

BAB V PENUTUP

5.1 Kesimpulan

Berdasarkan hasil pelatihan dan evaluasi pada dataset utama, MobileNetV2 menunjukkan performa paling baik dan paling stabil dibandingkan model lainnya. Pada percobaan pertama, MobileNetV2 memperoleh nilai MAE training sebesar 0,53, MAE validation 1,23, dan MAE evaluasi 1,54. Pada percobaan kedua, performanya tetap konsisten dengan MAE training 0,86, MAE validation 0,99, dan MAE evaluasi 0,95, yang merupakan nilai terendah di antara seluruh model. Hal ini menunjukkan kemampuan generalisasi dan ekstraksi fitur yang efektif pada berbagai skenario data.

Model CNN menunjukkan performa yang cukup baik namun kurang stabil pada dataset utama. Pada percobaan pertama, CNN menghasilkan MAE training 0,94, MAE validation 2,72, dan MAE evaluasi 3,41, yang menandakan adanya kesenjangan antara data pelatihan dan evaluasi. Pada percobaan kedua, performa CNN membaik dengan MAE training 1,83, MAE validation 1,86, dan MAE evaluasi 1,86. Menariknya, pada pengujian data baru (data uji eksternal), CNN memberikan prediksi paling akurat dibandingkan MobileNetV2 dan EfficientNetB0, menunjukkan keunggulan CNN dalam menghadapi kondisi nyata meskipun nilai MAE pada dataset utama tidak serendah MobileNetV2.

Sementara itu, EfficientNetB0 menunjukkan performa yang kurang optimal pada dataset kecil, dengan nilai MAE training 5,85, MAE validation 6,73, dan MAE evaluasi 6,05 pada percobaan pertama. Namun, setelah jumlah data diperbesar pada percobaan kedua, performanya meningkat secara signifikan dengan MAE training 0,97, MAE validation 1,28, dan MAE evaluasi 1,30. Hasil ini menunjukkan bahwa EfficientNetB0 memerlukan dataset yang lebih besar agar dapat bekerja secara optimal.

Secara keseluruhan, hasil penelitian menunjukkan bahwa tidak terdapat satu model yang unggul mutlak pada seluruh skenario. MobileNetV2 menjadi model terbaik pada evaluasi internal (training-validation-evaluasi), CNN menunjukkan keunggulan pada pengujian data eksternal, sedangkan EfficientNetB0 hanya memberikan hasil optimal ketika jumlah data mencukupi. Temuan ini menegaskan

bahwa pemilihan model harus disesuaikan dengan kondisi dataset dan tujuan penerapan sistem prediksi kematangan buah.

5.2 Saran

Berdasarkan hasil penelitian dan tantangan yang dihadapi selama proses pengembangan model, beberapa saran yang dapat diberikan untuk penelitian selanjutnya adalah sebagai berikut:

1. Menambahkan tahap prediksi lanjutan yang mencakup fase pasca-kematangan (matang menuju busuk), karena pada penelitian ini model hanya difokuskan untuk memprediksi hari menuju kematangan. Pengembangan model lanjutan akan memberikan manfaat praktis yang lebih besar bagi petani dan pelaku industri buah dalam menentukan waktu panen dan distribusi yang optimal.
2. Mengeksplorasi variasi pembagian data (data split) yang berbeda, seperti 70/20/10 atau *k-fold cross validation*, untuk menguji konsistensi performa model terhadap distribusi data yang beragam. Penelitian ini hanya menggunakan pembagian 80/10/10, sehingga eksplorasi lebih lanjut dapat memberikan gambaran yang lebih menyeluruh mengenai kemampuan generalisasi model.
3. Mengembangkan integrasi model dengan sistem aplikasi praktis, misalnya penggabungan dengan kamera otomatis, sistem monitoring berbasis IoT, atau aplikasi Android untuk deteksi tingkat kematangan buah secara *real-time* di lapangan.