

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai klasifikasi penyakit daun terong menggunakan dataset teraugmentasi dengan optimasi fine-tuning pada arsitektur MobileNetV2, maka dapat disimpulkan beberapa hal sebagai berikut:

1. Model MobileNetV2 berhasil diimplementasikan untuk melakukan klasifikasi penyakit daun terong secara otomatis dengan memanfaatkan pendekatan transfer learning. Model pretrained MobileNetV2 yang berasal dari dataset ImageNet mampu digunakan sebagai dasar pembelajaran untuk mengenali pola-pola visual pada daun terong, baik daun sehat maupun daun yang mengalami gangguan penyakit. Hal ini membuktikan bahwa MobileNetV2 dapat diterapkan sebagai solusi klasifikasi berbasis citra digital pada bidang pertanian.
2. Proses pelatihan model menunjukkan performa yang meningkat secara signifikan dari epoch awal hingga epoch terbaik. Berdasarkan hasil training, akurasi validasi (*validation accuracy*) mengalami peningkatan dari 75.21% pada epoch awal menjadi nilai terbaik sebesar 95.52% pada epoch ke-34. Penurunan nilai training loss dan validation loss yang konsisten menunjukkan bahwa proses pembelajaran berjalan dengan baik, serta model mampu mempelajari fitur penyakit daun terong secara bertahap dan stabil.
3. Optimasi fine-tuning memberikan kontribusi penting dalam meningkatkan kemampuan model dalam mengenali kelas penyakit daun terong. Fine-tuning memungkinkan model menyesuaikan bobot pada lapisan tertentu sehingga lebih relevan dengan karakteristik dataset daun terong. Strategi ini terbukti efektif karena model tidak hanya menggunakan fitur umum dari dataset ImageNet, tetapi juga mempelajari fitur spesifik seperti pola bercak, perubahan warna mosaik, jamur putih, serta bentuk daun layu yang menjadi ciri khas masing-masing kelas penyakit.

4. Hasil evaluasi menggunakan confusion matrix menunjukkan bahwa model memiliki performa klasifikasi yang baik pada data testing. Berdasarkan hasil perhitungan dari confusion matrix, model mampu menghasilkan akurasi pengujian sebesar 93.92%. Nilai tersebut menunjukkan bahwa model mampu mengklasifikasikan sebagian besar citra daun terong secara tepat, serta memiliki kemampuan generalisasi yang cukup tinggi pada data yang belum pernah dilihat sebelumnya.
5. Model MobileNetV2 dinilai efektif dan efisien untuk digunakan dalam sistem klasifikasi penyakit daun terong, karena memiliki ukuran model yang ringan dan kebutuhan komputasi yang lebih rendah dibanding arsitektur CNN yang lebih besar seperti VGG atau ResNet. Dengan demikian, model ini memiliki potensi besar untuk dikembangkan lebih lanjut pada sistem berbasis mobile atau aplikasi pertanian cerdas (*smart agriculture*) yang dapat membantu petani melakukan identifikasi penyakit secara cepat.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan, terdapat beberapa saran yang dapat digunakan untuk pengembangan penelitian selanjutnya agar sistem klasifikasi penyakit daun terong dapat menjadi lebih baik dan lebih siap diterapkan dalam kondisi nyata. Adapun saran-saran tersebut adalah sebagai berikut:

1. Penelitian selanjutnya disarankan untuk menggunakan dataset tambahan yang berasal dari kondisi lapangan (*real-world dataset*). Dataset publik biasanya memiliki kualitas gambar yang relatif baik dan latar belakang yang lebih bersih, sedangkan kondisi lapangan sering memiliki variasi pencahayaan, background yang kompleks, serta noise seperti daun lain atau tanah. Dengan dataset lapangan, model dapat diuji lebih realistis dan meningkatkan kemampuan generalisasi.
2. Disarankan untuk melakukan penanganan dataset tidak seimbang (*imbalanced dataset*) secara lebih mendalam. Penelitian selanjutnya dapat menerapkan teknik balancing seperti oversampling pada kelas minoritas, undersampling pada kelas mayoritas, penggunaan class weighting pada loss function, atau penerapan metode khusus seperti SMOTE (*Synthetic*

Minority Oversampling Technique). Hal ini bertujuan untuk meningkatkan performa model pada kelas-kelas yang memiliki jumlah data lebih sedikit, seperti Wilt Disease atau Healthy Leaf.

3. Disarankan untuk melakukan optimasi hyperparameter secara lebih luas, seperti variasi learning rate, batch size, optimizer (Adam, AdamW, SGD), penggunaan scheduler learning rate, dropout, dan early stopping. Optimasi hyperparameter dapat meningkatkan stabilitas pelatihan serta mencegah model mengalami overfitting pada epoch tertentu.

