bertanda tangan dibawah ini:

Nama : Bella Amelia

NPM : 2115031025

Dengan ini saya menyatakan bahwa skripsi saya yang berjudul “ Evaluasi Algoritma YOLOv8 Dan YOLOv11 Dalam Klasifikasi Otomatis Tingkat Kematangan Tandan Buah Segar Kelapa Sawit ” merupakan asli penelitian saya.

Pada skripsi ini tidak terdapat karya yang pernah dilakukan orang lain dan sepengetahuan saya tidak terdapat atau diterbitkan oleh orang lain, kecuali secara tertulis diacu dalam naskah ini sebagaimana yang disebutkan dalam daftar Pustaka.

Selain itu, saya menyatakan bahwa skripsi ini dibuat oleh saya sendiri.

Apabila pernyataan saya tidak benar, maka saya bersedia dikenai sanksi sesuai dengan hukum yang berlaku.

Bandar Lampung, 25 Agustus 2025

Penulis



Bella Amelia
2115031025

RIWAYAT HIDUP



Penulis dilahirkan di Bengkulu pada tanggal 19 Agustus 2003. Penulis merupakan anak keempat dari empat bersaudara, dari pasangan Bapak Muslim dan Ibu Rumsiah. Pendidikan sekolah dasar diselesaikan di SDN 1 Kutoarjo tahun 2015. Sekolah menengah pertama di SMPN 1 Pesawaran dan lulus tahun 2018, serta sekolah menengah atas di SMAN 1 Gedong Tataan dengan mengambil jurusan Ilmu Pengetahuan Alam (IPA) yang diselesaikan tahun 2021. Pada tahun yang sama, penulis diterima sebagai mahasiswa di Jurusan Teknik Elektro, Fakultas Teknik, Universitas Lampung melalui jalur SNMPTN. Selama perkuliahan, penulis aktif di Himpunan Mahasiswa Teknik Elektro Universitas Lampung (HIMATRO UNILA) sebagai Anggota Departemen Pengembang Keteknikan Divisi Penelitian dan Pengembangan pada tahun 2021 sampai 2022. Selain itu, penulis juga mengembangkan potensi diri melalui berbagai lomba bertim. Pada 2022, penulis meraih Juara 2 International Conference on Science, Infrastructure Technology and Regional Development (ICoSITeR) serta menjadi finalis 20 besar PLN ICE. Tahun 2023, penulis menjadi finalis Lomba Inovasi Digital Mahasiswa (LIDM), dan pada 2024 lolos sebagai finalis 40 besar Lomba Riset Sawit tingkat nasional. Sebagai bentuk implementasi Merdeka Belajar Kampus Merdeka (MBKM), penulis mengikuti Studi Independen Internet of Things (IoT) Engineer Camp di PT Ozami Inti Sinergi (Indobot Academy) dari 16 Februari sampai 30 Juni 2024 dengan menyusun proyek akhir berjudul FERMENTECH – Biotech Sensing, yaitu alat untuk mempercepat fermentasi tempe. Melalui pengalaman tersebut, penulis mengembangkan keterampilan di bidang IoT, penelitian, dan inovasi teknologi, serta meningkatkan kemampuan komunikasi dan kerja sama tim.

PERSEMBAHAN

Dengan Ridho Allah SWT dan Dengan penuh rasa syukur kepada Allah SWT

Teriring shalawat kepada Nabi Muhammad SAW

Kupersembahkan Skripsi ini sebagai tanda terimakasih kepada:

Ayah dan Ibuku Tersayang

MUSLIM dan RUMSIAH

Serta Kakak-Kakak ku Tersayang

Alm. Doni Saputra

Raden Nurhadiansyah

Ibrahim, S.Kom

Keluarga besar, Dosen, Teman, Serta Almamater yang telah menjadi motivasi dan inspirasi, terima kasih atas kekeluargaan, do'a, serta dukungan yang selalu mengiringi hingga merasa lebih baik dari hari ke hari.

Terimakasih untuk segala Tulus Kasih, Semangat, dan Dukungan dalam segala hal selama ini, sehingga penulis dapat menyelesaikan masa kuliah ini.

Terimakasih untuk diri saya sendiri Bella Amelia

MOTTO

Allah tidak pernah membebani seseorang melainkan

Sesuai dengan kesanggupannya

(Qs. Al-Baqarah:286)

Maka sesungguhnya bersama kesulitan ada kemudahan. Sesungguhnya bersama kesulitan ada kemudahan

(Qs. Al-Insyirah:5-6)

Dan bersabarlah kamu sesungguhnya janji Allah adalah benar

(Qs. Ar-Ruum:60)

Takdir tidak pernah salah Alamat, Setiap orang ditakdirkan dengan waktu yang berbeda. maka Jangan lah takut terlambat, karena setiap orang punya garis waktunya sendiri, tugas kita hanyalah berusaha sebaik mungkin dan percaya bahwa Allah selalu menyiapkan hasil terbaik di saat yang tepat. Sebab semua sudah ada takdir dan rezekinya masing-masing, jadi jangan pernah takut merasa terlambat.

SEWACANA

Puji Syukur penulis panjatkan kepada Tuhan Yang Maha Esa berkat Rahmat dan hidayah-Nya penulis dapat menyelesaikan skripsi yang berjudul “Evaluasi Algoritma YOLOv8 Dan YOLOv11 Dalam Klasifikasi Otomatis Tingkat Kematangan Tandan Buah Sawit”. Penulis menyadari bahwa penulisan laporan skripsi ini dapat diselesaikan atas bantuan dari berbagai pihak, oleh karena itu, penulis ingin mengucapkan terimakasih kepada:

1. Allah Subhanahu Wa Ta’ala yang telah memberikan kelancaran serta kesehatan sehingga mampu menyelesaikan laporan hasil ini.
2. Kedua orang tua penulis, kepada cinta pertama penulis Ayah tercinta Bapak Muslim dan pintu surga penulis Ibu tercinta Ibu Rumsiah. Terima kasih atas setiap kerja keras, pengorbanan, serta dukungan yang tiada henti diberikan kepada penulis selama menempuh perkuliahan ini. Segala kasih sayang, semangat, motivasi, dan nasihat yang Ayah dan Ibu berikan menjadi kekuatan besar bagi penulis. Serta dukungan baik moril maupun materiil yang tak terhingga untuk penulis terima kasih sudah selalu mengusahakan nya. Dan terima kasih pula atas doa yang selalu dipanjatkan dalam setiap langkah dan proses kehidupan penulis.
3. Kakak-Kakak penulis, alm bang doni, Bang aden, mba ipar ku mba uci, Aa, dan keponakan ku tersayang kakak bani. Terima kasih atas kasih sayang yang diberikan kepada penulis. Terimakasih atas doa doa baik yang selalu di panjatkan. Terima kasih selalu ada dan selalu mendukung adek bungsu kalian dalam keadaan apapun itu, selalu mendengarkan keluh kesah penulis, selalu di repotkan penulis selama perkuliahan dan dalam menjalankan dan menyelesaikan skripsi ini.
4. Ibu Prof. Dr. Ir Lusmeilia Afriani, D.E.A., I.P.M. Selaku Rektor Universitas Lampung.

5. Bapak Dr. Eng. Helmy Fitriawan, S.T., M.Sc. Selaku Dekan Fakultas Teknik Universitas Lampung.
6. Ibu Herlinawati, S.T.,M.T. Sebagai Ketua Jurusan Teknik Elektro Universitas Lampung.
7. Bapak Sumadi, S.T., M.T. Sebagai Ketua Program Studi Teknik Elektro Universitas Lampung.
8. Ibu Ing. Melvi, S.T., M.T. Ph.D Sebagai Dosen Pembimbing Utama dalam penyusunan laporan hasil ini.
9. Bapak Aryanto, S.T., M.T. Sebagai Dosen Pembimbing Pendamping.
10. Bapak DR.ENG. Lukmanul Hakim, S.T., M.SC. Selaku dosen Pembimbing Akademik.
11. Dinda Armeylia Putri sebagai rekan penulis dalam pengerjaan skripsi ini terima kasih sudah selalu ada dan selalu membersamai setiap proses dan Langkah dalam perkuliah ini. sebagai tempat saling bertukar pendapat, ilmu dan diskusi mulai dari awal penelitian hingga akhir penelitian dan juga selalu sedia membantu penulis dalam hal apapun serta meminjamkan laptop.
12. Siti Rahmawati yang selalu menemani, membantu, meminjamkan laptop, mendengarkan keluh kesah penulis dan selalu memberikan dukungan kepada penulis selama penyelesaian skripsi ini.
13. Tiara Khairunnisa yang selalu membantu penulis dalam mengerjakan skripsi ini dan mendengarkan keluh kesah penulis
14. Anindyaputri Rhamadani yang selalu ada mendengarkan keluh kesah penulis dan selalu membantu dan direpotkan penulis untuk meminjam laptop
15. Semua pihak yang telah terlibat yang membantu penulis dalam menyelesaikan skripsi ini yang tidak dapat penulis sebutkan satu persatu
16. Last but not least untuk diri saya sendiri, Terimakasih sudah berjuang dan berusaha sejauh ini, bertahan sejauh dan sekuat ini kamu keren sekali. Semoga hal hal baik selalu mengiringi Langkah kita ke depan.

Penulis menyadari bahwa laporan skripsi ini masih memiliki kekurangan dari segi penyusunan maupun pemilihan kata. Oleh karena itu penulis memohon saran dan kritik membangun sebagai evaluasi laporan ini. Terima kasih.

Bandar Lampung, 2025

Penulis

Bella Amelia
2115031025

DAFTAR ISI

	Halaman
ABSTRAK	iii
ABSTRACT	iv
HALAMAN PERSETUJUN	v
HALAMAN MENGESAHKAN	vi
SURAT PERNYATAAN	vii
RIWAYAT HIDUP	viii
PERSEMBAHAN.....	ix
MOTTO	x
SEWACANA	xi
DAFTAR ISI.....	xiv
DAFTAR GAMBAR.....	xvii
DAFTAR TABEL	xix
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Tujuan Penelitian.....	2
1.3 Rumusan Masalah	3
1.4 Batasan Masalah.....	3
1.5 Manfaat Penelitian.....	4
1.6 Sistematika Penulisan.....	4

BAB II TINJAUAN PUSTAKA.....	6
2.1 Penelitian Terkait	6
2.2 Karakteristik Kelapa Sawit.....	7
2.3 Kematangan Buah Sawit	7
2.4 Klasifikasi Objek.....	8
2.5 <i>You Only Look Once</i> (YOLO).....	10
2.6 Teknologi Deteksi Objek dengan YOLO.....	15
2.7 Aplikasi YOLO dalam sektor pertanian	16
2.8 YOLOv8.....	17
2.9 YOLOv11	19
2.10 Perbandingan YOLOv8 dan YOLOv11	22
2.11 Data Preparation	23
2.12 Implementasi Model.....	26
2.13 AI Project Cycle	26
2.14 <i>Mean Average Precision</i> (mAP)	28
2.15 <i>Precision</i>	29
2.16 <i>Recall</i>	30
2.17 F-Measure.....	31
2.18 <i>Accuracy</i>	32
2.19 Python.....	32
2.20 <i>Google Colaboratory</i>	33
2.21 <i>Roboflow</i>	34
BAB 3 METODE PENELITIAN.....	37
3.1 Waktu dan Tempat Penelitian	37
3.3 Prosedur Penelitian.....	37
3.4 <i>Dataset</i> Penelitian.....	38

3.5 Perancangan program	39
BAB 4 HASIL DAN PEMBAHASAN	47
4.1 <i>Dataset</i>	47
4.2 Deteksi object dengan algoritma YOLO	48
4.3 Evaluasi dan Hasil Kinerja YOLO	57
4.4 Analisis hasil Pembahasan dan pengujian	62
BAB 5 KESIMPULAN DAN SARAN	64
5.1 Kesimpulan	64
5.2 Saran	65
DAFTAR PUSTAKA	66
LAMPIRAN	70

DAFTAR GAMBAR

	Halaman
Gambar 2. 1 Klasifikasi Objek pada Buah sawit	9
Gambar 2. 2 Arsitektur YOLO	11
Gambar 2. 3 Sistem Deteksi YOLO.....	13
Gambar 2. 4 komponen Bounding box	13
Gambar 2. 5 Alur Kerja algoritma YOLO dalam pendeteksi objek pada citra.....	15
Gambar 2. 6 Arsitektur YOLOv8	18
Gambar 2. 7 Arsitektur YOLOv11	20
Gambar 2. 8 Tingkat Kematangan Buah sawit	24
Gambar 2. 9 Label txt.....	25
Gambar 2. 10 AI Project Cycle	26
Gambar 2. 11 Google Colaboratory	33
Gambar 3. 1 Berbagai tingkat kematangan tandan buah kelapa sawit.....	39
Gambar 3. 2 Diagram Alir AI Project cycle untuk metode YOLOv8 dan YOLOv11	40
Gambar 3. 3 Diagram alir data exploration.....	42
Gambar 3. 4 Labeling Object	42
Gambar 3. 5 Rincian preprocessing dan augmentasi data	43
Gambar 3. 6 Alur proses tahap modeling.....	44
Gambar 3. 7 confusion matrix.....	45
Gambar 4. 1 Proses <i>preprocessing</i> dan <i>augmentations</i> dengan <i>dataset</i> 8400 gambar	49
Gambar 4. 2 Proses <i>preprocessing</i> dan <i>augmentations</i> dengan <i>dataset</i> 625 gambar	50
Gambar 4. 3 instalasi GPU.....	52

Gambar 4. 4 Instalasi Ultralytics dan yolo.....	53
Gambar 4. 5 Mount Google Drive dan Buat Struktur Direktori	53
Gambar 4. 6 konfigurasi pelatihan	53
Gambar 4. 7 Download dataset dari roboflow	54
Gambar 4. 8 Proses Training.....	55
Gambar 4. 9 output hasil pelatihan YOLO	55
Gambar 4. 10 proses evaluasi model.....	56
Gambar 4. 11 Predict Gambar baru.....	57

DAFTAR TABEL

	Halaman
Tabel 3. 1 Problem Scoping	41
Tabel 4. 1 Hasil Evaluasi YOLOv8 dengan dataset roboflow sebanyak 8400 gambar	58
Tabel 4. 2 Hasil Evaluasi YOLOv8 dengan subset dataset roboflow sebanyak 625 gambar.....	58
Tabel 4. 3 Hasil evaluasi YOLOv8 dengan dataset lapangan atau perkebunan sebanyak 625 gambar.....	59
Tabel 4. 4 Hasil Evaluasi YOLOv11 dengan dataset roboflow sebanyak 8400 gambar.....	60
Tabel 4. 5 Hasil Evaluasi YOLOv11 dengan subset dataset roboflow sebanyak 625 gambar.....	61
Tabel 4. 6 Hasil Evaluasi YOLOv11 dengan dataset perkebunan sebanyak 625 gambar.....	61

BAB 1 PENDAHULUAN

1.1 Latar Belakang

Tandan Buah Segar (TBS) kelapa sawit merupakan faktor kunci yang menentukan kualitas *Crude Palm Oil* (CPO) yang dihasilkan. Kematangan TBS yang optimal berpengaruh langsung terhadap kandungan minyak dan kualitas produk akhir [1]. Buah sawit yang matang merupakan kunci utama untuk mendapatkan hasil produksi yang optimal. Namun, penentuan kematangan buah sawit seringkali menjadi tantangan bagi petani. Keterlambatan dalam mendeteksi kematangan buah dapat mengakibatkan kerugian ekonomi yang signifikan, baik karena kehilangan hasil panen maupun penurunan kualitas minyak sawit [2]. Kematangan TBS yang tidak sempurna tidak hanya merugikan hasil panen, tetapi juga mempengaruhi tiga faktor utama dalam produksi minyak sawit, yaitu tingkat kematangan, rendahnya kadar asam lemak bebas, dan tingginya tingkat ekstraksi minyak [3].

Penentuan tingkat kematangan TBS secara tradisional masih mengandalkan tenaga manusia, yang sering kali bersifat subjektif serta dipengaruhi oleh pengalaman serta pengetahuan individu. Proses ini cenderung lambat dan tidak menyeluruh, sehingga dapat mengakibatkan variasi kualitas hasil panen.

Dengan perkembangan teknologi, penggunaan kecerdasan buatan *Artificial Intelligence* (AI) dalam pertanian semakin populer. Salah satu metode yang menjanjikan adalah penggunaan algoritma deteksi objek seperti *You Only Look Once* (YOLO), yang mampu melakukan identifikasi dan klasifikasi objek secara *real-time* dengan akurasi tinggi [4]. Dalam konteks TBS kelapa sawit, YOLO dapat digunakan untuk menganalisis ciri-ciri visual seperti warna, sehingga

memungkinkan penentuan tingkat kematangan secara lebih objektif dan efisien. Teknologi ini diharapkan dapat mengurangi ketergantungan terhadap penilaian visual manusia yang subjektif serta meningkatkan efisiensi dalam proses pemanenan.

Penelitian ini menggunakan dua variasi dataset untuk memperoleh hasil yang lebih komprehensif. Dataset pertama adalah dataset Roboflow yang terdiri dari 8.400 gambar (train, validasi, dan testing) yang diambil dari platform Roboflow. Selain itu, dari dataset Roboflow yang berjumlah 8400 tersebut diambil subset (bagian data yang dipilih dari kumpulan yang lebih besar) sebanyak 625 gambar, agar jumlahnya sama dengan dataset perkebunan sehingga dapat dilakukan perbandingan yang adil (*apple to apple*). Dataset kedua adalah dataset perkebunan sebanyak 625 gambar, yang diambil langsung di lapangan dan diproses melalui platform Roboflow menggunakan tahap *augmentasi* dan *preprocessing*.

Penggunaan dua variasi dataset ini bertujuan agar model dapat belajar dari kondisi yang beragam, baik dari sisi pencahayaan, latar belakang, maupun kualitas gambar. Selain itu, variasi ini memungkinkan analisis pengaruh kondisi data yang seragam (dataset Roboflow) dibandingkan dengan data yang lebih bervariasi (dataset perkebunan) terhadap hasil deteksi dan kecepatan komputasi.

Penggunaan dua variasi dataset ini bertujuan agar model dapat belajar dari kondisi yang beragam, baik dari sisi pencahayaan, latar belakang, maupun kualitas gambar. Selain itu, variasi ini memungkinkan analisis pengaruh kondisi data yang seragam (dataset Roboflow) dibandingkan dengan data yang lebih bervariasi (dataset perkebunan) terhadap hasil deteksi dan kecepatan komputasi.

Selain mengukur akurasi, penelitian ini juga mengevaluasi performa model berdasarkan kecepatan *inferensi* atau *Fame Per Second* (FPS) sebagai indikator efisiensi. Hasil awal menunjukkan bahwa *dataset Roboflow* memungkinkan model berjalan dengan FPS tinggi, sedangkan *dataset* lapangan menurunkan FPS karena adanya variasi kondisi gambar yang lebih kompleks.

Namun, meskipun teknologi ini memiliki potensi besar, masih sedikit penelitian yang membahas secara mendalam tingkat akurasi deteksi kematangan buah sawit menggunakan YOLO, terutama dengan versi terbarunya, seperti YOLOv8 dan YOLOv11. Kedua versi terbaru dari YOLO ini dipilih karena kemampuan mereka dalam mendeteksi objek dengan lebih cepat dan akurat dibandingkan dengan versi sebelumnya, serta keunggulan dalam mengatasi masalah deteksi objek yang lebih kecil dan kompleks. YOLOv8 dan YOLOv11 menunjukkan performa yang lebih baik dalam hal kecepatan dan akurasi, menjadikannya pilihan ideal untuk tugas ini.

Penggunaan teknologi ini dapat membantu mengatasi tantangan yang dihadapi dalam deteksi manual kematangan buah sawit, yang tidak hanya bergantung pada keahlian petani, tetapi juga cenderung menghasilkan kesalahan yang dapat merugikan hasil panen dan kualitas CPO. Dalam hal ini, YOLO mampu menggantikan deteksi manual dengan analisis visual otomatis yang lebih cepat dan akurat. Melalui penelitian ini, diharapkan dapat dilihat sejauh mana tingkat akurasi algoritma YOLO dalam mendeteksi kematangan buah sawit, serta bagaimana perbandingan performa antara YOLOv8 dan YOLOv11.

1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Menganalisis tingkat akurasi, dan efisiensi (FPS) algoritma YOLOv8 dan YOLOv11 dalam mendeteksi kematangan Tandan Buah Segar (TBS) kelapa sawit.
2. Membandingkan performa kedua model berdasarkan metrik *mean Average Precision* (mAP), *Precision*, *Recall*, *F1-Score*, *Accuracy*, serta kecepatan inferensi (FPS) pada dua variasi *dataset* (*Roboflow* dan lapangan).
3. Membandingkan performa kedua model pada subset dataset Roboflow (625 gambar) yang diambil dari dataset 8400 dibandingkan dengan dataset perkebunan (625 gambar).
4. Memberikan rekomendasi model terbaik untuk implementasi praktis.

1.3 Rumusan Masalah

Adapun rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana tingkat akurasi, presisi, *recall*, *F1-score*, mAP, dan efisiensi algoritma YOLOv8 dan YOLOv11 dalam klasifikasi TBS kelapa sawit?
2. Bagaimana perbandingan hasil klasifikasi pada subset dataset Roboflow (625 gambar) dibandingkan dengan dataset perkebunan (625 gambar)?
3. Bagaimana performa YOLOv8 dan YOLOv11 ketika diuji pada dua *dataset* dengan jumlah data yang berbeda tersebut (8.400 gambar vs 625 gambar)?
4. Apakah perbedaan jumlah data (8.400 gambar vs 625 gambar) mempengaruhi tingkat akurasi, presisi, *recall*, *F1-score*, mAP, serta FPS model pada kedua jenis *dataset*?
5. Model mana yang lebih unggul dalam hal efisiensi komputasi (FPS dan waktu inferensi) pada variasi *dataset* yang berbeda?

1.4 Batasan Masalah

Adapun batasan masalah dalam penelitian ini adalah sebagai berikut:

1. *Dataset* yang digunakan dalam penelitian berupa citra tandan buah segar (TBS) kelapa sawit dengan ekstensi .jpg/.jpeg.
2. *Dataset* yang digunakan terdiri dari gambar tandan buah segar kelapa sawit dalam berbagai tingkat kematangan yaitu mentah, mengkal, dan matang.
3. *Dataset* menggunakan kombinasi dua sumber (*Roboflow* dan lapangan) untuk memberikan variasi kondisi gambar.
4. *Dataset* lapangan melalui proses augmentasi dan *preprocessing* di platform *Roboflow* untuk meningkatkan kualitas data.
5. Klasifikasi tingkat kematangan dilakukan berdasarkan warna TBS kelapa sawit.
6. Analisis performa mencakup akurasi dan efisiensi komputasi (kecepatan inferensi dalam FPS).

1.5 Manfaat Penelitian

Adapun manfaat dari penelitian ini yaitu penggunaan teknologi YOLO ini menawarkan kemudahan bagi para petani dengan memberikan solusi yang lebih cepat dalam menentukan kematangan Tandan Buah Segar (TBS). Selain itu, penelitian ini juga berkontribusi pada pengembangan ilmu pengetahuan, khususnya dalam penerapan teknologi kecerdasan buatan (AI) di sektor pertanian, terutama kelapa sawit. Inovasi ini memperkenalkan dan mendorong pemanfaatan teknologi cerdas dalam praktik pertanian di Indonesia. Dengan demikian, penelitian ini dapat dijadikan acuan untuk pengembangan sistem pertanian cerdas yang berkelanjutan dan ramah lingkungan.

1.6 Sistematika Penulisan

Sistematika penulisan dari penulisan laporan proposal ini adalah:

BAB I. PENDAHULUAN

Berisikan latar belakang, tujuan penelitian, manfaat penelitian, perumusan masalah, batasan masalah, dan sistematika penulisan.

BAB II. TINJAUAN PUSTAKA

Berisikan teori-teori yang digunakan dalam melakukan penelitian.

BAB III. METODE PENELITIAN

Bab ini berisikan tentang hal-hal yang dilakukan dalam penelitian, seperti; waktu dan tempat penelitian, metode dan proses pembuatan progra

BAB IV HASIL DAN PEMBAHASAN

Bab ini berisikan mengenai hasil dari penelitian

BAB V KESIMPULAN DAN SARAN

Bab ini berisikan kesimpulan dan saran dari penelitian ini

BAB II TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Menurut [5] dengan judul "Klasifikasi Tingkat Kematangan Buah Sawit Berbasis Deep Learning dengan Menggunakan Arsitektur YOLOv5 tahun". membahas tentang sistem deteksi kematangan buah sawit menggunakan metode *deep learning* untuk meningkatkan efisiensi dan akurasi dalam industri kelapa sawit. Penelitian ini menggunakan metode *You Only Look Once* (YOLO) v5, dengan *dataset* yang terdiri dari 1.500 gambar buah sawit yang telah dilabeli menggunakan *roboflow*. Data ini kemudian diklasifikasikan ke dalam tiga kategori: matang, belum matang, dan busuk. Hasil penelitian menunjukkan bahwa model yang digunakan memiliki tingkat akurasi yang tinggi, dengan *mean Average Precision* (mAP) mencapai 92%, akurasi 97%, dan *recall* 96%. Sistem ini juga berhasil diuji secara *real-time*, menunjukkan efektivitasnya dalam mendeteksi kematangan buah sawit secara otomatis dan akurat.

Menurut [6] dalam jurnal berjudul "Deep Learning Model to Predict the Ripeness of Oil Palm Fruit" membahas tentang mengeksplorasi penerapan *deep learning*, khususnya model YOLOv8, untuk memprediksi tingkat kematangan buah kelapa sawit melalui analisis gambar digital. Penelitian yang bersumber dari Proceedings of the 16th International Conference on Agents and Artificial Intelligence (ICAART) ini bertujuan untuk mengotomatiskan klasifikasi kematangan yang sebelumnya dilakukan secara manual, yang seringkali subjektif dan memakan waktu. Dengan menggunakan gambar buah kelapa sawit yang diambil dari video di area produksi, model YOLOv8 dilatih untuk membedakan tiga tingkat kematangan: mentah, matang, dan terlalu matang. Hasil penelitian menunjukkan bahwa model ini memiliki potensi yang menjanjikan dengan nilai *presisi* dan *recall* yang tinggi.

Meskipun demikian, penelitian menyarankan untuk pengumpulan data yang lebih banyak dan bervariasi untuk meningkatkan kinerja model, serta mempertimbangkan pemisahan kelas kematangan yang lebih detail untuk aplikasi yang lebih akurat di industri kelapa sawit.

Menurut [7], dengan judul "Deteksi Kematangan Tandan Buah Segar (TBS) Kelapa Sawit Berdasarkan Komposisi Warna Menggunakan Deep Learning" membahas tentang mengembangkan metode otomatis untuk mendeteksi kematangan Tandan Buah Segar (TBS) kelapa sawit berdasarkan komposisi warna menggunakan deep learning. Penelitian ini dilakukan karena metode tradisional yang mengandalkan pengamatan manusia kurang efektif, tidak objektif, dan membutuhkan biaya tinggi. Model yang digunakan adalah EfficientNetB0 dan EfficientNetB1 dengan enam kategori kematangan, yaitu TBS mentah, kurang masak, masak, terlalu masak, abnormal, dan janjang kosong. Penelitian ini membandingkan dua optimizer, yaitu RMSprop dan SGD, menggunakan *dataset* 8.976 gambar dengan rasio pembagian 7:1:2 untuk *training*, validasi, dan *testing*. Hasil penelitian menunjukkan bahwa EfficientNetB0 dengan optimizer RMSprop mencapai akurasi tertinggi sebesar 99,55%, sementara EfficientNetB1 dengan optimizer RMSprop mencapai 99,49%, jauh lebih baik dibandingkan model dengan optimizer SGD yang hanya mencapai sekitar 91%. Model dengan RMSprop juga lebih cepat mengalami konvergensi dibandingkan SGD. Kesimpulannya, penggunaan *deep learning*, khususnya EfficientNetB0 dengan RMSprop, mampu meningkatkan efisiensi dan objektivitas dalam menentukan kematangan TBS kelapa sawit dibandingkan metode konvensional berbasis penglihatan manusia.

Menurut [8] dengan judul "Oil Palm Fruit Ripeness Detection using Deep Learning". Penelitian ini membahas tentang deteksi tingkat kematangan tandan buah segar (TBS) kelapa sawit berdasarkan citra digital menggunakan algoritma *deep learning*. Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan tahapan meliputi persiapan data, perancangan arsitektur model dan parameter CNN, pengujian model, pengujian citra, serta analisis hasil. Penelitian ini memperoleh hasil bahwa algoritma CNN mampu mendeteksi tingkat

kematangan TBS kelapa sawit dengan tingkat akurasi sebesar 92% untuk data uji dan 76% untuk pengujian model.

Penelitian yang dilakukan [9] dengan judul "Oil Palm Fruits Ripeness Classification Based on the Characteristics of Protein, Lipid, Carotene, and Guanine/Cytosine from the Raman Spectra". Penelitian ini membahas tentang klasifikasi tingkat kematangan buah kelapa sawit berdasarkan karakteristik protein, lipid, karoten, dan guanin/sitosin yang diekstrak dari spektrum Raman. Penelitian ini menggunakan metode *Raman spectroscopy* yang dikombinasikan dengan *Artificial Neural Network* (ANN) untuk menganalisis spektrum molekuler dan mengklasifikasikan kematangan buah kelapa sawit. Penelitian ini memperoleh hasil bahwa sistem klasifikasi berbasis ANN yang dikembangkan dengan menggunakan tujuh fitur signifikan dari spektrum Raman mencapai akurasi keseluruhan sebesar 97,9%, menjadikannya metode yang efisien dan akurat untuk menentukan tingkat kematangan buah kelapa sawit secara non-destruktif.

2.2 Karakteristik Kelapa Sawit

Pohon kelapa sawit (*Elaeis guineensis* dan *Elaeis oleifera*) adalah tanaman tropis yang berasal dari Afrika Barat dan Amerika Tengah dan Selatan. Pohon kelapa sawit memiliki batang yang tegak dan tinggi, dengan daun yang panjang dan berbentuk seperti bulu ayam. Tingginya dapat mencapai 20-30 meter dan memiliki umur produktif selama 25-30 tahun. Pohon kelapa sawit memiliki akar tunggang yang kuat dan dapat menyerap nutrisi dari tanah dengan baik. Buahnya berwarna merah dan berbentuk bulat, dengan kulit yang tebal dan berduri[10].

2.3 Kematangan Buah Sawit

Kematangan buah kelapa sawit sangat berpengaruh terhadap kualitas dan rendemen minyak yang dihasilkan, serta dapat dikategorikan ke dalam beberapa tingkat. Proses pematangan berlangsung sekitar 5-6 bulan setelah penyerbukan, diawali dengan daging buah berwarna putih kehijauan yang kemudian berubah menjadi kuning kehijauan setelah tiga bulan, menandakan awal pembentukan minyak.

Seiring waktu, cangkang buah mengeras dan warnanya berubah menjadi merah atau oranye, tergantung varietasnya.[11] Secara umum, tingkat kematangan buah sawit dibagi menjadi tiga kategori utama: mentah, matang optimal, dan terlalu matang. Buah mentah memiliki kadar minyak rendah dan kadar air tinggi, sehingga kurang efisien dalam proses ekstraksi minyak. Buah matang optimal ditandai dengan jatuhnya minimal lima brondolan dari tandan, yang menunjukkan kandungan minyak maksimal dengan kadar asam lemak bebas (FFA) yang masih rendah, sehingga kualitas minyak tetap baik. Sementara itu, buah yang terlalu matang cenderung mengalami fermentasi, meningkatkan kadar FFA, yang dapat menurunkan mutu minyak sawit mentah (CPO). Oleh karena itu, pemanenan harus dilakukan secara berkala setiap 10-14 hari untuk memastikan buah yang diambil berada dalam tingkat kematangan yang tepat agar produktivitas dan efisiensi ekstraksi minyak sawit tetap maksimal. [12]

2.4 Klasifikasi Objek

Klasifikasi objek pada algoritma YOLO (You Only Look Once) dilakukan dengan membagi gambar input menjadi beberapa grid, di mana setiap grid memprediksi bounding box (kotak pembatas) dan skor keyakinan (confidence score) yang mengindikasikan probabilitas keberadaan objek beserta klasifikasinya. YOLO menganggap deteksi objek sebagai masalah regresi tunggal yang langsung memetakan dari input gambar ke bounding box dan kelas objek yang ada di gambar tersebut. Proses klasifikasi pada YOLO bekerja sebagai berikut: Gambar dibagi menjadi beberapa grid (misalnya $s \times s$). Setiap grid memprediksi sejumlah bounding box yang mungkin mengandung objek. Setiap bounding box memiliki nilai confidence yang mencerminkan kepercayaan lokasi objek serta probabilitas kelas objek. Klasifikasi objek dilakukan dengan menentukan kelas yang memiliki probabilitas tertinggi untuk bounding box tersebut. Hanya bounding box dengan skor confidence di atas ambang tertentu yang dianggap valid dan diklasifikasikan.

Contoh aplikasi klasifikasi objek dengan YOLO meliputi deteksi dan klasifikasi jenis kendaraan (mobil, motor, bus, truk), posisi tidur manusia, jenis sampah, dan berbagai objek dalam video rekaman real-time dengan tingkat akurasi yang cukup tinggi serta kecepatan proses yang cepat.

Klasifikasi objek YOLO melibatkan prediksi bounding box dan kelas objek secara simultan pada setiap grid gambar, dengan hasil berupa lokasi objek dan label kelasnya dalam satu langkah proses jaringan saraf tunggal. Dalam konteks pertanian, klasifikasi objek sering digunakan untuk memantau dan menentukan tingkat kematangan buah sawit. Sebagai contoh, pada Gambar 2.1 ditunjukkan penerapan teknologi deteksi objek berbasis deep learning yang berhasil mengidentifikasi tingkat kematangan buah sawit dalam sebuah gambar. Penerapan deteksi objek pada kematangan buah sawit bertujuan utama untuk mendukung kegiatan panen yang lebih efisien dan akurat. Sebagai contoh, model berbasis *deep learning* dapat digunakan untuk mendeteksi buah sawit dengan kematangan optimal melalui analisis citra. Model ini mampu membedakan karakteristik visual, seperti warna, tekstur, dan ukuran buah, yang menjadi indikator tingkat kematangan [13] .




Gambar 2. 1 Klasifikasi Objek pada Buah sawit

Dalam dua dekade terakhir, teknologi deteksi objek mengalami dua periode perkembangan utama. Periode pertama, sebelum tahun 2014, dikenal sebagai era deteksi objek tradisional. Pada masa ini, metode deteksi masih mengandalkan teknik konvensional, seperti pengolahan citra manual untuk mengekstraksi fitur visual buah sawit. Representasi gambar belum cukup efektif, sehingga diperlukan desain fitur yang rumit dan optimasi proses komputasi sesuai dengan keterbatasan perangkat keras saat itu. Setelah tahun 2014, periode deteksi objek berbasis *deep learning* membawa perubahan besar. Metode ini, seperti yang menggunakan *Convolutional Neural Networks* (CNNs), meningkatkan akurasi dan efisiensi deteksi kematangan buah sawit. Dengan memanfaatkan arsitektur yang mampu menggali informasi dari lapisan-lapisan dalam, model-model ini dapat mengenali tingkat kematangan dengan lebih presisi. Teknik *deep learning* telah diaplikasikan dalam analisis kematangan buah sawit melalui pelatihan pada *dataset* citra sawit yang besar dan beragam sehingga memungkinkan sistem untuk mengenali pola kematangan dengan lebih baik. Perkembangan teknologi ini membuka potensi besar dalam mengotomatisasi dan meningkatkan kualitas panen buah sawit, menjadikannya alat yang penting dalam sektor agrikultur modern. Hal ini tidak hanya meningkatkan efisiensi, tetapi juga berkontribusi pada manajemen sumber daya yang lebih baik dalam industri kelapa sawit.

2.5 *You Only Look Once* (YOLO)

You Only Look Once (YOLO) adalah metode klasifikasi object yang inovatif, dikenal karena kecepatannya yang lebih unggul dibandingkan metode berbasis CNN. Arsitektur YOLO memprioritaskan kecepatan dan akurasi. Kecepatan YOLO membuatnya lebih disukai untuk pendeteksian objek secara *real-time* dan membuatnya menjadi deskriptor umum pendeteksi objek yang canggih dan berakurasi tinggi. Keunggulan YOLO terletak pada pendekatannya yang sederhana, yaitu membentuk pola deteksi objek melalui satu proses regresi. Proses ini menghasilkan kotak pembatas dalam bentuk piksel gambar dengan dimensi spasial tertentu, sekaligus menghitung probabilitas kelas objek terkait. Dengan memanfaatkan jaringan saraf tunggal, YOLO mampu melakukan deteksi dan

pengenalan objek secara langsung dalam satu tahap, memprediksi koordinat kotak pembatas dan probabilitas kelas secara bersamaan [14]. Dari segi arsitektur, YOLO memiliki kemiripan dengan GoogleNet. Yolo memiliki 24 lapisan konvolusional, lapisan konvolusional 1×1 yang bergantian mengurangi ruang fitur dari lapisan sebelumnya, kemudian diikuti oleh 2 lapisan yang terhubung sepenuhnya untuk menghasilkan tensor akhir seperti yang ditunjukkan sebelumnya.



Gambar 2. 2 Arsitektur YOLO [15]

Pada Gambar 2.2 YOLO memproses gambar dengan memasukkannya ke dalam jaringan saraf konvolusional (CNN) yang efisien, backbond untuk mendeteksi objek dalam gambar. Arsitektur CNN ini, yang krusial bagi fungsionalitas YOLO, secara efisien mengurai keseluruhan gambar dalam satu evaluasi, sehingga memungkinkannya memprediksi kotak pembatas dan probabilitas kelas yang sesuai secara bersamaan. Desain jaringan ini dioptimalkan untuk menyeimbangkan kecepatan dan akurasi, menjadikan YOLO sangat efektif untuk aplikasi deteksi objek secara *real-time*.

Berikut adalah uraian terperinci tentang cara kerja YOLO:

LANGKAH 1. Membagi gambar menjadi Kotak-kotak

YOLO dimulai dengan membagi seluruh gambar menjadi kotak-kotak kecil. Segmentasi ini membantu mengelola kompleksitas gambar dengan memecahnya

menjadi bagian-bagian yang lebih mudah dikelola. Setiap kotak kemudian dianalisis secara independen, yang menyederhanakan proses deteksi awal karena algoritme berfokus pada area yang lebih kecil pada satu waktu, bukan pada keseluruhan gambar.

LANGKAH 2. Deteksi objek dalam setiap sel grid


Di dalam setiap kotak, YOLO memprediksi keberadaan objek. Model ini menggunakan model pembelajaran mendalam yang canggih yang dilatih secara ekstensif pada kumpulan data gambar dan label terkait. Pelatihan ini memungkinkan model untuk mengenali dan mengkategorikan berbagai objek secara efektif di dalam kotak-kotak ini. Model memprediksi apakah suatu objek ada dan mengantisipasi kategorinya berdasarkan karakteristik yang dipelajari.

LANGKAH 3. Menyempurnakan prediksi dengan penekanan non-maksimum

Setelah prediksi awal dibuat, YOLO menyempurnakannya menggunakan teknik yang dikenal sebagai penekanan non-maksimum. Metode ini penting karena membantu menghilangkan kotak pembatas yang berlebihan dan tumpang tindih. Dengan membandingkan tumpang tindih antara prediksi dan hanya mempertahankan yang paling mungkin, penekanan non-maksimum memastikan bahwa kotak pembatas terbaik yang mungkin mewakili setiap objek yang terdeteksi.

LANGKAH 4. Mengeluarkan deteksi akhir


Langkah terakhir dalam proses deteksi YOLO melibatkan keluaran prediksi yang telah disempurnakan. YOLO mengeluarkan kotak pembatas untuk setiap objek yang terdeteksi, garis persegi panjang yang secara akurat merangkum lokasi objek dalam gambar. Selain itu, ia menetapkan label objek, yang mengidentifikasi jenis objek yang terdapat dalam kotak pembatas. Anotasi ini memberikan wawasan yang jelas dan dapat ditindaklanjuti tentang objek dalam gambar, seperti yang ada pada gambar 2.3 dibawah ini.



Gambar 2. 3 Sistem Deteksi YOLO [16]

Gambar 2.3 Sistem Deteksi YOLO. Memproses gambar dengan YOLO adalah sederhana dan langsung. Dimana pertama (1) resize image mengubah ukuran gambar masukan menjadi 640 x 640, (2) menjalankan satu jaringan konvolusi pada gambar, dan (3) menetapkan ambang deteksi yang dihasilkan berdasarkan kepercayaan model.

Model klasifikasi YOLO membagi citra masukan menjadi grid berukuran $S \times S$. Setiap sel grid bertanggung jawab untuk mengklasifikasi objek yang mungkin ada di dalamnya. Setiap sel grid memprediksi kotak pembatas (B) seperti kotak-kotak yang ada di gambar 2.3 yang berwarna biru, biru muda dan merah dan skor keyakinan kotak (*box confidence scores*) yang berada di atas setiap objek yang ada tersebut. Skor keyakinan mencerminkan seberapa yakin model YOLO bahwa kotak pembatas berisi objek dan seberapa akurat kotak pembatas tersebut dalam memperkirakan lokasi dan ukuran objek. Berikut gambar dibawah ini adalah komponen *bounding box*.

Gambar 2. 4 komponen *Bounding box* [17]


Detektor YOLO dapat memprediksi kelas objek, kotak batasnya, dan probabilitas kelas objek di dalam kotak batas. Kotak pembatas yang diprediksi (B) dalam YOLO terdiri dari lima komponen: x , y , w , h , dan skor keyakinan kotak, seperti pada gambar 2.4. Koordinat (x , y) mewakili pusat kotak, posisi pusat kotak batas dalam gambar (b_x , b_y) relatif terhadap batas sel grid. Koordinat ini dinormalisas antara 0 dan 1. Dimensi (w , h) Lebar kotak (b_w) Tinggi kotak (b_h) digunakan untuk mengukur citra dan diproses dalam sistem dan Kelas objek (c). Hasil dari prediksi deteksi objek algoritma YOLO dituliskan sebagai tensor dengan ukuran seperti pada Persamaan 2.1.

$$\text{Ukuran tensor} = S \times S \times (B \times 5 + C) \quad (2.1)$$

Dimana:

- $S \times S$: Grid dari gambar yang dibagi menjadi $S \times S$ sel.
- B : Jumlah *bounding boxes* yang diprediksi per sel.
- 5 : Elemen-elemen yang terdiri dari koordinat pusat, ukuran *bounding box*, dan skor keyakinan.
- C : Jumlah kelas yang dapat diprediksi oleh model.

Secara keseluruhan, YOLO merupakan metode deteksi objek canggih yang menggunakan jaringan saraf tunggal, membagi citra masukan menjadi grid, dan memprediksi kotak pembatas, skor keyakinan, dan probabilitas kelas untuk deteksi objek yang efisien dan akurat. Pendekatan ini menawarkan solusi komprehensif dengan menggabungkan dimensi spasial, skor keyakinan, dan probabilitas kelas, memungkinkan lokalisasi objek yang presisi dan pemrosesan yang cepat.



Gambar 2. 5 Alur Kerja algoritma YOLO dalam pendeteksi objek pada citra [18]

2.6 Teknologi Deteksi Objek dengan YOLO

Teknologi deteksi objek dengan YOLO adalah salah satu metode paling populer dalam bidang *computer vision* yang digunakan untuk mendeteksi dan mengklasifikasikan objek dalam gambar atau video secara *real-time*. Proses dimulai dengan memasukkan gambar atau frame video ke dalam model YOLO, yang kemudian diubah ukurannya menjadi dimensi tetap (misalnya, 416x416 piksel) untuk memastikan konsistensi dalam pemrosesan. Gambar yang telah di-resize dibagi menjadi grid dengan ukuran tetap, dimana setiap sel grid bertanggung jawab untuk mendeteksi objek yang berada di dalam area tersebut.

Setiap sel memprediksi sejumlah *bounding box* (kotak pembatas) dan probabilitas untuk setiap objek yang mungkin ada, termasuk koordinat, ukuran, dan *confidence score*. Selain itu, YOLO juga mengklasifikasikan objek yang terdeteksi ke dalam kategori tertentu. Setelah semua prediksi dilakukan, teknik *Non-Maximum Suppression* (NMS) digunakan untuk menghilangkan *bounding box* yang tumpang tindih, sehingga menghasilkan output akhir yang mencakup *bounding box*, kelas objek, dan *confidence score*.

Keunggulan utama YOLO terletak pada kecepatannya yang mampu memproses gambar dalam waktu nyata, serta akurasi yang baik dalam mendeteksi objek. Teknologi ini telah diterapkan dalam berbagai bidang, termasuk pertanian untuk

mendeteksi penyakit tanaman, keamanan untuk pengawasan, otomotif dalam kendaraan otonom, dan analisis citra medis. Dengan fleksibilitas dan efisiensi sumber daya yang ditawarkannya, YOLO menjadi alat yang sangat berguna dalam berbagai aplikasi deteksi objek.


2.7 Aplikasi YOLO dalam sektor pertanian

YOLO adalah algoritma deteksi objek yang sangat efektif dalam sektor pertanian, digunakan untuk mendeteksi berbagai masalah seperti penyakit tanaman, kualitas hasil panen, dan identifikasi spesies tanaman. Dengan akurasi tinggi dan kecepatan, teknologi ini membantu petani dalam pengambilan keputusan yang lebih baik dan efisien. Misalnya, YOLO dapat menganalisis citra daun dan bagian tanaman lainnya untuk mendeteksi penyakit memungkinkan petani mengambil tindakan pencegahan lebih cepat dan mengurangi kerugian hasil panen [19]. Selain itu, teknologi ini juga efektif dalam mengidentifikasi hama yang menyerang tanaman [20], sehingga deteksi dini dapat dilakukan untuk menerapkan pengendalian yang tepat sebelum infestasi menyebar. Dalam hal pemantauan kualitas hasil panen, YOLO dapat menganalisis citra buah dan sayuran, memastikan bahwa produk yang dihasilkan memenuhi standar kualitas yang diinginkan. Dengan menggunakan YOLO, petani dapat lebih efisien dalam mengelola sumber daya seperti air dan pupuk, serta mendapatkan informasi akurat mengenai kondisi tanaman dan lingkungan yang mendukung strategi pertanian yang lebih efektif.

Secara keseluruhan, penerapan YOLO dalam pertanian memberikan alat yang efektif bagi petani untuk mengelola sumber daya dan meningkatkan hasil panen, serta menunjukkan potensi besar teknologi ini untuk meningkatkan efisiensi dan produktivitas di sektor pertanian .

2.8 YOLOv8

YOLOv8 merupakan sebuah Arsitektur deteksi objek yang merupakan evolusi dari YOLOv7. YOLOv8 dikembangkan oleh Ultralytics pada tahun 2021 sebagai solusi terbaru untuk tugas deteksi objek menggunakan jaringan saraf konvolusional (CNN). Memanfaatkan pembelajaran dari pendahulunya, YOLOv8 menghadirkan sejumlah perbaikan dan peningkatan yang signifikan. Salah satu peningkatan utama adalah penggunaan backbone CNN yang lebih efisien, yaitu CSPDarknet53, yang memiliki kinerja baik dalam mengekstrak fitur dari gambar input. Tidak hanya itu, YOLOv8 juga mengintegrasikan teknik deteksi objek terbaru seperti Feature Pyramid Network (FPN) dan Path Aggregation Network (PAN) untuk meningkatkan kemampuan dalam mendeteksi objek dengan berbagai ukuran dan jarak. Selain itu, untuk mengurangi risiko overfitting, YOLOv8 mengadopsi teknik baru seperti CutMix dan Auto Augment. Dibagi menjadi tiga bagian utama, YOLOv8 memiliki backbone untuk ekstraksi fitur, FPN untuk menggabungkan fitur dari berbagai level, dan head untuk memprediksi *bounding box*, kelas objek, dan probabilitas objek yang terdeteksi. Kinerja arsitektur ini terbukti sangat baik dalam berbagai konteks, seperti deteksi objek pada video, kendaraan otonom, dan video surveillance. Dengan kinerja yang efisien dan kemudahan implementasi, YOLOv8 telah menjadi salah satu arsitektur CNN paling populer untuk tugas deteksi objek [21]. Arsitektur YOLOv8 ditunjukkan oleh Gambar 2.8 dibawah ini:



Gambar 2. 6 Arsitektur YOLOv8 [21]

Pada Gambar 2.8 diatas berikut adalah penjelasan detail mengenai arsitektur YOLOv8

1. Backbone:

Pada YOLOv8, backbone terdiri dari beberapa modul utama seperti *Conv*, *SPD-Conv*, *C2f*, dan *SPPF*. Modul *SPD-Conv* (diberi warna hijau) merupakan peningkatan dari modul standar yang bertujuan untuk meningkatkan efisiensi dan representasi fitur. Modul *C2f* (berwarna biru) menggantikan modul *C3* untuk memfasilitasi fusi fitur dengan beban komputasi yang lebih ringan dan kecepatan yang lebih tinggi. *SPPF* (Spatial Pyramid Pooling Fast) digunakan pada bagian akhir backbone untuk menangkap informasi spasial dari berbagai ukuran receptive

field, membantu memperkaya representasi fitur sebelum diteruskan ke neck.[22],[23]

2. Neck: Jaringan Agregasi Jalur (PANet)

Bagian neck bertugas untuk menggabungkan fitur dari berbagai tingkat kedalaman (multiskala) dan memperkuat informasi penting dari gambar. Neck YOLOv8 menggunakan kombinasi antara upsample, concat, C2f, dan modul perhatian seperti Global Attention Module (GAM). Modul GAM (berwarna oranye) ditambahkan untuk meningkatkan fokus pada area penting dalam gambar, sehingga membantu deteksi objek yang lebih akurat. Struktur neck ini mengikuti prinsip PANet, yang memungkinkan aliran informasi dari bawah ke atas dan sebaliknya. Penggunaan modul tambahan dan perbaikan pada neck bertujuan untuk meningkatkan kemampuan model dalam mendeteksi objek dari berbagai ukuran dan posisi. [22],[23]


3. Head: Multi-Detection Heads

Bagian head bertanggung jawab atas prediksi akhir berupa bounding box dan label kelas objek. Pada YOLOv8, terdapat beberapa jalur deteksi yang memungkinkan prediksi pada berbagai skala (multi-scale detection). Hal ini membantu dalam mendeteksi objek kecil, sedang, maupun besar dengan presisi yang seimbang. Head menggunakan pendekatan *anchor-free*, sehingga model secara langsung memprediksi koordinat bounding box tanpa ketergantungan pada anchor box yang telah ditentukan sebelumnya. Beberapa modul C2f dan GAM juga tetap digunakan dalam head untuk mempertahankan efisiensi dan akurasi.[22], [23]

2.9 YOLOv11

YOLOv11 merupakan langkah revolusioner dalam seri YOLO yang menghadirkan inovasi pada arsitektur dan metode pelatihan, menjadikannya salah satu model deteksi objek paling serbaguna dan canggih saat ini. Dengan peningkatan kemampuan ekstraksi fitur melalui arsitektur backbone dan neck yang lebih baik, YOLOv11 mampu memberikan performa superior pada berbagai tugas, termasuk

deteksi objek kecil, estimasi pose, dan deteksi objek berorientasi. Model ini juga lebih efisien secara komputasi, menggunakan 22% lebih sedikit parameter dibandingkan YOLOv8, sehingga cocok untuk diterapkan pada perangkat berdaya rendah seperti edge devices dan perangkat mobile. Selain efisiensinya, arsitektur YOLOv11 dirancang untuk mengoptimalkan kecepatan dan akurasi, berdasarkan kemajuan yang diperkenalkan dalam versi YOLO sebelumnya seperti YOLOv8, YOLOv9, dan YOLOv10. YOLOv11 menunjukkan adaptabilitas, mendukung beragam tugas seperti segmentasi instance, klasifikasi, dan analisis video secara *real-time*. [24]. Arsitektur YOLOv11 ditunjukkan oleh Gambar 2.7 dibawah ini:



Gambar 2. 7 Arsitektur YOLOv11[25]

Pada Gambar 2.9 di atas berikut merupakan penjelasan rinci arsitektur YOLOv11.

A. Backbone (Jaringan Utama) : Backbone berfungsi sebagai komponen dasar model, yang didedikasikan untuk mengekstraksi fitur multiskala dari gambar masukan. Backbone mencakup modul-modul berikut: (1) Conv (Lapisan Konvolusional): Modul Conv, lapisan konvolusional awal, memproses gambar masukan untuk mengekstraksi fitur dasar tingkat rendah, yang membentuk dasar untuk ekstraksi fitur tingkat tinggi. (2) Modul C3k2: Modul C3k2 mengintegrasikan beberapa lapisan konvolusional dan koneksi bypass, yang memfasilitasi ekstraksi fitur lokal yang efisien sambil mempertahankan aliran

gradien untuk meningkatkan stabilitas pelatihan. (3) Modul Penggabungan SPPF (Modul Penggabungan Piramida Spasial): Modul SPPF menggunakan operasi penggabungan pada skala yang bervariasi untuk meningkatkan kapasitas model dalam menangkap konteks global melalui representasi fitur multiskala. (4) Modul C2PSA: Mekanisme Cross-Stage Partial Attention (C2PSA) merupakan tambahan baru untuk YOLOv11. Ini secara efektif menyaring informasi yang tidak relevan, menekankan fitur-fitur penting, dan meningkatkan kemampuan deteksi dalam adegan-adegan yang kompleks.[25]

B. Neck (Feature Fusion Layer): Neck berfungsi sebagai lapisan perantara yang menghubungkan Backbone dan Head, meningkatkan deteksi objek dengan menggabungkan fitur multiskala, yang khususnya menguntungkan untuk mendeteksi objek dengan berbagai ukuran. Ini mencakup komponen berikut: (1) Upsample: Modul Upsample meningkatkan resolusi peta fitur resolusi rendah, mirip dengan memperbesar bagian gambar yang kabur, sehingga meningkatkan deteksi objek yang lebih kecil; (2) Concat (Feature Concatenation): Modul Concat menggabungkan peta fitur dengan berbagai resolusi, analog dengan melapisi lapisan transparan dengan detail berbeda, yang memungkinkan model memanfaatkan informasi multilevel untuk meningkatkan kinerja deteksi; (3) Modul C3k2 (Modul C3 Kernel Size 2): Modul C3k2, yang diperkenalkan kembali di Neck, mengintegrasikan fitur lintas skala melalui operasi konvolusional berulang dan koneksi pintasan, memperkaya representasi fitur dan meningkatkan akurasi deteksi.[25]

C. Head (Detection Head) : Head, sebagai tahap akhir YOLOv11, mengubah peta fitur yang diproses menjadi keluaran deteksi objek yang presisi. Modul Detect, inti dari Head, memproses peta fitur di berbagai skala, mirip dengan memperbesar dan memperkecil gambar, untuk mengidentifikasi objek besar dan kecil secara akurat. Kemampuan multiskala ini sangat penting untuk mendeteksi objek dengan berbagai ukuran, mulai dari mesin besar hingga alat yang lebih kecil, memastikan kinerja yang konsisten di berbagai lingkungan. Akibatnya, Head berperan penting dalam mengubah fitur yang dipelajari menjadi hasil

deteksi yang akurat, menjadikannya komponen integral dari arsitektur YOLOv11.[25]

2.10 Perbandingan YOLOv8 dan YOLOv11

Perbandingan atau comparing YOLOv8 dan YOLOv11 berdasarkan kinerja Metrik utama yang digunakan untuk perbandingan adalah sebagai berikut [26]:

1. Versi Model (n, s, m,):

Model YOLO yang dikembangkan oleh Ultralytics hadir dalam berbagai ukuran, yaitu nano (n), *small* (s), dan *medium* (m) . Model yang lebih besar cenderung lebih kompleks dan kuat, namun, model tersebut juga membutuhkan lebih banyak sumber daya dan beroperasi dengan kecepatan yang lebih lambat.

2. mAP (*Mean Average Precision*): Skor

mAP memberi tahu kita seberapa akurat model dalam mendeteksi objek. Perhitungan didasarkan pada kemampuan model untuk mengenali objek pada berbagai tingkat tumpang tindih dengan objek sebenarnya yang ada dalam gambar. Rata-rata Presisi (mAP) yang lebih tinggi menunjukkan akurasi model yang lebih tinggi, yang menandakan peningkatan kemampuannya untuk mendeteksi dan memposisikan objek secara akurat dalam gambar.

3. Kecepatan (dalam ms):

Kecepatan memberi tahu kita seberapa cepat model dapat memproses gambar. Ada 2 jenis kecepatan yaitu sebagai berikut:

- Kecepatan CPU: Ini mengukur seberapa cepat model berjalan pada prosesor komputer biasa (CPU)
- Kecepatan GPU: Ini mengukur seberapa cepat model berjalan pada GPU NVIDIA seperti A100 atau T4, yang biasanya digunakan untuk tugas AI berperforma tinggi.
- YOLOv11 lebih unggul di CPU, tetapi YOLOv8 tetap memimpin di GPU, menjadikannya lebih ideal untuk aplikasi *real-time* berbasis GPU.

4. Params(M):

Menunjukkan jumlah parameter (dalam jutaan) untuk model tertentu. Semakin besar model, semakin banyak parameternya. YOLOv11 unggul secara konsisten di semua model dengan peningkatan akurasi meski semakin kecil pada model yang lebih besar

5. FLOP(B):

FLOP (Floating Point Operations) menunjukkan kompleksitas komputasional model. FLOP yang lebih tinggi berarti model membutuhkan lebih banyak sumber daya komputasional. Nilainya diukur dalam miliaran YOLOv11 lebih efisien dalam penggunaan parameter dan FLOPs, mengurangi beban komputasi dengan tetap menjaga akurasi lebih tinggi dibanding YOLOv8.

2.11 Data Preparation

2.11.1 Pengumpulan Data

Data gambar untuk penelitian ini dikumpulkan dari kebun kelapa sawit yang terletak di Kalirejo Pringsewu serta data dari platform *Roboflow*. Pengumpulan data dilakukan dengan cara mengambil gambar tandan buah segar kelapa sawit dengan berbagai tingkat kematangan. Lokasi pengambilan gambar dipilih untuk mencakup variasi dalam lingkungan pertanian, termasuk perbedaan pencahayaan, cuaca, dan latar belakang. *Dataset* dari perkebunan terdiri dari gambar awal 256 gambar dan *dataset* dari *Roboflow* terdiri dari 8.400 gambar yang mencakup beberapa tingkat kematangan tandan buah kelapa sawit. *Dataset* lapangan ini kemudian diproses melalui platform *Roboflow* dengan tahap augmentasi dan *preprocessing* yang kemudian menghasilkan 625 gambar akhir. Kedua *dataset* ini dikelompokkan ke dalam beberapa kategori kematangan. Variasi *dataset* ini juga digunakan untuk membandingkan pengaruh kondisi data yang seragam (*dataset Roboflow*) dan data yang lebih beragam (*dataset* lapangan) terhadap hasil deteksi dan kecepatan komputasi.

No	Gambar	Tingkat Kematangan	Keterangan
1		Mentah	Sawit mentah merupakan kategori buah kelapa sawit yang belum siap diolah. Ciri khas buahnya adalah warna kulitnya masih hitam.
2		Mengkal	Tandan buah yang mulai menunjukkan warna kuning merah, tetapi masih memiliki tekstur keras dan kandungan minyak yang rendah. Buah dalam tahap ini belum optimal untuk dipanen.
3		Matang	Sawit matang merupakan kategori kelapa sawit buah yang siap diolah. Ciri buah adalah warna kulit merah atau oranye.

Gambar 2. 8 Tingkat Kematangan Buah sawit

2.10.2 Anotasi Data

Setiap gambar dalam *dataset* dianotasi. Proses anotasi ini melibatkan penempatan *bounding box* di sekitar setiap tandan buah sawit yang terdeteksi, serta pemberian label tingkat kematangan yang sesuai. Format anotasi yang digunakan adalah format YOLO, yang menyimpan informasi tentang kelas objek (kematangan buah)

dan koordinat *bounding box* dalam bentuk rasio terhadap ukuran gambar, yaitu *x_center*, *y_center*, *width*, dan *height*. Seperti ditunjukkan pada Gambar 2.9, contoh file label tersebut terdiri dari tiga baris data yang masing-masing mewakili satu objek sawit yang terdeteksi.

```
1 0.492647 0.569118 0.563072 0.331373
0 0.828268 0.267892 0.343464 0.248529
0 0.086765 0.346569 0.172876 0.245588
```

Gambar 2. 9 Label txt

Pada gambar 2.11 baris pertama memiliki nilai 1 0.492647 0.569118 0.563072 0.331373, yang berarti objek tersebut termasuk kelas 1 (mentah), dengan posisi tengah *bounding box* berada pada koordinat X sebesar 0.4926 (sekitar 49,26% dari lebar gambar) dan Y sebesar 0.5691 (sekitar 56,91% dari tinggi gambar). Ukuran *bounding box*-nya memiliki lebar 0.5631 dan tinggi 0.3313 dalam rasio terhadap dimensi gambar.

Baris kedua 0 0.828268 0.267892 0.343464 0.248529 menunjukkan objek dengan kelas 0 (mengkak), terletak di bagian kanan atas gambar, dengan titik tengah pada X sebesar 0.8282 (82,82%) dan Y sebesar 0.2678 (26,78%). *Bounding box* ini memiliki lebar 0.3434 dan tinggi 0.2485.

Sementara itu, baris ketiga 0 0.086765 0.346569 0.172876 0.245588 juga merupakan objek dari kelas 0 (mengkak), dengan posisi di bagian kiri tengah gambar. Titik tengah *bounding box* berada pada koordinat X sebesar 0.0867 (8,67%) dan Y sebesar 0.3465 (34,65%), serta ukuran kotak selebar 0.1728 dan setinggi 0.2455.

Informasi ini penting bagi model YOLO untuk memahami di mana posisi objek dan bagaimana ukurannya dalam gambar. Dengan menggunakan format rasio, model dapat melakukan pelatihan dan deteksi secara fleksibel pada berbagai ukuran resolusi gambar, tanpa kehilangan presisi lokasi objek.

2.12 Implementasi Model

2.12.1 Proses Pelatihan Model


Model YOLOv8 dan YOLOv11 dilatih menggunakan *dataset* yang telah dianotasi. Proses pelatihan melibatkan pengaturan *hyperparameter* seperti *learning rate*, *batch size*, dan jumlah *epoch*. Teknik augmentasi data, seperti *rotasi*, *flipping*, dan perubahan kecerahan, diterapkan untuk meningkatkan keberagaman data pelatihan.

2.12.2 Evaluasi Kinerja Model

Kinerja model dievaluasi menggunakan *dataset* validasi. Metrik yang digunakan untuk mengukur kinerja termasuk *Mean Average Precision* (mAP), *precision*, *recall*, dan *F-Measure*. Hasil evaluasi ini akan memberikan gambaran tentang seberapa baik model dalam mendeteksi tingkat kematangan tandan buah kelapa sawit.

2.13 AI Project Cycle

AI Project Cycle, yaitu sebuah kerangka kerja yang terdiri dari tahapan-tahapan untuk mengembangkan sebuah proyek berbasis kecerdasan buatan (*Artificial Intelligence*). Dalam penelitian ini, digunakan metode YOLOv8 dan YOLOv11 untuk mendeteksi tingkat kematangan buah sawit. Project Cycle untuk penelitian ini di gambarkan pada gambar 2.10 berikut.



Gambar 2. 10 AI Project Cycle [27]

2.13.1. Problem Scoping

Pada tahap awal penelitian, dilakukan observasi langsung terhadap berbagai fenomena lingkungan, disertai dengan tinjauan literatur untuk memperoleh pemahaman yang lebih mendalam. Setelah itu, dilakukan identifikasi masalah yang akan dijadikan fokus penelitian. Ruang lingkup permasalahan dianalisis menggunakan pendekatan 4W, yaitu Who, What, Where, dan Why. Proses ini berperan penting dalam mengenali serta menyelesaikan permasalahan secara lebih efektif dan efisien.

2.13.2. Data Acquisition (Pengumpulan dan Persiapan Data)

Tahap ini melibatkan pengumpulan *dataset* yang relevan dari berbagai sumber, seperti citra atau video untuk deteksi objek. Setelah data dikumpulkan, dilakukan proses pembersihan data, termasuk menghapus duplikasi, menangani data yang hilang, serta memastikan konsistensi dan kualitas data. Selain itu, data juga dapat diproses lebih lanjut, misalnya melalui normalisasi atau augmentasi untuk meningkatkan performa model.

2.13.3. Data Exploration

Pada tahap ini, dilakukan eksplorasi data untuk memahami pola, tren, dan hubungan antarvariabel. Visualisasi data menggunakan grafik atau diagram membantu dalam menganalisis distribusi dan mendeteksi anomali atau outlier yang mungkin mempengaruhi performa model. Dengan memahami karakteristik data, tim dapat mengambil keputusan yang lebih baik sebelum melanjutkan ke tahap pemodelan.

2.13.4. Modelling (Pemilihan dan Pengembangan Model)

Tahap ini melibatkan pemilihan algoritma AI yang sesuai untuk klasifikasi objek, seperti YOLO, Faster R-CNN, atau SSD. Data yang telah diproses sebelumnya dibagi menjadi set pelatihan, validasi, dan pengujian. Model kemudian dilatih

menggunakan data pelatihan dan dilakukan tuning hyperparameter untuk mengoptimalkan kinerjanya. Selain itu, beberapa model dapat dibandingkan untuk memilih yang memiliki performa terbaik.

2.13.5. Evaluation (Evaluasi Model)

Pada tahap evaluasi, kinerja model diuji menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-Score*. *Cross-validation* juga dilakukan untuk memastikan model tidak mengalami *overfitting* dan dapat bekerja dengan baik pada data baru. Jika model belum memberikan hasil yang optimal, maka dilakukan perbaikan melalui peningkatan data atau penyesuaian parameter model sebelum diterapkan dalam sistem produksi.

2.14 Mean Average Precision (mAP)

Mean Average Precision (mAP) adalah metrik evaluasi yang sering digunakan dalam bidang pengenalan objek dan informasi terkait pencarian. mAP adalah nilai rata-rata dari *Average Precision* (AP) untuk setiap kueri atau objek dalam *dataset* yang diuji. AP sendiri mengukur sejauh mana sistem mengembalikan hasil yang relevan dalam urutan yang tepat. Dalam konteks informasi terkait pencarian atau deteksi objek, mAP mengukur sejauh mana sistem dapat memberikan hasil yang relevan dengan tingkat kepastian tertentu. Dengan kata lain, semakin tinggi nilai mAP, semakin baik sistem pengenalan objek atau pencarian informasi tersebut. Ini adalah metrik penting dalam mengevaluasi kinerja algoritma terkait pencarian informasi dan pengenalan objek [28]. Nilai mAP dapat dihitung dengan persamaan berikut:

$$mAP = \sum (recall_{n+1} - recall_n) \cdot precision_{interp.}(recall_{n+1}) \quad (2.2)$$

Dimana:

- mAP memberikan nilai rata-rata *precision* pada berbagai tingkat *recall* dan memberikan gambaran keseluruhan tentang kinerja model deteksi objek.

- *Recall* mengukur seberapa baik model menangkap semua objek yang ada.
- *Precision* mengukur akurasi prediksi positif model.
- $n+1$ dan n menunjukkan dua titik berturut-turut pada kurva *Precision-Recall*.
- $n+1$ adalah titik *recall* yang lebih tinggi (lebih besar) daripada n .
- interp (interpolasi) mengacu pada metode untuk menghaluskan nilai *precision* antara dua nilai *recall* agar lebih stabil dan tidak fluktuatif.

2.15 Precision

Precision adalah metrik evaluasi yang digunakan dalam statistik, pembelajaran mesin, dan tugas-tugas klasifikasi untuk mengukur sejauh mana hasil positif yang dihasilkan oleh suatu model atau algoritma adalah benar atau relevan. *Precision* mengukur ketepatan dari prediksi positif yang dibuat oleh model [28]. Presisi merupakan parameter evaluasi yang menilai kemampuan model dalam membuat prediksi yang tepat untuk kelas positif dari total prediksi positif yang dilakukan. Dalam konteks klasifikasi, presisi memberikan informasi tentang seberapa sering model mampu memprediksi dengan benar kelas positif, di antara semua prediksi positif yang dihasilkan oleh model. Presisi dihitung dengan membandingkan jumlah prediksi positif yang benar (True Positive) dengan total jumlah prediksi positif (True Positive-TP dan False Positive FP). Dengan menggunakan nilai presisi, kita dapat mengevaluasi kemampuan model untuk mengidentifikasi review positif tanpa mengklasifikasikan secara keliru review negatif sebagai positif. [29]. Nilai *Precision* dapat dihitung dengan persamaan berikut:

$$Precision = \frac{TP}{TP+FP} \quad (2.3)$$

Dimana:

- True Positif (TP) didefinisikan sebagai data positif yang diprediksi sebagai positif
- False Positif (FP) didefinisikan sebagai data negatif yang diprediksi positif

- *Precision* mengukur seberapa sering model benar ketika ia mengidentifikasi objek yang positif (misalnya, objek yang ada di gambar). *Precision* dihitung dengan membagi jumlah prediksi positif yang benar (TP) dengan total prediksi positif yang dilakukan oleh model (TP + FP).

2.16 Recall

Recall adalah metrik evaluasi yang digunakan dalam statistik, pembelajaran mesin, dan tugas klasifikasi untuk mengukur sejauh mana model atau algoritma mampu mengidentifikasi semua instance yang seharusnya termasuk dalam kelas positif. Sebagai analogi, kita dapat membayangkan situasi mencari jarum di tumpukan jerami, di mana *Recall* menggambarkan seberapa baik kita menemukan semua jarum yang ada. Jika kita berhasil menemukan 6 dari 10 jarum di tumpukan jerami, itu berarti masih ada 4 jarum yang terlewatkan. Nilai *Recall* akan memberikan informasi tentang seberapa efektif model dalam mengenali dan mengklasifikasikan review positif secara akurat. Dalam konteks review film, hal ini menjadi penting karena kita ingin memahami sejauh mana model dapat mengenali review yang memberikan pujian terhadap film, sehingga kita dapat memahami respons penonton terhadap film tersebut. Keunggulan dari *Recall* adalah fokus pada mengurangi kesalahan False Negative (FN), sehingga memastikan bahwa sebanyak mungkin review positif diidentifikasi dengan benar. Walaupun *Recall* memberikan informasi yang berharga, perlu diingat bahwa parameter ini sendirian mungkin tidak mencakup evaluasi terhadap kinerja model dalam mengklasifikasikan kelas negatif. Oleh karena itu, disarankan untuk mempertimbangkan metrik evaluasi lain seperti Presisi dan F1 Score untuk mendapatkan gambaran yang lebih holistik tentang kinerja model. Nilai *recall* dapat dihitung dengan persamaan berikut:[28],[29]

$$Recall = \frac{TP}{TP+FN} \quad (2.4)$$

Dimana :

- True Positif (TP) didefinisikan sebagai data positif yang diprediksi sebagai positif
- False Negatif (FN) merupakan kebalikan dari TP yaitu data positif yang diprediksi sebagai negatif dan
- *Recall* mengukur seberapa lengkap model dalam mendeteksi objek yang ada. Dengan kata lain, *recall* memberi tahu kita seberapa banyak objek yang benar-benar ada yang dapat ditemukan oleh model.

2.17 F-Measure

F-Measure, juga dikenal sebagai *F1-Score*, adalah metrik evaluasi yang digunakan dalam statistik, pembelajaran mesin, dan bidang terkait untuk mengukur kualitas suatu model atau algoritma, terutama dalam tugas klasifikasi biner. F-Measure menggabungkan dua metrik lain, yaitu presisi (*precision*) dan *recall*, untuk memberikan gambaran holistik tentang seberapa baik suatu model dapat membedakan antara kelas positif dan negatif [28],[29]. Nilai F-measure dapat dihitung dengan persamaan berikut:

$$F1-Score = \frac{2 \cdot recall \cdot precision}{recall + precision} \quad (2.5)$$

Dimana

- *Precision*: Mengukur akurasi prediksi model. *Precision* adalah rasio antara True Positives (TP) dan jumlah total objek yang diprediksi positif, yang dihitung dengan rumus pada persamaan 2.3
- *Recall*: Mengukur seberapa baik model menangkap semua objek yang benar-benar ada. *Recall* adalah rasio antara True Positives (TP) dan jumlah total objek yang sebenarnya positif, yang dihitung dengan rumus pada persamaan 2.4

2.18 Accuracy

Akurasi adalah metrik evaluasi yang mengukur seberapa baik model membuat prediksi yang benar dari total prediksi yang dilakukan. Dalam konteks klasifikasi pada penelitian deteksi kematangan Tandan Buah Segar (TBS) kelapa sawit, akurasi memberikan gambaran mengenai seberapa sering model memprediksi kelas yang benar, baik itu kelas mentah, mengkal, maupun matang. Nilai akurasi menjawab sejauh mana model yang digunakan mampu memprediksi tingkat kematangan buah sawit secara keseluruhan dengan benar. Untuk menghitung akurasi digunakan rumus berikut: [29]

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.6)$$

Dimana:

- True Positif (TP) didefinisikan sebagai data positif yang diprediksi sebagai positif
- True Negatif (TN) didefinisikan sebagai data negatif yang di prediksi sebagai negatif.
- False Negatif (FN) merupakan kebalikan dari TP yaitu data positif yang diprediksi sebagai negatif dan
- False Positif (FP) kebalikan dari TN, yaitu data negatif yang diprediksi positif

2.19 Python

Python adalah bahasa pemrograman tingkat tinggi yang bersifat serbaguna, dibuat oleh Guido van Rossum dan diperkenalkan pada tahun 1991. Python terkenal karena sintaksnya yang simpel dan mudah dipelajari, sehingga menjadi pilihan favorit bagi pemula maupun ahli dalam bidang pemrograman [30]. Bahasa ini mendukung berbagai paradigma pemrograman, seperti pemrograman berorientasi objek, fungsional, dan prosedural, menjadikannya sangat fleksibel untuk digunakan

dalam berbagai aplikasi, termasuk pengembangan web, analisis data, kecerdasan buatan, hingga pengembangan perangkat lunak skala besar. Python juga didukung oleh komunitas yang besar dan aktif, serta memiliki pustaka standar yang kaya, memudahkan pengembang untuk menyelesaikan berbagai tugas dengan efisien[31].

2.20 Google Colaboratory

Google Colaboratory, atau sering disebut Google Colab, adalah lingkungan pemrograman online yang memungkinkan pengguna untuk menulis dan menjalankan kode Python melalui peramban web. Colab adalah layanan gratis yang disediakan oleh Google dan dirancang untuk mendukung pembelajaran mesin, penelitian data, dan pengembangan proyek berbasis Python. Dengan integrasi dengan Google Drive, Colab memungkinkan penyimpanan, manajemen, dan berbagi notebook secara efisien. Selain itu, mendukung berbagai pustaka populer seperti TensorFlow, PyTorch, dan OpenCV, yang memudahkan pengembangan aplikasi kecerdasan buatan dan analisis data. Selain itu, pengguna dapat dengan mudah mengakses sumber daya internet, menginstal pustaka tambahan, dan menyimpan atau mengunduh notebook [32].



Gambar 2. 11 *Google Colaboratory*

2.21 Roboflow

Roboflow merupakan platform web yang memiliki fungsi berhubungan dengan kumpulan *dataset*. *Roboflow* adalah kerangka kerja pengembang *computer vision* untuk pengumpulan data yang lebih baik hingga prapemrosesan, dan teknik pelatihan model. Dengan menggunakan *roboflow* dapat membagikan *dataset* sekaligus memproses *dataset* tersebut melakukan annotate atau menandai objek yang akan di deteksi menggunakan *bounding box*, selain itu dapat digunakan juga pre-processing pada *dataset* misalnya melakukan grayscale, dan juga augmentasi dengan menggunakan *roboflow*. Untuk melakukan pengujian deteksi objek diperlukan sebuah *dataset* pada tahap akuisisi data (pengumpulan data), dimana tahap tersebut merupakan sebuah tantangan bagi peneliti untuk mengumpulkan sekumpulan data citra buah sawit yang baik untuk melakukan pendeteksian objek [33].

BAB 3 METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

Adapun penelitian ini dilaksanakan di Laboratorium Telekomunikasi, Laboratorium Terpadu Jurusan Teknik Elektro, Universitas Lampung, dimulai pada bulan Januari 2025 sampai dengan bulan Mei 2025.

3.2 Alat dan Perangkat Lunak

- Hardware: Satu buah handphone Android Samsung A05, yang digunakan untuk mengambil citra tandan buah segar kelapa sawit di Pesawaran, Lampung.
- Satu laptop HP 14 Intel Celeron-N3060 yang digunakan untuk pelatihan model dan *software* untuk klasifikasi objek.
- *Software roboflow* yang digunakan untuk eksplorasi data.
- *Software* Google Colab yang digunakan untuk melatih model.
- *YOLOV8* dan *YOLOV11* yang digunakan untuk mendeteksi dan mengklasifikasi tingkat kematangan tandan buah segar kelapa sawit.

3.3 Prosedur Penelitian

Penelitian ini fokus untuk membandingkan performa algoritma YOLOv8 dan YOLOv11 dalam mengklasifikasi tingkat kematangan tandan buah segar kelapa sawit. Dengan berkembangnya teknologi deteksi berbasis visi komputer, pemilihan algoritma yang tepat menjadi krusial untuk meningkatkan akurasi dan efisiensi proses klasifikasi. Pendekatan yang digunakan adalah eksperimen komparatif, di

mana kedua algoritma akan diuji pada *dataset* yang sama untuk mengidentifikasi keunggulan masing-masing dalam aspek akurasi, presisi, kecepatan, dan efisiensi komputasi. Hasil penelitian ini diharapkan dapat memberikan rekomendasi algoritma yang optimal untuk aplikasi pada industri kelapa sawit. Berikut Merupakan sistem langkah langkah kerja sebagai berikut :

1. Studi literatur

Tahap awal pada penelitian ini adalah studi literatur. Studi literatur dilakukan untuk pencarian masalah, mencari sumber terkait dengan penelitian dan landasan teori sebagai acuan untuk melakukan penelitian. Studi literatur dilakukan dengan melakukan tinjauan literatur yang berhubungan dengan pendeteksian dan klasifikasi Tanda buah segar kelapa sawit dengan menggunakan algoritma YOLO, dengan data masukan berupa gambar. Proses pencarian literatur dilakukan dengan menggunakan Google Scholar dan ResearchGate dengan memasukan kata kunci yang sesuai. Adapun kata kunci utama yang dicari dibagi menjadi lima bagian, yaitu: a) "*object detection*", b) "*classification*", c) "*image based*", e) "*You Only Look Once (YOLO)*". Hal-hal yang menjadi kriteria dalam memilih literatur sebagai berikut:

- a. Literatur merupakan publikasi ilmiah.
- b. Literatur membahas tentang pendeteksian dan klasifikasi Tanda buah segar kelapa sawit.
- c. Literatur berasal dari publikasi ilmiah berbahasa Indonesia dan bahasa Inggris.
- d. Literatur menggunakan pendekatan image-based.

2. Pengumpulan Data Kegiatan pengumpulan data dilakukan dengan mengumpulkan data-data yang diperlukan dalam pembuatan desain program, termasuk data citra tandan buah segar kelapa sawit.

3. Pembuatan Program Pembuatan program ini bertujuan untuk mengimplementasikan hasil studi literatur dan bimbingan yang telah dilakukan, dengan menggunakan bahasa pemrograman Python. Data yang telah dikumpulkan sebelumnya akan digunakan dalam proses pelatihan dan evaluasi model YOLOv8 dan YOLOv11.

4. Pembuatan Laporan Pembuatan laporan ini melibatkan dokumentasi hasil penelitian yang telah dilakukan dan dapat dipertanggungjawabkan. Laporan penelitian terdiri dari dua bagian utama, yaitu laporan proposal untuk seminar proposal dan laporan akhir yang digunakan dalam seminar hasil dan dalam siding konprehensif.
5. Interpretasi dan Pembahasan Setelah mendapatkan model yang sesuai dengan tingkat akurasi yang tinggi, dilakukan interpretasi hasil dan pembahasan terkait efektivitas algoritma YOLOv8 dan YOLOv11 dalam mendeteksi tingkat kematangan TBS. Analisis ini mencakup perbandingan kinerja kedua algoritma dalam berbagai kondisi pencahayaan dan lingkungan, serta dampaknya terhadap efisiensi produksi CPO.
6. Kesimpulan dan saran

3.4 Dataset Penelitian

Dataset yang digunakan pada penelitian ini terdiri dari dua sumber utama, yaitu gambar yang diambil langsung dari kebun kelapa sawit di Kalirejo, Pringsewu, dan data yang diperoleh dari *software roboflow*. Pengumpulan data dilakukan dengan metode pengambilan gambar tandan buah segar kelapa sawit yang memiliki berbagai tingkat kematangan.

Lokasi pengambilan gambar dipilih secara strategis untuk mencakup variasi dalam lingkungan pertanian, yang meliputi perbedaan pencahayaan, dan latar belakang. Hal ini bertujuan untuk memastikan bahwa *dataset* yang dihasilkan dapat merepresentasikan kondisi nyata di lapangan dan meningkatkan generalisasi model yang akan dikembangkan. Dataset yang digunakan dalam penelitian ini berasal dari dua sumber utama: dataset Roboflow dan dataset lapangan.

1. Dataset Roboflow (Penuh)

Dataset ini terdiri dari 8.400 gambar TBS kelapa sawit yang telah dianotasi secara sistematis melalui platform Roboflow. Gambar-gambar tersebut mewakili tiga tingkat kematangan (mentah, mengkal, matang) dengan


kondisi pencahayaan dan latar belakang yang relatif seragam. Dataset ini digunakan pada skenario evaluasi utama untuk melihat kinerja model pada data berukuran besar dan berkualitas konsisten.

2. Dataset Lapangan

Dataset ini berjumlah 625 gambar yang diambil langsung dari kebun kelapa sawit di Kalirejo, Pringsewu. Gambar diambil dengan variasi pencahayaan, cuaca, latar belakang, dan sudut pengambilan yang berbeda. Setelah pengambilan, gambar diproses melalui platform Roboflow untuk augmentasi dan preprocessing, kemudian diberi anotasi sesuai format YOLO.

3. Subset Dataset Roboflow (625 Gambar)

Selain menggunakan dataset Roboflow penuh, penelitian ini juga mengambil subset sebanyak 625 gambar dari dataset Roboflow untuk perbandingan apple to apple dengan dataset lapangan yang jumlahnya sama. Subset ini dipilih secara acak dari keseluruhan dataset Roboflow, dengan mempertahankan proporsi kelas kematangan yang seimbang.



Gambar 3. 1 Berbagai tingkat kematangan tandan buah kelapa sawit


3.5 Perancangan program

Perancangan program dilakukan menggunakan *Google Colab* dengan bahasa pemrograman Python serta referensi dari berbagai sumber seperti GitHub, dan Youtube. Program ini berfokus pada penerapan metode YOLO untuk mendeteksi

dan mengklasifikasikan tingkat kematangan TBS berdasarkan citra yang diperoleh. YOLO akan dilatih menggunakan *dataset* gambar TBS dengan berbagai tingkat kematangan agar dapat mengenali pola visual seperti perubahan warna dan tekstur buah st. secara akurat.

3.5.1 Implementasi Metode Yolo

Alur Kerja dan Metode dalam Perancangan program menggunakan metode YOLO mengikuti *AI Project Cycle*, yaitu sebuah kerangka kerja yang terdiri dari tahapan-tahapan untuk mengembangkan sebuah proyek berbasis kecerdasan buatan (*Artificial Intelligence*). Dalam penelitian ini, digunakan metode YOLOv8 dan YOLOv11 untuk mendeteksi tingkat kematangan buah sawit. Project Cycle untuk penelitian ini di gambarkan pada gambar 3.1 dibawah ini:



Gambar 3. 2 Diagram Alir AI Project cycle untuk metode YOLOv8 dan YOLOv11

1. Problem Scoping

Langkah ini bertujuan untuk merinci masalah yang di hadapi dalam merumuskan solusi yang melibatkan kecerdasan buatan seperti yang di tujukkan pada tabel 3.2

Tabel 3. 1 Peoblem Scoping

Who?	peneliti yang melakukan penelitian ini. Target penerapannya adalah petani kelapa sawit, industri pengolahan sawit, dan peneliti di bidang AI.
What?	Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi tingkat kematangan tandan buah segar (TBS) kelapa sawit menggunakan algoritma YOLOv8 dan YOLOv11. Sistem ini membantu dalam klasifikasi kematangan buah sawit secara otomatis berdasarkan citra visual, guna meningkatkan efisiensi dan akurasi panen
Where?	Lab Telekomunikasi dan Perkebunan Sawit di Kalirejo Pringsewu
Why?	Mengingat pentingnya kematangan buah sawit dalam menentukan kualitas minyak yang dihasilkan, maka dikembangkanlah sistem deteksi otomatis yang dapat membantu petani dan industri kelapa sawit. Program ini bertujuan untuk mengurangi subjektivitas dalam penilaian kematangan buah sawit, meningkatkan efisiensi panen, serta mendukung optimalisasi produksi minyak sawit berkualitas tinggi.


2. Data Acquisition

Proses pengumpulan *dataset* gambar Tandan buah segar kelapa sawit dilakukan pada website *roboflow* dengan memanfaatkan *Application Programming Interface* (API) menggunakan *Google Colaboratory*.

3. Data Exploration


Proses ini dilakukan untuk mengolah *dataset* yang telah terkumpul. Pengolahan foto dilakukan agar format setiap foto sesuai dengan prasyarat algoritma

pendeteksian yang dibuat. Alur kerja pada data exploration dapat dilihat pada Gambar 3.1.



Gambar 3. 3 Diagram alir data exploration

Pada Gambar 3.3 tahap data exploration akan dilakukan proses pelabelan dan anotasi dengan software *roboflow*. Pelabelan data dilakukan untuk memberikan nama atau label dari objek yang dianotasi. Anotasi data dilakukan untuk memberikan kotak penanda pada objek di suatu gambar yang biasa disebut dengan *bounding box* seperti pada Gambar 3.4.



Gambar 3. 4 Labeling Object

Setelah proses pelabelan selesai dilakukan, *dataset* 8400 gambar dibagi menjadi tiga bagian dengan rasio 80% untuk data *train*, 13% untuk data *validation*, dan 7% untuk data *test*. Total data dalam masing-masing set adalah 6736 gambar untuk

train set, 1118 gambar untuk *validation set*, dan 546 gambar untuk *test set*. Lalu pada *dataset* 625 gambar baik dataset subset roboflow atau dataset perkebunan ini semua sama yang di bagi yaitu Train set: 557 gambar (89%), *Validation set*: 51 gambar (8%), dan Test set: 17 gambar (3%). Tahapan selanjutnya dalam eksplorasi data adalah *preprocessing* dan augmentasi data menggunakan software *roboflow*. Detail *preprocessing* data dan augmentasi data yang digunakan dapat dilihat pada Gambar 3.5

Preprocessing	Auto-Orient: Applied Resize: Stretch to 640x640
Augmentations	Outputs per training example: 2 Flip: Horizontal, Vertical


Gambar 3. 5 Rincian preprocessing dan augmentasi data

Pada Gambar 3.5 Tahap *preprocessing* data dilakukan untuk memastikan konsistensi selama proses pelatihan dan inferensi model. Auto-Orient diterapkan untuk menghapus informasi EXIF dari gambar, sehingga orientasi gambar konsisten dengan cara penyimpanan di disk. Selanjutnya, gambar diubah ukurannya menjadi resolusi 640 x 640 piksel, menyesuaikan dengan kebutuhan pretrained model YOLO yang dilatih menggunakan resolusi tersebut, serta mempertimbangkan efisiensi pelatihan model. Proses augmentasi data dilakukan dengan menghasilkan tiga keluaran per contoh pelatihan melalui teknik *flip* secara horizontal, yang bertujuan meningkatkan keragaman data dan kemampuan generalisasi model. Selain itu, data tanpa objek (*null objects*) difilter agar tidak memengaruhi hasil pelatihan model.

4. Modeling

Pada tahap ini, *dataset* yang telah disiapkan akan digunakan untuk melatih model deteksi tingkat kematangan buah sawit. Proses pelatihan dilakukan dengan memanfaatkan pretrained model YOLOv8 dan YOLOv11. Penggunaan pretrained model ini bertujuan untuk mempercepat proses pelatihan dan meningkatkan performa model dalam mendeteksi tingkat kematangan. Seluruh proses pelatihan

model dilakukan menggunakan platform Google Colab untuk memanfaatkan sumber daya komputasi yang memadai. Selama pelatihan, beberapa konfigurasi penting akan diatur, seperti ukuran gambar, *batch size*, dan jumlah *epoch*. Konfigurasi ini akan disesuaikan melalui pendekatan *trial and error* hingga ditemukan kombinasi yang menghasilkan akurasi tinggi. Evaluasi model akan dilakukan menggunakan metrik-metrik kinerja seperti *F1-Score*, *Precision*, *Recall*, *Mean Average Precision* (mAP), *Loss*, dan *Accuracy*. Hasil evaluasi ini akan digunakan untuk menilai efektivitas model dalam mendeteksi tingkat kematangan buah sawit serta memberikan wawasan untuk perbaikan lebih lanjut berikut merupakan alur dari proses modeling yang akan di lakukan.



Gambar 3. 6 Alur proses tahap modeling

5. Evaluasi

Tahap evaluation dilakukan proses pemilihan model yang akan digunakan untuk hasil akhir. *Dataset* pengujian nantinya digunakan untuk menguji model deteksi tingkat kematangan buah sawit yang telah dilatih sebelumnya, yaitu YOLOv8 dan YOLOv11. Untuk mengevaluasi kinerja model deteksi tingkat kematangan buah sawit yang telah dilatih, digunakan beberapa metrik evaluasi utama. Metrik-metrik ini mencakup *Mean Average Precision* (mAP), *F1-Score*, presisi, *recall*, dan *accuracy*. Evaluasi ini bertujuan untuk memahami sejauh mana model dapat secara akurat mendeteksi tingkat kematangan buah sawit. Metriks yang digunakan untuk mengevaluasi model adalah *accuracy*, *precision*, *recall* dan *F1-Score*. Untuk memahami metriks yang digunakan, sebelumnya akan didefinisikan terlebih dahulu true positive (TP), false positive (FP), false negative (FN) dan true negative (TN) seperti yang ditunjukkan pada confusion matrix gambar 3.7. TP didefinisikan sebagai data positif yang diprediksi sebagai positif dan TN didefinisikan sebagai data negatif yang di prediksi sebagai negatif. Sedangkan FN merupakan kebalikan dari TP yaitu data positif yang diprediksi sebagai negatif dan FP, kebalikan dari TN, yaitu data negatif yang diprediksi positif

		Predicted Values	
		Positive	Negative
Actual Values	Positive	TP	FN
	Negative	FP	TN

Gambar Gambar 3. 7 confusion matrix

6. pengujian *dataset*

Pada tahap ini, *dataset* pengujian digunakan untuk menguji model deteksi tingkat kematangan buah sawit yang telah dilatih sebelumnya, yaitu YOLOv8 dan YOLOv11. Pengujian ini bertujuan untuk mengukur kemampuan kedua model dalam mendeteksi tingkat kematangan buah sawit, dengan mengevaluasi parameter seperti presisi, *recall*, dan akurasi. Setelah membandingkan kinerja YOLOv8 dan YOLOv11 pada *dataset* buah sawit, Pengujian pada *dataset* tambahan ini bertujuan untuk mengevaluasi kemampuan generalisasi model serta potensi penerapannya dalam berbagai konteks, termasuk mendeteksi objek dengan karakteristik yang berbeda.

7. Analisis dan Pembahasan

Setelah proses deteksi selesai, hasil prediksi tingkat kematangan buah sawit dari YOLOv8 dan YOLOv11 akan dibandingkan dengan data label yang sebenarnya. Data tersebut akan diolah untuk menghitung tingkat kesalahan dan performa model dalam mengklasifikasikan tingkat kematangan. Analisis ini akan membantu mengidentifikasi populasi buah sawit yang terdeteksi dalam penelitian serta mengukur keefektifan kedua model dalam aplikasi praktis.

BAB 5 KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai evaluasi algoritma YOLOv8 dan YOLOv11 dalam klasifikasi tingkat kematangan tandan buah segar (TBS) kelapa sawit, maka dapat disimpulkan hal-hal berikut:

1. Performa Model YOLOv8 dan YOLOv11

YOLOv8 secara umum menunjukkan performa yang lebih stabil dan seimbang dibanding YOLOv11 di berbagai skenario. Model YOLOv8s menjadi pilihan utama karena konsisten memiliki kombinasi akurasi tinggi (87,8%), F1-score (90,7%), mAP (94,8%), dan kecepatan inferensi yang kompetitif (1.123 FPS).

2. Pengaruh Variasi Dataset

Dataset Roboflow 8.400 gambar menghasilkan performa model lebih tinggi dibanding dataset lapangan 625 gambar karena jumlah data yang besar, kualitas citra seragam, dan anotasi yang rapih. Pada dataset besar ini, YOLOv8s menjadi yang terbaik dengan precision 90,5%, recall 90,8%, dan mAP 94,8%.

3. Perbandingan Jumlah Data Sama (625 gambar)

Ketika jumlah data disamakan, subset Roboflow unggul pada mAP (95,2%) dan precision (94,3%), sedangkan dataset lapangan unggul pada recall (87,6%), akurasi (78,1%), dan kecepatan inferensi (1.079 FPS). Hal ini menunjukkan bahwa meskipun kualitas gambar lapangan lebih bervariasi, model mampu beradaptasi lebih baik pada kondisi nyata.

4. Kelebihan Model di Kondisi Tertentu

YOLOv8m unggul dalam presisi dan mAP pada subset Roboflow (94,3% precision, 95,2% mAP) serta recall tinggi di dataset lapangan (87,6%). YOLOv11s unggul pada kondisi spesifik di dataset lapangan dengan mAP 92,1% dan recall 88,1%, namun performanya kurang konsisten dibanding YOLOv8.

5. Rekomendasi Model

Dengan mempertimbangkan keseimbangan performa di berbagai kondisi, YOLOv8s direkomendasikan sebagai model terbaik untuk implementasi karena konsistensi dan keseimbangannya. YOLOv8m atau YOLOv11s dapat dipilih jika prioritas utama adalah presisi tinggi atau cakupan deteksi pada kondisi tertentu.

5.2 Saran

Adapun saran dari hasil penelitian ini adalah sebagai berikut:

1. Pengumpulan Data yang Lebih Luas Gunakan *dataset* yang lebih besar, bervariasi, dan berasal dari berbagai lokasi serta kondisi lingkungan untuk meningkatkan kemampuan generalisasi model.
2. Integrasi ke Sistem Lapangan Rancang dan bangun sistem berbasis mobile atau edge computing agar hasil deteksi dapat dimanfaatkan langsung oleh petani secara *real-time*.
3. Validasi Lapangan Uji model langsung di lingkungan perkebunan untuk mengetahui efektivitas sistem dalam kondisi sebenarnya dan menyesuaikan dengan kebutuhan pengguna aiykhir.

DAFTAR PUSTAKA

- [1] M. Rifqi, M. Akbar, and Y. Fitrisia, "Aplikasi Pendeteksian Kematangan Tandan Buah Segar (TBS) Kelapa Sawit Berdasarkan Komposisi Warna Menggunakan Algoritma K-NN," *J. Komput. Terapan*, vol. 6, no. 1, Mei 2020, halaman 99–107. e-ISSN:2460-5255p-ISSN:2443-4159.
- [2] M. Hudori, "Pengkuran Kinerja Kualitas Tandan Buah Segar (TBS) Kelapa Sawit Sebagai Bahan Baku Pabrik Kelapa Sawit (PKS)," *J. Tek. Industri*, vol. 7, pp. 4–10, 2018, doi: 10.53912/iejm.v7i2.338. Nomer Isbn: Issn 2302-934x, E-Issn 2614-2910 DOI: [10.53912/iejm.V7i2.338](https://doi.org/10.53912/iejm.V7i2.338)
- [3] H. A. Hasibuan, "Penentuan Hasil, Kualitas dan Komposisi Kimia Minyak Kelapa Sawit dan Minyak Inti Sawit Tandan Buah Segar dengan Kematangan Variasi Sebagai Dasar Penentuan Standar Kematangan Panen," *J. Penelit. Kelapa Sawit*, vol. 28, no. 3, pp. 123–132, 2020.
- [4] Alfarizi D. N., Pangestu R. A., Aditya D., Setiawan M. A., Rosyani P. "Penggunaan Metode YOLO Pada Deteksi Objek: Sebuah Tinjauan Literatur Sistematis." *Jurnal AI dan SPK: Jurnal Artificial Intelligence dan Sistem Penunjang Keputusan*, Vol. 1, 2023, Hal. 54–63. ISSN:9999-9999
- [5] R. Kurniawan, A. T. Martadinata, and S. D. Cahyo, "Klasifikasi Tingkat Kematangan Buah Sawit Berbasis Deep Learning dengan Menggunakan Arsitektur YOLOv5," *J. Inf. Syst. Res. (JOSH)*, vol. 5, no. 1, pp. 302–309, 2023. ISSN: 2686-228X, DOI: [10.47065/josh.v5i1.4408](https://doi.org/10.47065/josh.v5i1.4408)
- [6] I. Bonet, M. Gongora, F. Acevedo, and I. Ochoa, "Deep Learning Model to Predict the Ripeness of Oil Palm Fruit," in *Proc. 16th Int. Conf. Agents Artif. Intell. (ICAART 2024)*, vol. 3, pp. 1068–1075, 2024. ISSN: 2184433X, DOI: [10.5220/0012434600003636](https://doi.org/10.5220/0012434600003636).
- [7] Rifqi, M. 'Deteksi Kematangan Tandan Buah Segar (Tbs) Kelapa Sawit Berdasarkan Komposisi Warna Menggunakan Deep Learning', *Jurnal Teknik Informatika*, Vol. 14, No. 2, 2021. DOI: [10.15408/Jti.V14i2.23295](https://doi.org/10.15408/Jti.V14i2.23295).
- [8] Ashari, S., Yanris, G. J., & Purnama, I. (2022). *Oil Palm Fruit Ripeness Detection using Deep Learning*. Sinkron: Jurnal dan Penelitian Teknik

Informatika, Vol. 6, No. 2, April 2022. e-ISSN: 2541-2019, p-ISSN: 2541044X, DOI: [10.33395/sinkron.v7i2.11420](https://doi.org/10.33395/sinkron.v7i2.11420).

- [9] G. T. H. Tzuan *et al.*, "Oil palm fruits ripeness classification based on the characteristics of protein, lipid, carotene, and guanine/cytosine from the Raman spectra," *Plants*, vol. 11, no. 15, Aug. 2022, DOI: 10.3390/Plants11151936
- [10] M. Nasamsir and M. Indrayadi, "Karakteristik Fisik dan Produksi Kelapa Sawit (*Elaeis guineensis* Jacq.) pada Tiga Agroekologi Lahan," *J. Media Pertanian*, vol. 1, no. 2, pp. 55–61, 2016. ISSN: 2503-1279.
- [11] Sulardi, *Budidaya Tanaman Kelapa Sawit: Buku Ajar*, Jakarta: PT Dewangga Energi Internasional, 2022. ISBN: 978-623-5927-23-7.
- [12] Y. R. Silitonga, R. Heryanto, N. Taufik, K. Indrayana, M. Nas, and N. Kusriani, *Budidaya Kelapa Sawit & Varietas Kelapa Sawit*, Sulawesi Barat: Balai Pengkajian Teknologi Pertanian Sulawesi Barat, Badan Penelitian dan Pengembangan Pertanian, Kementerian Pertanian, 2020.
- [13] Bisolusi, "FFB grading using computer vision", [Online]. Available: <https://www.bisolusi.com/id/ffb-grading-using-computer-vision>. [Accessed: Jul. 29, 2025].
- [14] A. K. E. Lapien, S. R. U. A. Sompie, and P. D. K. Manembu, "Implementasi Framework *You Only Look Once* Untuk Klasifikasi Pola Tanda Tangan," *J. Tek. Inform.*, vol. 16, no. 3, pp. 337–346, 2021. P-ISSN: 2301-8364, E-ISSN: 2685-6131, DOI: <https://doi.org/10.47111/Jti>
- [15] Pareto, "YOLO object detection: You only look once explained," *Pareto AI*, [Online]. Available: <https://pareto.ai/blog/yolo-object-detection>. [Accessed: Jul. 29, 2025].
- [16] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 779–788. *arXiv*, 2016. DOI: <https://doi.org/10.48550/arXiv.1506.02640>.
- [17] A. Choudhary, A. Verma, A. Patidar, and S. Tyagi, "Object Detection using YOLO Algorithm," *International Journal for Research in Applied Science and Engineering Technology (IJRASET)*, vol. 10, no. 4, pp. 1641–1645, Apr. 2022. doi: [10.22214/ijraset.2022.44530](https://doi.org/10.22214/ijraset.2022.44530).
- [18] R. A. H. Rahman, A. A. Sunarto, and Asriyanik, "Penerapan YOLOv8 untuk Deteksi Tingkat Kematangan Buah Manggis," *JATI*, vol. 8, no. 5, 2024.
- [19] Bonitalia and E. Alfonsius, "Pengembangan sistem identifikasi penyakit tanaman anggur berdasarkan citra daun menggunakan algoritma YOLOv8,"

- J. Inf. Syst. Res. (JOSH)*, vol. 6, no. 2, pp. 789–800, Jan. 2025, [Online]. Available: <https://doi.org/10.47065/josh.v6i2.6235>
- [20] N. M. Yasen, S. Rifka, R. Vitria, and Yulindon, "Pemanfaatan YOLO untuk deteksi hama dan penyakit pada daun cabai menggunakan metode deep learning," *Elektron: J. Ilmiah*, vol. 15, no. 2, pp. 63–71, Dec. 2023, DOI: <https://doi.org/10.30630/eji.0.0.397>
- [21] X. Zhai, Z. Huang, T. Li, H. Liu, and S. Wang, "YOLO-Drone: An Optimized YOLOv8 Network for Tiny UAV Object Detection," *Electronics*, vol. 12, 3664, 2023, e-ISSN: 2079-9292. DOI: [10.3390/electronics12173664](https://doi.org/10.3390/electronics12173664).
- [22] *YOLOv8.org*, "YOLOv8 Architecture," [Online]. Available: <https://yolov8.org/yolov8-architecture/>. [Accessed: Mar. 5, 2025].
- [23] Indyalenawala, "YOLOv8 Architecture: A Detailed Overview," *Medium*, [Online]. Available: <https://medium.com/@vindyalenawala/yolov8-architecture-a-detailedoverview-5e2c371cf82a>. [Accessed: Mar. 5, 2025].
- [24] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," *arXiv preprint*, vol. 2410, pp. 1–9, 2024, DOI: [10.48550/arXiv.2410.17725](https://doi.org/10.48550/arXiv.2410.17725).
- [25] L. He, Y. Zhou, L. Liu, And J. Ma, 'Research And Application Of YOLOv11Based Object Segmentation In Intelligent Recognition At Construction Site', *Buildings*, Vol. 14, No. 12, Dec. 2024, DOI: [10.3390/Buildings14123777](https://doi.org/10.3390/Buildings14123777).
- [26] Ultralytics, "YOLOv11 vs. YOLOv8 Detail Comparison," [Online]. Available: <https://docs.ultralytics.com/compare/yolo11-vs-yolov8/>. [Accessed: Mar. 5, 2025].
- [27] H. Hannifah, "AI Project Cycle," *Medium*, [Online]. Available: <https://medium.com/@hannnfh/ai-project-cycle-ccd67c3dd21d>. [Accessed: Jul. 15, 2025].
- [28] D. M. W. Powers, "Evaluation: From *Precision*, *Recall* and F-Measure to ROC, Informedness, Markedness & Correlation," *J. Mach. Learn. Technol.*, vol. 2, no. 1, pp. 37–63, 2011, ISSN: 2229-3981, 2229-399X DOI: [10.9735/2229-3981](https://doi.org/10.9735/2229-3981)
- [29] Rey, "Mengenal *Accuracy*, *Precision*, *Recall*, dan Specificity serta yang Diprioritaskan," *Medium*. [Online]. Available: <https://rey1024.medium.com/mengenal-accuracy-precision-recall-dan-specificity-septa-yang-diprioritaskan-b79ff4d77de8>
- [30] M. R. S. Alfarizi *et al.*, "Penggunaan Python sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning," *Karimah Tauhid*, vol. 2, no. 1, 2023, e-ISSN: 2963-590X. DOI: [10.29407/ja.v6i2.16018](https://doi.org/10.29407/ja.v6i2.16018).

- [31] I. Setiawan, "Komparasi Kinerja Integrated Development Environment (IDE) Dalam Mengeksekusi Perintah Python," *SATESI*, vol. 2, no. 1, pp. 52–59, 2022 ISSN: 2807–8152. DOI: [10.54259/satesi.v2i1.784](https://doi.org/10.54259/satesi.v2i1.784).
- [32] P. Kanani, "Deep Learning to Detect Skin Cancer using Google Colab," *Int. J. Eng. Adv. Technol. (IJEAT)*, vol. 8, no. 6, p. 2176, 2019, ISSN: 2249-8958. DOI: [10.35940/ijeat.F8587.088619](https://doi.org/10.35940/ijeat.F8587.088619)
- [33] *Roboflow*, "Roboflow: Give your software the eyes it needs." [Online]. Available: <https://roboflow.com/>. [Accessed: Jul. 26, 2025].