

BAB I

PENDAHULUAN

1.1 Latar Belakang

Industri pertanian modern, khususnya dalam penanganan pasca panen, menghadapi tantangan signifikan terkait efisiensi dan akurasi penyortiran buah. Penyortiran manual masih menjadi metode umum yang mengharuskan pekerja berulang kali mengamati dan mengklasifikasikan setiap buah berdasarkan karakteristik visual seperti warna, ukuran, tekstur permukaan, dan kematangan[1]. Proses ini tidak hanya memakan waktu dan tenaga, tetapi juga rentan terhadap hasil yang tidak konsisten dan kesalahan. Standar klasifikasi dapat bervariasi tidak hanya antar pekerja yang berbeda, tetapi juga pada pekerja yang sama seiring berjalannya waktu dan meningkatnya kelelahan. Kekurangan ini berasal dari keterbatasan manusia seperti kelelahan, subjektivitas dalam penilaian, dan keterbatasan presisi visual, yang dalam skala industri dapat berdampak negatif pada produktivitas, akurasi klasifikasi, dan ketepatan waktu distribusi produk[1].

Permasalahan tersebut telah menjadi perhatian dalam berbagai penelitian sebelumnya. Beberapa studi menunjukkan bahwa penyortiran manual tidak mampu memenuhi kebutuhan industri berskala besar yang menuntut kecepatan, konsistensi, dan ketepatan klasifikasi yang tinggi. Upaya awal untuk mengatasi masalah ini dilakukan dengan penerapan sistem otomatis berbasis sensor sederhana atau metode pengolahan citra konvensional. Namun, pendekatan tersebut masih memiliki keterbatasan, terutama dalam menangani variasi kondisi pencahayaan, perbedaan warna buah yang kompleks, serta perubahan karakteristik visual buah akibat tingkat kematangan yang beragam. Selain itu, metode machine learning tradisional masih bergantung pada proses feature engineering manual, sehingga kurang fleksibel dan sulit beradaptasi terhadap variasi data yang tinggi.

Seiring dengan perkembangan era Industri 4.0, teknologi cerdas seperti kecerdasan buatan (AI), *computer vision*, dan *Internet of Things* (IoT) mulai diterapkan untuk mengotomatisasi berbagai proses di sektor pertanian[1]. Penerapan deep learning dalam sistem visi mesin memungkinkan proses ekstraksi fitur dilakukan secara otomatis dan hierarkis, sehingga model mampu mengenali pola visual yang kompleks dengan tingkat akurasi yang lebih tinggi. Algoritma deteksi objek berbasis deep learning, khususnya YOLO (You Only Look Once), menjadi salah satu solusi yang menjanjikan karena memiliki keunggulan dalam kecepatan inferensi dan kemampuan deteksi real-time, yang sangat sesuai untuk aplikasi industri penyortiran buah. *Deep learning* muncul sebagai teknik yang menjanjikan untuk berbagai tugas *computer vision*, termasuk deteksi dan inspeksi buah. Dengan mempelajari fitur gambar secara otomatis, model *deep learning* dapat mengekstrak informasi penting dari gambar dengan lebih sedikit campur tangan manusia, sehingga menghasilkan akurasi yang lebih tinggi dan kinerja yang lebih baik[2]. Pengintegrasian algoritma *computer vision* tingkat lanjut ke dalam sistem visi mesin dapat meningkatkan efisiensi proses ini secara signifikan. Sebuah sistem visi mesin yang lengkap biasanya terdiri dari kamera beresolusi tinggi, sistem pencahayaan yang terkontrol untuk menstandarkan kondisi gambar, serta unit pemrosesan yang kuat untuk menjalankan algoritma[3]. Metodologi ini menggunakan *computer vision* dan algoritma pembelajaran mesin yang canggih untuk mengevaluasi berbagai aspek buah secara otomatis dan membuat keputusan kategorisasi yang akurat. Setelah klasifikasi, sistem dapat secara otomatis mengirimkan sinyal ke aktuator mekanis untuk memisahkan buah ke dalam jalur atau wadah yang berbeda sesuai dengan gradenya. Pendekatan ini tidak hanya meningkatkan kecepatan dan konsistensi proses, tetapi juga mengurangi ketergantungan pada tenaga kerja manusia[3].

Salah satu algoritma *deep learning* yang banyak digunakan untuk deteksi dan klasifikasi objek secara *real-time* adalah YOLO (You Only Look Once). YOLO memiliki keunggulan dalam kecepatan inferensi dan

kemampuan mendeteksi objek dalam satu tahap pemrosesan, sehingga sangat sesuai untuk aplikasi industri yang membutuhkan respon cepat. Namun, performa YOLO sangat bergantung pada konfigurasi hyperparameter yang digunakan selama proses pelatihan. Hyperparameter seperti *learning rate*, *batch size*, *optimizer*, *Weight Decay*, dan *Epoch* berperan penting dalam menentukan stabilitas pelatihan, kecepatan konvergensi, serta kemampuan model dalam melakukan generalisasi. Pemilihan *hyperparameter* ini masih sering dilakukan secara manual atau hanya menggunakan nilai *default*, yang belum tentu optimal untuk karakteristik dataset atau permasalahan yang dihadapi[3]. Hal ini dikarenakan setiap dataset memiliki karakteristik yang berbeda, seperti ukuran, distribusi kelas, tingkat *noise*, serta kompleksitas fitur yang terkandung di dalamnya. Hyperparameter yang tidak sesuai dapat menyebabkan model mengalami *overfitting* atau *underfitting*, di mana model gagal mempertahankan performa pada data uji maupun kondisi nyata di lapangan. Oleh karena itu, penyesuaian dan optimasi hyperparameter menjadi langkah yang krusial untuk memastikan model mampu belajar secara efektif dan menghasilkan prediksi yang stabil serta akurat. Dengan demikian, optimasi hyperparameter tidak hanya berfungsi untuk meningkatkan performa model secara numerik, tetapi juga berperan penting dalam menjamin keandalan, efisiensi, dan kesiapan implementasi sistem YOLO pada aplikasi penyortiran buah di lingkungan industri pertanian modern[3].

Berdasarkan permasalahan tersebut, penelitian ini dilakukan untuk merancang dan mengimplementasikan sistem klasifikasi tingkat kematangan buah apel berbasis deep learning menggunakan algoritma YOLOv8 yang diintegrasikan dengan sistem mekanik penyortiran otomatis. Penelitian ini berfokus pada optimasi hyperparameter untuk meningkatkan akurasi dan konsistensi klasifikasi, sekaligus memastikan performa real-time yang sesuai dengan kebutuhan industri. Sistem yang dikembangkan tidak hanya mengklasifikasikan buah apel berdasarkan tingkat kematangan, tetapi juga mengintegrasikan hasil klasifikasi dengan aktuator mekanik guna mengarahkan buah ke jalur penyortiran yang sesuai. Dengan demikian,

penelitian ini diharapkan dapat menjadi solusi yang efektif dalam meningkatkan efisiensi, akurasi, dan keandalan proses penyortiran buah pada industri pertanian modern.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan pada sub bab sebelumnya, maka dapat dirumuskan permasalahan yang ingin diangkat dalam Tugas Akhir ini sebagai berikut :

1. Bagaimana cara merancang sistem hardware yang mendukung model *deep learning* berbasis YOLOv8 agar dapat melakukan klasifikasi tingkat kematangan buah apel (matang, setengah matang, dan tidak matang) ?
2. Bagaimana melakukan optimasi *hyperparameter* untuk meningkatkan performa model dalam mendeteksi tingkat kematangan apel secara *real time* ?
3. Bagaimana pengaruh optimisasi *hyperparameter* terhadap kinerja deteksi dan klasifikasi apel pada model YOLOv8 dan serta jumlah buah apel yang dapat diklasifikasikan oleh sistem dalam satuan waktu tertentu ?

1.3 Tujuan Tugas Akhir

Tujuan penulisan pada pembuatan Tugas Akhir ini adalah sebagai berikut :

1. Mengembangkan model machine learning yang efektif untuk mengklasifikasikan tingkat kematangan apel (matang, setengah matang, dan tidak matang) berdasarkan data inspeksi *real time*.
2. Melakukan tuning hyper parameter untuk mengoptimalkan performa model machine learning dalam mendeteksi tingkat kematangan apel secara *real time*.
3. Membandingkan efektivitas dan efisiensi dari proses tuning *hyperparameter* terhadap model klasifikasi kematangan apel.

1.4 Batasan Masalah

Batasan dari pembuatan Tugas Akhir ini adalah sebagai berikut :

1. Penelitian ini hanya berfokus pada klasifikasi tingkat kematangan apel dengan tiga kelas yaitu matang, setengah matang, dan tidak matang.
2. Penelitian ini tidak membedakan jenis atau varietas apel tertentu, melainkan hanya menggunakan pendekatan klasifikasi berdasarkan karakteristik warna sebagai indikator kematangan.
3. Sistem pengklasifikasian hanya diuji pada kondisi pencahayaan terkontrol yang disediakan oleh modul LED berdaya 3 - 4 W dengan enam titik LED per modul dan keluaran cahaya ± 300 lumen per modul. Pencahayaan dijaga relatif stabil selama pengujian, sementara variasi intensitas atau perubahan sumber cahaya tidak dipertimbangkan.
4. Arduino digunakan hanya sebagai perangkat akuisisi data untuk membaca dan merekam sinyal PWM yang dihasilkan Dimmer pada tahap pengambilan data karakteristik sistem. Arduino tidak digunakan sebagai pengendali motor dan tidak terhubung secara permanen dengan rangkaian dimmer selama sistem beroperasi normal.
5. Kerusakan apel dalam penelitian ini dibatasi pada kerusakan fisik yang terjadi akibat benturan mekanik selama proses transportasi pada sistem konveyor, seperti goresan dan perubahan bentuk yang dapat diamati secara visual.