

BAB I

PENDAHULUAN

1.1. Latar Belakang

Dalam pertanian, kelapa sawit (*Elaeis guineensis*) diakui karena produktivitasnya sebagai penghasil minyak nabati. Kualitas minyak kelapa sawit sangat dipengaruhi oleh tingkat kematangan buah, di mana perbedaan tingkat kematangan akan menghasilkan jenis minyak yang berbeda [1]. Karakteristik kematangan kelapa sawit meliputi buah berwarna ungu kehitaman untuk Tandan Buah Segar (TBS) yang belum matang, buah berwarna merah dengan sedikit brondolan untuk TBS setengah matang (mengkal), serta buah berwarna merah atau oranye untuk TBS matang. Sebagai negara beriklim tropis, Indonesia memiliki keunggulan komparatif dalam pengembangan komoditas kelapa sawit yang didukung oleh ketersediaan lahan yang luas dan sumber daya manusia yang melimpah. Kondisi ini menjadikan Indonesia sebagai salah satu produsen sekaligus eksportir minyak kelapa sawit terbesar di dunia [2]. Berdasarkan Satu Data Pertanian pada sisi produksi, luas area perkebunan kelapa sawit pada tahun 2024 diperkirakan mencapai 16,83 juta hektare dengan produksi sebesar 47,47 juta ton. Skala produksi tersebut memperkuat posisi Indonesia sebagai produsen minyak sawit (CPO) terbesar di dunia, bahkan melampaui Malaysia. Kontribusi subsektor perkebunan yang didominasi kelapa sawit juga mencapai 93,24% dari total nilai ekspor sektor pertanian, sehingga menjadikannya sebagai sumber devisa utama negara [3].

Namun demikian, di balik besarnya kontribusi tersebut, proses penentuan tingkat kematangan Tandan Buah Segar (TBS) di lapangan masih belum optimal. Berdasarkan pengalaman penulis selama kegiatan magang di mitra industri (mitra X), proses penentuan kematangan TBS masih dilakukan secara manual oleh pekerja panen dengan mengandalkan pengamatan visual terhadap warna buah dan jumlah brondolan yang jatuh. Dalam praktiknya, metode ini seringkali menimbulkan ketidakkonsistenan antar pekerja akibat variasi sudut pandang dan kondisi lingkungan saat pengamatan. Selain itu, ditemukan bahwa beberapa TBS yang

dipanen masih berada pada kategori belum matang atau setengah matang, yang mengindikasikan adanya ketidaktepatan dalam proses identifikasi kematangan.

Lebih lanjut, berdasarkan diskusi dengan pihak operasional di Mitra X, ketidaktepatan dalam penentuan kematangan TBS berdampak pada penurunan kualitas minyak yang dihasilkan serta potensi penurunan rendemen. Temuan ini sejalan dengan kajian ilmiah yang melaporkan bahwa perbedaan tingkat kematangan TBS dapat memengaruhi rendemen minyak, dengan variasi penurunan yang berkisar sekitar $\pm 1-5\%$ dibandingkan kondisi optimal, tergantung pada komposisi buah serta kondisi proses pengolahan di pabrik [4]. Selain itu, buah yang terlalu matang juga dapat meningkatkan kadar asam lemak bebas (*Free Fatty Acid/FFA*) yang berdampak menurunkan kualitas minyak kelapa sawit. Peningkatan FFA ini terjadi akibat proses hidrolisis trigliserida yang semakin tinggi pada buah yang terlalu matang atau mengalami keterlambatan pengolahan. Beberapa penelitian menunjukkan bahwa kadar FFA pada buah yang tidak ditangani dengan baik dapat meningkat melebihi batas standar kualitas minyak sawit mentah (CPO) yang umumnya berada di bawah 3–5% [5]. Kondisi ini menyebabkan penurunan mutu minyak serta berdampak pada peningkatan biaya operasional, serta berpotensi adanya penurunan harga jual produk di pasar karena kadar FFA merupakan parameter utama dalam penentuan mutu dan harga CPO.

Oleh karena itu, diperlukan suatu pendekatan yang lebih objektif dan akurat dalam menentukan tingkat kematangan TBS. Pendekatan konvensional seperti penggunaan sensor atau metode berbasis aturan memiliki keterbatasan dalam menghadapi variasi kondisi lapangan, seperti perubahan pencahayaan dan kompleksitas latar belakang [6]. Dengan demikian, pendekatan berbasis pembelajaran mendalam (*deep learning*) menjadi lebih relevan karena mampu mengekstraksi fitur secara otomatis dan adaptif dari data citra [7].

Dalam konteks kelapa sawit, di mana dalam satu citra dapat terdapat banyak buah dengan tingkat kematangan yang berbeda serta posisi yang saling tumpang tindih, kemampuan untuk melakukan deteksi sekaligus lokalisasi objek menjadi penting. Dalam analisis citra pertanian, terdapat beberapa pendekatan yang umum digunakan untuk deteksi objek, seperti *Faster R-CNN* dan *Single Shot Detector*

(SSD), yang umumnya memanfaatkan *Convolutional Neural Network* (CNN) sebagai *backbone* dalam proses ekstraksi fitur. Namun, CNN berbasis klasifikasi hanya mampu menentukan kelas gambar secara keseluruhan tanpa mengetahui lokasi objek, sehingga kurang sesuai untuk kasus di mana dalam satu citra terdapat banyak buah dengan tingkat kematangan berbeda [8]. Sementara itu, *Faster R-CNN* memiliki tingkat akurasi yang tinggi, tetapi memiliki kompleksitas komputasi yang besar dan kecepatan inferensi yang relatif lambat sehingga kurang optimal untuk implementasi di lapangan [9]. Disisi lain, SSD menawarkan kecepatan yang lebih baik dibandingkan *Faster R-CNN*, namun pada beberapa studi menunjukkan bahwa akurasinya cenderung lebih rendah, terutama dalam mendeteksi objek berukuran kecil atau objek yang saling tumpang tindih [10].

Untuk mengatasi keterbatasan tersebut, diperlukan suatu pendekatan deteksi objek yang mampu menyeimbangkan antara akurasi dan efisiensi komputasi. Salah satu metode yang digunakan adalah *You Only Look Once* (YOLO), yang merupakan pendekatan deteksi satu tahap (*single-stage detector*). YOLO mampu melakukan proses deteksi dan lokalisasi objek secara bersama dalam satu kali proses (*forward pass*), sehingga lebih efisien dibandingkan metode dua tahap dalam hal kompleksitas komputasi [11]. Selain itu, YOLO memiliki kemampuan yang baik dalam mendeteksi banyak objek dalam satu citra, sehingga sesuai dengan karakteristik citra kelapa sawit yang mengandung banyak buah dengan tingkat kematangan yang berbeda. Namun demikian, YOLO memiliki keterbatasan dalam mendeteksi objek berukuran kecil atau objek yang saling tumpang tindih secara kompleks, sehingga performanya sangat bergantung pada kualitas data dan konfigurasi model yang digunakan.

Dengan adanya perkembangan arsitektur YOLO terus mengalami penyempurnaan untuk mengatasi berbagai keterbatasan tersebut. Salah satu versi terbaru yaitu YOLOv12, YOLOv12 merupakan pengembangan lanjutan dari arsitektur YOLO yang menghadirkan peningkatan pada mekanisme ekstraksi fitur melalui penerapan *attention mechanism* dan R-ELAN (*Residual Efficient Layer Aggregation Network*). Meskipun secara teoretis peningkatan ini berpotensi meningkatkan kemampuan representasi fitur, namun performa aktual model sangat

bergantung pada karakteristik dataset, seperti halnya pada penelitian Sapkota dkk. (2026) bertujuan mengevaluasi berbagai model YOLO untuk deteksi dan penghitungan buah apel hijau dalam kondisi kebun yang kompleks. Metode yang digunakan adalah perbandingan beberapa model YOLO seperti YOLOv8, YOLOv9, YOLOv10, YOLOv11, dan YOLOv12 dengan total 26 konfigurasi model menggunakan dataset buah apel dari kamera iPhone 14 Pro Max dan Intel RealSense. Hasil penelitian menunjukkan YOLOv10x memiliki presisi tertinggi (0,908), YOLOv12l memiliki recall tertinggi (0,900), serta YOLOv9 mencapai mAP@50 sebesar 0,935. Kelemahan penelitian ini adalah adanya variasi performa antar model pada kondisi lapangan yang kompleks, trade-off antara akurasi dan jumlah parameter, serta keterbatasan dataset [12] dan pada penelitian lain yang dilakukan C. Bakir and A. Gezer (2025) bertujuan mendeteksi dan mengklasifikasikan defisiensi nutrisi pada daun selada untuk mendukung *smart agriculture*. Metode yang digunakan adalah YOLOv12 dengan *Hybrid Task Learning (HTL)* dan *feature fusion* untuk meningkatkan deteksi objek kecil, serta menggunakan *transfer learning* dan *data augmentation*. Hasil penelitian menunjukkan mAP50 mencapai 98,6% Kelemahan penelitian ini adalah dataset hanya terbatas pada tanaman selada sehingga belum diuji pada jenis tanaman lain seperti tomat atau cabai [13].

Di sisi lain, YOLOv8 sebagai model yang lebih stabil dan telah banyak digunakan dengan menunjukkan performa yang cukup baik dalam berbagai penelitian, khususnya dalam hal akurasi deteksi dan efisiensi komputasi, namun beberapa penelitian menunjukkan bahwa model ini masih memiliki keterbatasan seperti pada penelitian terdahulu terkait deteksi kematangan kelapa sawit dengan model YOLOv8 telah dilakukan oleh Z. Genoveva and R. D. Syah (2024). Tujuan penelitian ini adalah menggunakan teknologi pembelajaran mesin berbasis YOLOv8 untuk mendeteksi tingkat kematangan Tandan Buah Segar (FFB) kelapa sawit dengan proses yang lebih cepat dan efisien. Metode yang digunakan adalah model YOLOv8 untuk deteksi objek kematangan kelapa sawit berbasis citra digital. Hasil penelitian menunjukkan bahwa penerapan YOLOv8 mampu mendeteksi berbagai kategori objek dengan cukup baik, namun masih ditemukan beberapa

kesalahan seperti posisi bounding box yang kurang tepat. Selain itu, performa model juga dipengaruhi oleh faktor eksternal seperti sudut pengambilan gambar, pencahayaan, tingkat kematangan, serta kualitas data pelatihan. Kelemahan penelitian ini adalah masih adanya kesalahan deteksi serta sensitivitas model terhadap kondisi lingkungan dan kualitas dataset [14].

Penelitian lain dilakukan oleh Josdaan dkk. (2024). Tujuan penelitian ini adalah mengembangkan sistem klasifikasi kematangan buah kelapa sawit secara otomatis untuk meningkatkan akurasi dan efisiensi dibandingkan metode manual. Metode yang digunakan adalah *deep learning* berbasis YOLOv8 dengan beberapa varian model (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x), serta dilakukan tahapan praproses data berupa standardisasi, normalisasi, dan augmentasi data. Hasil penelitian menunjukkan bahwa YOLOv8m memberikan performa optimal dengan top-1 *accuracy* 0,9885 dan top-5 *accuracy* 0,998 serta efisiensi komputasi yang baik dibandingkan varian lainnya. Secara umum YOLOv8 lebih unggul dibandingkan metode sebelumnya seperti CNN, ANN, dan YOLO generasi lama. Kelemahan penelitian ini adalah belum adanya pembahasan mendalam terkait keterbatasan metodologi serta kurangnya pengujian pada kondisi lapangan yang kompleks seperti variasi pencahayaan, sudut pandang [15].

Pada penelitian lain yang dilakukan oleh Zayani dkk. (2024) bertujuan untuk mengembangkan sistem deteksi penyakit pada buah tomat berbasis *deep learning* guna meningkatkan kualitas hasil pertanian. Metode yang digunakan adalah model YOLOv8 dengan dataset dari Roboflow yang terdiri dari tiga jenis penyakit tomat. Hasil penelitian menunjukkan akurasi sebesar 66,67%, dengan performa berbeda pada tiap kelas penyakit, di mana sebagian kelas memiliki *recall* tinggi namun kelas lain sulit dibedakan karena kemiripan visual. Kelemahan penelitian ini adalah adanya ketidakseimbangan dataset dan perbedaan performa antar kelas yang cukup signifikan, sehingga beberapa penyakit tidak terdeteksi secara optimal [16].

Berdasarkan tinjauan tersebut, dapat disimpulkan bahwa meskipun YOLOv8 telah banyak digunakan dan menunjukkan performa yang baik, serta YOLOv12 menawarkan peningkatan arsitektural, masih terdapat keterbatasan

dalam hal validasi pada domain spesifik kelapa sawit dengan kondisi lapangan nyata. Selain itu, implementasi sistem deteksi ke dalam platform yang dapat digunakan secara praktis oleh pengguna lapangan juga masih belum banyak dikembangkan.

Oleh karena itu, penelitian ini bertujuan untuk menganalisis dan membandingkan performa YOLOv8 dan YOLOv12 dalam deteksi kematangan buah kelapa sawit menggunakan dataset yang merepresentasikan kondisi lapangan nyata pada Mitra X. Evaluasi dilakukan menggunakan metrik *mean Average Precision (mAP)*, *confusion matrix*, serta waktu inferensi untuk menilai akurasi dan efisiensi model. Selain itu, penelitian ini juga mengimplementasikan sistem deteksi berbasis web menggunakan Streamlit sebagai bentuk penerapan praktis hasil penelitian dalam mendukung proses identifikasi kematangan buah kelapa sawit di lingkungan perkebunan.

1.2. Rumusan Masalah

Berdasarkan uraian pada bagian latar belakang, maka perumusan masalah dalam penelitian ini dapat disajikan sebagai berikut:

1. Bagaimana model YOLOv8 dan YOLOv12 diterapkan untuk mendeteksi tingkat kematangan buah kelapa sawit?
2. Bagaimana hasil evaluasi performa model deteksi yang optimal berdasarkan metrik evaluasi seperti mAP, *Confusion matrix*, dan *inference time*?
3. Bagaimana mengintegrasikan model deteksi yang optimal ke dalam antarmuka aplikasi berbasis GUI menggunakan Streamlit?

1.3. Batasan Masalah

Penelitian tetap terarah dan fokus, maka terdapat beberapa batasan masalah sebagai berikut:

1. Penelitian ini difokuskan pada deteksi tingkat kematangan buah kelapa sawit berdasarkan citra digital tanpa mempertimbangkan faktor lain seperti jenis penyakit, ukuran buah, atau kondisi lingkungan.

2. Hingga saat ini, belum terdapat studi yang secara khusus mengimplementasikan model YOLOv12 untuk mendeteksi tingkat kematangan buah kelapa sawit.
3. Pengujian model dilakukan menggunakan dataset gambar kelapa sawit yang telah diberi label secara manual pada platform Roboflow
4. Evaluasi performa model dilakukan berdasarkan metrik akurasi (mAP) dan efisiensi komputasi yang diukur melalui nilai *inference time* (waktu inferensi).

1.4. Tujuan Penelitian

Berdasarkan latar belakang dan rumusan masalah penelitian ini dirumuskan tujuan sebagai berikut:

1. Menerapkan dan melatih model YOLOv8 dan YOLOv12 untuk mendeteksi tingkat kematangan buah kelapa sawit secara otomatis.
2. Membandingkan kedua model tersebut berdasarkan akurasi, waktu inferensi (*inference time*), dan efisiensi komputasi guna menentukan model yang paling optimal untuk diterapkan pada sistem deteksi kematangan buah kelapa sawit di lingkungan industri.
3. Merancang dan mengimplementasikan antarmuka pengguna (*user interface*) berbasis Streamlit yang mendukung visualisasi hasil deteksi buah kelapa sawit secara interaktif dan mudah digunakan.

1.5. Manfaat Penelitian

Adapun beberapa manfaat dari penelitian ini, hasil penelitian mendeteksi buah kelapa sawit adalah:

1. Bagi bidang keilmuan
Memberikan kontribusi dalam pengembangan ilmu *computer vision* dan *deep learning*, khususnya pada penerapan model deteksi objek berbasis YOLO (YOLOv8 dan YOLOv12) untuk deteksi tingkat kematangan buah kelapa sawit.
2. Bagi masyarakat/praktisi perkebunan
Membantu proses identifikasi tingkat kematangan buah kelapa sawit secara otomatis dan lebih efisien melalui aplikasi berbasis Streamlit. Dengan adanya

sistem ini, proses penentuan kematangan yang sebelumnya dilakukan secara manual dapat menjadi lebih cepat, objektif, dan mengurangi kesalahan dalam pengamatan visual.

3. Bagi industri/perusahaan perkebunan

Memberikan solusi teknologi yang dapat digunakan untuk meningkatkan kualitas panen dan efisiensi operasional. Dengan memanfaatkan model yang optimal dengan memiliki akurasi tinggi dan waktu inferensi yang cepat, sehingga berpotensi meningkatkan kualitas hasil minyak kelapa sawit.