

BAB I

PENDAHULUAN

1.1 Latar Belakang

Buah mangga merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi strategis di Indonesia [1]. Tingkat kematangan buah menjadi penentu utama kualitas produk, mencakup ketepatan waktu panen, karakteristik fisik, cita rasa, daya simpan, dan nilai jual [2], sehingga penyortiran berdasarkan tingkat kematangan menjadi tahapan kritis dalam rantai distribusi untuk menjamin keseragaman mutu sebelum produk dipasarkan. Pada kenyataannya, proses penyortiran ini masih dominan dilakukan melalui inspeksi visual oleh operator, yaitu pendekatan yang rentan terhadap inkonsistensi penilaian akibat variasi persepsi antarpribadi, akumulasi kelelahan, dan keterbatasan kemampuan penglihatan manusia [3]. Konsekuensinya mencakup potensi kesalahan klasifikasi yang berimplikasi pada kerugian ekonomi, penurunan kepuasan konsumen, dan inefisiensi dalam rantai distribusi. Hal ini mendorong kebutuhan pengembangan sistem klasifikasi tingkat kematangan yang otomatis dan objektif, salah satunya melalui pendekatan *Deep Learning* yang mampu mengekstraksi fitur visual seperti warna, tekstur, dan morfologi permukaan buah tanpa intervensi manual [4].

Sejumlah penelitian telah dilakukan untuk mengembangkan metode *Deep Learning* dalam klasifikasi tingkat kematangan mangga, namun masih menyisakan dua celah utama. Penelitian [5] yang menerapkan *Convolutional Neural Network* (CNN) dasar mencapai akurasi 53,3%, kinerja tersebut dinilai belum memadai karena masih terdapat tumpang tindih distribusi fitur visual antara kelas mentah dan setengah matang, yang menunjukkan bahwa model belum mampu membedakan kedua kelas secara konsisten. Temuan ini menunjukkan bahwa klasifikasi tingkat kematangan mangga memerlukan model yang mampu membangun representasi fitur yang lebih diskriminatif untuk membedakan karakteristik visual antar kelas yang lebih akurat. Penelitian [6] memanfaatkan CNN dan VGG16 mencapai akurasi hingga 96,28%, sementara penelitian [7] yang membandingkan VGG16 dan AlexNet melaporkan akurasi VGG16 sebesar 92,50%. Meskipun menunjukkan peningkatan akurasi yang signifikan, keduanya tidak mempertimbangkan efisiensi komputasi model, meliputi waktu pelatihan, waktu inferensi, dan ukuran model. Atas dasar ini, terdapat kebutuhan akan arsitektur yang mampu menghasilkan representasi fitur diskriminatif pada kelas dengan kemiripan visual tinggi, sekaligus memenuhi kriteria efisiensi komputasi.

Untuk menjawab dua celah tersebut, penelitian ini mengadopsi arsitektur EfficientNet-B0 dengan pendekatan *transfer learning*. *Transfer learning* memungkinkan pemanfaatan pengetahuan yang diperoleh dari tugas sumber untuk meningkatkan kinerja pada tugas target, sehingga model tidak perlu dilatih dari awal yang umumnya menuntut dataset beranotasi berskala besar dan waktu komputasi yang panjang [8]. Model pra-latih pada dataset skala besar seperti *ImageNet* mampu menangkap representasi fitur secara hierarkis, mulai dari fitur tingkat rendah seperti tepi dan tekstur hingga informasi semantik tingkat tinggi yang dapat ditransfer secara efektif ke domain klasifikasi baru [9]. Dibandingkan dengan arsitektur yang dirancang khusus untuk efisiensi komputasi seperti MobileNetV2, EfficientNet-B0 secara konsisten menunjukkan akurasi validasi dan kemampuan generalisasi yang lebih unggul berdasarkan hasil pengujian yang dilaporkan [10], melalui mekanisme *Compound Scaling* yang menskalakan kedalaman, lebar, dan resolusi model secara proporsional menggunakan koefisien tunggal tanpa peningkatan beban komputasi yang tidak proporsional [11]. Keunggulan ini dikonfirmasi oleh penelitian [12] pada klasifikasi kematangan kakao, di mana EfficientNet-B0 mencapai akurasi 99,71% dengan kemampuan generalisasi yang terjaga meskipun data pelatihan terbatas. Penelitian [13] pada klasifikasi penyakit daun apel melaporkan akurasi 99,69–99,78% dengan konsumsi memori dan *Floating-Point operations* (FLOPs) yang rendah, menjadikannya kandidat yang layak untuk implementasi pada perangkat dengan keterbatasan sumber daya komputasi [13]. Penelitian komparatif pada klasifikasi penyakit daun anggur lebih lanjut membuktikan bahwa EfficientNet-B0 mengungguli InceptionV3 dan Xception dengan akurasi 99,5% serta jumlah parameter dan waktu inferensi yang lebih rendah [14]. Keberhasilan EfficientNet-B0 pada berbagai domain klasifikasi buah dan penyakit tanaman tersebut mengindikasikan potensi arsitektur ini untuk mengatasi persoalan inti pada klasifikasi kematangan mangga, yaitu membedakan kelas dengan kemiripan visual tinggi secara akurat sekaligus efisien.

Penelitian ini melakukan evaluasi komparatif terkendali terhadap arsitektur EfficientNet-B0 dengan *transfer learning*, dengan CNN dasar sebagai *baseline* untuk mengevaluasi peningkatan kemampuan representasi fitur dan MobileNetV2 sebagai pembanding efisiensi komputasi. Kontribusi penelitian terletak pada evaluasi performa model berdasarkan keseimbangan antara akurasi klasifikasi dan efisiensi komputasi pada dataset kematangan mangga. Pendekatan tersebut belum dilakukan secara bersamaan pada penelitian terdahulu [6], [7], serta mencakup replikasi kondisi data sangat terbatas [5] untuk menganalisis pengaruh arsitektur dan *transfer learning* dengan meminimalkan pengaruh jumlah data.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, masalah yang dapat dirumuskan adalah sebagai berikut.

1. Klasifikasi tingkat kematangan buah mangga pada kelas dengan kemiripan visual yang tinggi belum mampu menghasilkan representasi fitur yang cukup diskriminatif dengan pendekatan CNN dasar, sehingga terjadi tumpang tindih distribusi fitur visual antar kelas kematangan yang berdekatan secara visual.
2. Model klasifikasi tingkat kematangan buah mangga yang tidak hanya memiliki akurasi tinggi tetapi juga efisien secara komputasi, sehingga layak diterapkan pada perangkat dengan sumber daya terbatas.

1.3 Tujuan

Penelitian ini memiliki tujuan sebagai berikut:

1. Membangun sistem klasifikasi tingkat kematangan buah mangga yang mampu membedakan kelas dengan kemiripan visual tinggi secara akurat melalui penerapan arsitektur EfficientNet-B0 dengan pendekatan *transfer learning* untuk menghasilkan representasi fitur yang diskriminatif.
2. Membangun model klasifikasi tingkat kematangan buah mangga yang tidak hanya memiliki akurasi tinggi tetapi juga efisien secara komputasi melalui evaluasi kinerja arsitektur EfficientNet-B0 berdasarkan akurasi klasifikasi serta efisiensi komputasi yang meliputi jumlah parameter, ukuran model, FLOPs, dan waktu inferensi, guna menilai keseimbangan antara akurasi dan efisiensi serta kelayakan penerapannya pada lingkungan dengan keterbatasan sumber daya komputasi.

1.4 Manfaat

Adapun manfaat yang diharapkan dari penelitian ini adalah sebagai berikut:

1. Memberikan kontribusi berupa model klasifikasi tingkat kematangan buah mangga berbasis *transfer learning* dengan arsitektur EfficientNet-B0 yang dievaluasi dari aspek akurasi klasifikasi dan efisiensi komputasi, sehingga dapat menjadi pertimbangan dalam pengembangan sistem penyortiran buah yang objektif dan dapat diterapkan pada lingkungan dengan keterbatasan sumber daya komputasi.
2. Menjadi referensi ilmiah bagi penelitian selanjutnya dalam penerapan *transfer learning* untuk klasifikasi citra pertanian, khususnya yang mempertimbangkan keseimbangan antara kinerja klasifikasi dan efisiensi komputasi sebagai kriteria evaluasi model.

1.5 Ruang Lingkup

Adapun ruang lingkup pada penelitian ini adalah sebagai berikut:

1. Dataset citra buah mangga yang digunakan dalam penelitian ini berasal dari platform Kaggle dengan judul “*Mango Ripeness Classification*” yang dikembangkan oleh Debajit Guha (*Owner*) [15].
2. Dari total 943 dataset berformat .jpg dan .png dengan latar belakang yang bersih, di mana setiap citra hanya memuat satu objek buah mangga, data dipartisi menjadi 70% data pelatihan, 15% data validasi, dan 15% data pengujian.
3. Proses *preprocessing* dilakukan dengan mengubah ukuran citra menjadi 224×224 piksel agar sesuai dengan masukan model EfficientNet-B0, serta penerapan teknik augmentasi berupa *Rotation*, *Shift*, *Flipping*, *Zoom*, *Brightness Adjustment*, serta *Channel Shifting* untuk meningkatkan variasi data dan ketahanan model terhadap perubahan kondisi citra.
4. Klasifikasi tingkat kematangan buah mangga dibagi menjadi empat kategori, yaitu *unripe*, *partially ripe*, *ripe*, dan *rotten*. Penelitian ini tidak mencakup varietas mangga tetap berwarna hijau saat matang.
5. Evaluasi kinerja klasifikasi model dilakukan dengan menghitung *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang diperoleh dari Confusion Matrix. Pengukuran dilakukan baik secara keseluruhan maupun pada setiap kelas tingkat kematangan.
6. Evaluasi efisiensi komputasi model dilakukan dengan mengukur jumlah parameter model, ukuran model, jumlah operasi bilangan *floating-point* (FLOPs), dan waktu inferensi. Hasil pengukuran tersebut dibandingkan dengan arsitektur CNN ringan lain yaitu MobileNetV2 yang dilatih pada dataset yang sama, untuk menilai kelayakan penerapan model pada lingkungan dengan keterbatasan sumber daya komputasi.
7. Perbandingan kemampuan representasi fitur antara CNN dasar dan EfficientNet-B0 dilakukan pada dua kondisi jumlah data yang setara, yaitu:
 - a. Kondisi data sangat terbatas (subset 40 citra, 10 citra per kelas mengikuti kondisi penelitian [5]): CNN dasar yang dilatih dari awal dibandingkan dengan EfficientNet-B0 berbasis *transfer learning*.
 - b. Kondisi data penuh (943 citra dengan augmentasi yang setara): CNN dasar dibandingkan dengan EfficientNet-B0 sebagai perbandingan adil pada jumlah data penuh.