

BAB I

PENDAHULUAN

1.1 Latar Belakang

Menurut laporan dari Departemen Pertanian Amerika Serikat pada tahun 2016, Indonesia menjadi penyedia lebih dari setengah total pasokan minyak kelapa sawit di pasar global (Setiawan, dkk, 2019). Kehadiran Indonesia sebagai salah satu pemimpin dalam industri minyak kelapa sawit memperkuat peran penting sektor pertanian dalam pertumbuhan ekonomi nasional. Sebagai negara agraris, Indonesia telah mampu memanfaatkan sektor pertaniannya dengan cukup baik. Pada tahun 2017, diperkirakan produksi kelapa sawit di Indonesia mencapai 35,36 juta ton, angka perkiraan ini meningkat sebesar 6,41% dari produksi kelapa sawit pada tahun 2016 (Syiafuddin, dkk, 2020). Oleh karena itu, untuk memastikan kelangsungan dan daya saing industri kelapa sawit, diperlukan upaya untuk terus meningkatkan kualitas dan efisiensi produksi. Salah satu aspek kunci dalam pencapaian ini adalah memastikan penilaian kematangan buah yang akurat saat panen. Dengan memastikan bahwa buah dipanen pada titik kematangan yang tepat, dapat dihasilkan minyak kelapa sawit dengan kualitas yang optimal. Hal ini tidak hanya mempengaruhi nilai jual produk, tetapi juga berpotensi untuk meningkatkan daya saing industri di pasar global. Oleh karena itu, pemantauan dan pengelolaan kematangan buah secara cermat menjadi strategi penting dalam menjaga dan meningkatkan produktivitas serta kualitas minyak kelapa sawit yang dihasilkan (Septiarini, dkk, 2020).

Penentuan Tingkat kematangan buah kelapa sawit merupakan hal yang penting dalam industri kelapa sawit. Hal ini dikarenakan kualitas minyak kelapa sawit yang dihasilkan sangat bergantung pada kematangan buah pada saat panen (Septiarini, dkk, 2021). Saat ini, penilai manusia tradisional memainkan peran penting dalam membedakan kematangan kelapa sawit di perkebunan. Selama tahap pra-panen, penilai manusia mengevaluasi tandan buah segar (TBS) kelapa sawit berdasarkan jumlah buah yang terlepas dan jatuh ke tanah serta warna permukaan

TBS kelapa sawit untuk menentukan tahap kematangannya. Untuk tahap pascapanen, seorang ahli manusia memeriksa warna permukaan TBS kelapa sawit untuk menolak TBS yang belum matang dan terlalu matang agar tidak melanjutkan proses ekstraksi minyak (Aliteh, dkk, 2020). Pentingnya sistem otomatis dalam membedakan buah kelapa sawit semakin meningkat seiring dengan krisis kekurangan tenaga kerja dalam industri kelapa sawit. Pengembangan sistem otomatis diharapkan dapat meningkatkan efisiensi dan produktivitas dalam menentukan kematangan buah kelapa sawit (Lai, dkk, 2023).

Dalam beberapa tahun terakhir, teknologi dalam mengotomatisasi analisis tanaman, terutama dalam bidang *Machine Learning* (ML) dan *Deep Learning* (DL) sudah sangat mengalami kemajuan. Algoritma kecerdasan buatan, khususnya jaringan saraf tiruan, telah digunakan untuk mendeteksi tingkat kematangan, kualitas, dan aspek lainnya dari buah. Hal ini menghasilkan kemajuan yang signifikan dalam memahami dan memproses informasi visual dari buah-buahan untuk tujuan analisis dan perbaikan (Espinoza, dkk, 2023). Penelitian deteksi objek telah menjadi fokus utama dalam beberapa tahun terakhir. Dengan kekuatan alat pembelajaran yang kuat, kita dapat dengan mudah mendeteksi dan mempelajari fitur-fitur yang lebih dalam (Srivastava, dkk, 2021). *Convolutional Neural Network* (CNN) adalah salah satu arsitektur *Deep Learning* (DL) yang paling banyak digunakan dalam pengolahan gambar. CNN memiliki tingkat abstraksi yang tinggi dan kemampuan untuk secara otomatis mempelajari pola yang ada dalam gambar. Terutama sejak tahun 2012, ketika CNN memenangkan kompetisi ImageNet, CNN telah menjadi sangat populer sebagai metode yang efisien untuk klasifikasi gambar di banyak bidang, termasuk dalam aplikasi pertanian seperti klasifikasi dan deteksi buah (Naranjo-Torres, dkk, 2020).

Convolutional Neural Network (CNN) telah menjadi pilihan utama dalam pengenalan dan klasifikasi gambar, termasuk dalam klasifikasi tingkat kematangan buah. CNN unggul dalam pembelajaran yang mendalam, ekstraksi fitur menggunakan konvolusi, representasi yang lebih baik, fleksibilitas terhadap berbagai jenis data gambar, dan kemajuan teknologi yang pesat. Dibandingkan dengan model lain seperti *Support Vector Machine* (SVM) atau *K-Nearest*

Neighbors (KNN), CNN menawarkan akurasi dan efisiensi yang lebih tinggi dalam klasifikasi tingkat kematangan buah, serta berpotensi untuk inovasi lebih lanjut dalam teknologi pengolahan citra dalam pertanian. CNN telah terbukti sangat efisien dalam klasifikasi dan pengenalan buah dengan mengurangi kesalahan secara signifikan. Namun, terdapat sedikit penelitian yang menggunakan CNN dalam klasifikasi tingkat kematangan buah hingga saat ini (Bhargava and Bansal, 2021). Dalam penelitian yang dilakukan (Aherwadi, dkk, 2022) dengan meninjau 35 paper tentang teknik *Machine Learning* (ML) dan *Deep Learning* (DL) untuk klasifikasi kematangan buah, menyimpulkan bahwa CNN adalah algoritma yang paling cocok untuk tugas ini. Dalam penelitian ini, Pelatihan dan validasi dilakukan dan mendapatkan hasil akurasi yang tinggi, yaitu 98,25% untuk model CNN.

Mengoptimalkan arsitektur CNN dan *hyperparameter* adalah langkah penting dalam pengembangan model CNN yang dapat mempengaruhi kinerja dan efisiensi secara signifikan. Pemilihan arsitektur CNN yang tepat melibatkan pertimbangan terhadap ukuran dan kompleksitas dataset, ketersediaan sumber daya komputasi, dan tujuan spesifik dari tugas klasifikasi citra. Dataset yang besar dan kompleks mungkin memerlukan arsitektur yang lebih dalam untuk mempelajari fitur-fitur yang kompleks, sementara sumber daya komputasi yang terbatas membatasi kompleksitas arsitektur yang dapat digunakan (Ghosh, dkk, 2023). Dengan merancang arsitektur CNN yang optimal, termasuk penyesuaian struktur jaringan seperti lapisan, ukuran kernel, dan jumlah filter, model dapat belajar dengan lebih efektif dari data pelatihan, mencegah terjadinya *overfitting* (Chen, dkk, 2021). Di sisi lain, mengoptimalkan *hyperparameter* seperti *learning rate*, jumlah *epochs*, dan metode regularisasi memungkinkan model untuk belajar dengan efisien, mengurangi risiko *overfitting*, dan menghasilkan prediksi yang lebih akurat pada data yang belum pernah dilihat sebelumnya (Fouad, dkk, 2021).

Differential Evolution (DE) adalah sebuah algoritma pencarian yang fleksibel dan serbaguna yang diperkenalkan pada tahun 1997 oleh Storn dan Price (Galván dan Mooney, 2021). DE adalah algoritma pencarian metaheuristik berbasis populasi yang menggunakan konsep perbandingan vektor dalam populasi untuk menghasilkan variasi baru yang dievaluasi dalam pencarian solusi optimal. DE

menggunakan operasi mutasi sebagai langkah utama untuk menghasilkan variasi dalam populasi (Dhar, dkk, 2023). Kelebihan DE adalah kemampuannya untuk menangani ruang pencarian yang kompleks dan non-linear dengan efisien. DE cenderung memiliki konvergensi yang cepat dan dapat menemukan solusi yang baik dalam jumlah iterasi yang relatif sedikit. Selain itu, DE relatif mudah diimplementasikan dan tidak memerlukan penyetelan parameter yang rumit, sehingga cocok digunakan dalam optimasi CNN (Galván dan Mooney, 2021). Hasil penelitian yang dilakukan (Piotrowski, Napiorkowski dan Piotrowska, 2023) menyebutkan bahwa *Differential Evolution* (DE) terbukti lebih baik daripada *Particle Swarm Optimization* (PSO) dalam hal kinerja optimasi. Hal ini dibuktikan dengan dominasi DE dalam sembilan kompetisi berbeda, di mana empat peringkat teratas selalu ditempati oleh varian DE. PSO kalah dari DE karena cenderung kurang stabil, mudah terjebak di solusi lokal, dan sangat bergantung pada parameter serta struktur swarm. Sementara itu, DE lebih adaptif, eksploratif, dan terbukti lebih unggul dalam banyak benchmark dan masalah nyata. Selain itu *Differential Evolution* (DE) menunjukkan keunggulan yang signifikan dibandingkan dengan teknik optimasi lain seperti Algoritma Genetika (GA), *Whale Optimization Algorithm* (WOA), dan *Particle Swarm Optimization* (PSO). Salah satu alasan utama DE lebih unggul adalah kecepatan konvergensi yang lebih tinggi dan kestabilan hasil yang lebih baik. DE mampu menemukan solusi optimal dengan waktu yang lebih singkat dan konsistensi yang lebih baik dalam berbagai percobaan, yang sangat penting untuk aplikasi di dunia nyata di mana waktu dan keandalan hasil menjadi faktor kritis (AL-Bahrani, AL-Kaabi dan AL Hasheme, 2022).

Berdasarkan temuan-temuan penelitian yang telah dijabarkan diatas, penelitian ini akan menggunakan model *Convolutional Neural Network* (CNN) yang akan di optimasi menggunakan *Differential Evolution* (DE) dalam melakukan klasifikasi kematangan buah kelapa sawit. Dengan pendekatan DE dalam klasifikasi tingkat kematangan buah kelapa sawit menggunakan CNN, diharapkan dapat memberikan kontribusi signifikan dalam meningkatkan efisiensi dan akurasi dalam industri kelapa sawit dan *computer vision*.

1.2 Tujuan Penelitian

Tujuan utama dari penelitian ini adalah untuk mengoptimalkan *Convolutional Neural Network* (CNN) dengan pendekatan *Differential Evolution* (DE) guna meningkatkan efisiensi dan akurasi dalam mengklasifikasi kematangan buah kelapa sawit.

1.3 Manfaat Penelitian

Penelitian ini dapat memajukan teknologi pengolahan citra dalam dunia pertanian, terutama dalam klasifikasi citra. Dengan menerapkan *Convolutional Neural Network* (CNN) dengan pendekatan *Differential Evolution* (DE), diharapkan peluang pengembangan teknologi analisis visual buah-buahan meningkat sehingga dapat meningkatkan efisiensi petani dan pengambilan keputusan.



SEKOLAH PASCASARJANA