

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil perancangan, pelatihan, dan evaluasi komparatif antara arsitektur EfficientNet B0 dan MobileNetV3 untuk klasifikasi penyakit daun mangga, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Performa Klasifikasi pada Dataset Utama

Kedua arsitektur menunjukkan kemampuan ekstraksi fitur yang sangat optimal ketika dihadapkan pada citra dengan latar belakang homogen. EfficientNet B0 berhasil mencapai tingkat akurasi pengujian sebesar 100%, sementara MobileNetV3 mencatatkan akurasi sebesar 99,75% dengan hanya satu kesalahan klasifikasi. Hal ini membuktikan bahwa secara teoritis, kedua model sangat mumpuni dalam membedakan delapan kelas kondisi daun mangga.

2. Efisiensi Karakteristik Komputasi

MobileNetV3 terbukti lebih efisien dalam penggunaan sumber daya komputasi dibandingkan EfficientNet B0. MobileNetV3 menghasilkan ukuran file yang lebih ringkas (14.96 MB berbanding 20.08 MB) dan latensi waktu inferensi yang lebih rendah (161.64 ms berbanding 176.96 ms per citra). Karakteristik ini menjadikan MobileNetV3 sebagai arsitektur yang lebih ideal untuk diimplementasikan pada perangkat dengan sumber daya terbatas.

3. Ketangguhan (*Robustness*) pada Citra Lapangan

Pengujian menggunakan citra lapangan menunjukkan terjadinya penurunan akurasi akibat *noise visual* latar belakang. EfficientNet B0 terbukti lebih tangguh dalam mempertahankan performa klasifikasinya (71.25%) dibandingkan MobileNetV3 (66.25%).

4. Dampak Pra-pemrosesan Segmentasi (*Background Removal*)

Penerapan teknik segmentasi latar belakang memberikan hasil yang spesifik terhadap arsitektur. Pada EfficientNet B0, segmentasi berhasil meningkatkan akurasi menjadi 75.00% dengan mengisolasi area ketertarikan (*Region of Interest*). Namun pada MobileNetV3, teknik segmentasi menurunkan akurasi

menjadi 65.00% karena algoritma pemotongan latar belakang mendistorsi fitur geometri tepi daun, yang sangat fatal bagi pengenalan kelas penyakit *Cutting Weevil*.

5. Performa Klasifikasi pada Skenario Segmentasi Latar Belakang (Laboratorium)

Pada eksperimen skenario kedua di mana model dilatih menggunakan dataset latih yang latar belakangnya telah disegmentasi, kedua arsitektur mencapai tingkat konvergensi yang identik. Baik EfficientNet B0 maupun MobileNetV3 memperoleh akurasi pengujian laboratorium sebesar 98,24%. Hal ini memvalidasi bahwa eliminasi gangguan visual pada tahap pelatihan mampu menyamakan batas kemampuan ekstraksi fitur patologi dari kedua model.

6. Ketangguhan Model Latih Segmentasi pada Dataset Uji

Pengujian pada skenario ini membalikkan temuan sebelumnya terkait generalisasi *domain shift*. Ketika model yang dilatih dengan dataset latih yang latar belakangnya telah disegmentasi dihadapkan pada data uji mentah (tanpa segmentasi latar belakang), MobileNetV3 terbukti jauh lebih tangguh (71,25%) dibandingkan EfficientNet B0 (62,50%). EfficientNet B0 mengalami bias prediksi ekstrem akibat sensitivitas berlebih (*over-sensitive*) terhadap bayangan dan *noise* visual alami, yang secara keliru diidentifikasi sebagai kelas *Anthraxnose*.

7. Pengaruh Isolasi Objek pada Model Latih Segmentasi

Ketika data uji lapangan ikut disegmentasi (dihapus latar belakangnya), EfficientNet B0 mengalami peningkatan akurasi yaitu di angka 75,00%, sementara performa MobileNetV3 cenderung stagnan di angka 71,25%. Fenomena komputasi ini menghasilkan kesimpulan bahwa arsitektur EfficientNet B0 sangat bergantung pada kondisi subjek yang steril dan terisolasi untuk mencapai performa maksimal, sedangkan MobileNetV3 secara arsitektural memiliki ketahanan bawaan yang adaptif terhadap keberadaan maupun ketiadaan latar belakang.

5.2 Saran

Berdasarkan proses penelitian yang telah dilakukan, terdapat beberapa batasan yang dapat dikembangkan untuk penelitian selanjutnya, antara lain:

1. Penambahan Dataset Latih Lingkungan Nyata

Penelitian selanjutnya disarankan untuk tidak hanya mengandalkan dataset laboratorium, tetapi juga menyertakan proporsi citra lapangan asli (dengan latar belakang natural) secara langsung ke dalam fase pelatihan (*training*). Hal ini bertujuan melatih model agar lebih adaptif terhadap pergeseran domain citra (*domain shift*) sejak awal.

2. Optimalisasi Algoritma Segmentasi

Mengingat algoritma penghapusan latar belakang bawaan dapat merusak fitur batas tepi daun, penelitian berikutnya dapat mengeksplorasi penggunaan metode segmentasi semantik bersyarat (*conditional semantic segmentation*) yang dirancang khusus untuk mempertahankan struktur geometri dan batas kontur morfologi daun.

3. Implementasi pada Perangkat *Mobile*

Karena evaluasi waktu inferensi dan ukuran penyimpanan menunjukkan hasil yang memenuhi standar aplikasi, arsitektur terbaik dari penelitian ini dapat dilanjutkan pada tahap *deployment*. Model dapat dikonversi ke dalam format TensorFlow Lite (.tflite) dan diintegrasikan ke dalam sistem operasi berbasis Android untuk pengujian penyakit secara *real-time* di perkebunan.