

BAB V

KESIMPULAN DAN SARAN

Bab ini menyajikan kesimpulan yang diturunkan langsung dari hasil pengujian dan analisis komparatif pada Bab IV, serta saran yang berorientasi pada pengembangan penelitian lebih lanjut.

5.1 Kesimpulan

Berdasarkan hasil pengujian eksperimental, analisis komparatif, dan pembahasan yang telah dilaksanakan secara menyeluruh, ditarik kesimpulan sebagai berikut:

1. Perbandingan Kinerja Kuantitatif (Menjawab Rumusan Masalah 1)

Arsitektur MobileNetV2 terbukti secara empiris mengungguli ResNet50 secara signifikan dalam seluruh metrik evaluasi berdasarkan standar SNI 3164:2009. MobileNetV2 mencapai nilai Akurasi, Presisi, *Recall*, dan *F1-Score* sebesar 97,00% dengan Weighted Average F1-Score sebesar 0,97. Di sisi lain, ResNet50 *Base* hanya mencapai 78%, dan meskipun telah dioptimasi melalui *Fine-Tuning*, akurasi maksimal ResNet50 meningkat menjadi 94,00% — masih 3 poin persentase di bawah MobileNetV2 yang tidak memerlukan *Fine-Tuning* sama sekali.

2. Kemampuan Deteksi Fitur Patologis Halus (Menjawab Rumusan Masalah 2)

MobileNetV2 menunjukkan ketangguhan (*robustness*) jauh lebih unggul dalam mendeteksi fitur cacat visual patologis halus gejala awal antraknosa laten (*Colletotrichum gloeosporioides*) dan bekas serangan oviposisi lalat buah (*Bactrocera dorsalis*) pada dataset dengan latar belakang bervariasi. Mekanisme *Depthwise Separable Convolution* terbukti efektif memisahkan sinyal fitur dari noise visual, menghasilkan *Recall* sebesar 0,97 melewati hanya ~3% kasus Tidak Layak. Sebanding, ResNet50 *Base* (*Recall* 0,85) melewati ~15% kasus, yang merepresentasikan risiko operasional tidak dapat diterima.

3. Trade-off Efisiensi Komputasi Optimal (Menjawab Rumusan Masalah 3)

MobileNetV2 memberikan *trade-off* paling optimal antara akurasi dan efisiensi. Dengan waktu inferensi ~7,60 ms/citra (~1,7x lebih cepat dari ResNet50: ~12,70 ms) dan total durasi pelatihan yang lebih singkat (~55 detik

untuk 30 epoch, dibanding ~272 detik total dua fase ResNet50), serta hanya ~3,4 juta parameter (< 14% ResNet50), MobileNetV2 memenuhi seluruh persyaratan teknis untuk implementasi *real-time* pada *smartphone* standar. Model ini layak diekspor ke format *TensorFlow Lite* (.tflite) untuk aplikasi penyortiran yang dapat dioperasikan oleh petani, pengepul, dan UMKM pertanian Indonesia tanpa investasi infrastruktur mahal.

5.2 Saran

Penelitian ini telah membangun fondasi empiris yang kuat untuk sistem klasifikasi kelayakan mangga berbasis *Deep Learning*. Saran berikut ditujukan untuk pengembangan lanjutan:

1. Implementasi Sistem Terintegrasi pada Perangkat Nyata: Model MobileNetV2 perlu diekspor ke *TensorFlow Lite* dan diintegrasikan menjadi purwarupa aplikasi *mobile* (Android/iOS) atau *embedded system* (Raspberry Pi 4). Purwarupa tersebut perlu diuji langsung oleh petani dan tenaga sortir di lingkungan perkebunan/gudang nyata untuk mengukur kesenjangan antara kinerja *in-silico* dan *in-situ*.
2. Ekspansi dan Diversifikasi Dataset secara Terkontrol: Pengayaan dataset secara sistematis mencakup kondisi pencahayaan ekstrem, lebih banyak varietas lokal Indonesia, dan kelas cacat spesifik seperti memar mekanis (*mechanical bruising*). Peningkatan dataset hingga 5.000-10.000 citra diharapkan mendorong akurasi mendekati 99%.
3. Pengujian Arsitektur Deteksi Objek untuk Skenario Industri: Untuk penyortiran pada konveyor berjalan skala industri yang memerlukan lokalisasi presisi cacat, disarankan membandingkan model ini dengan arsitektur *object detection* seperti YOLOv8-nano atau SSD-MobileNetV3 yang mampu melokalisasi (*bounding box*) lesi patologis secara *real-time*.
4. Eksplorasi Teknik Kompresi Model Lanjutan: Untuk perangkat sangat terbatas (*smartphone entry-level*, RAM < 2 GB), disarankan mengeksplorasi *quantization* (konversi bobot 32-bit ke 8-bit integer) dan *knowledge distillation* untuk mereduksi ukuran dan latensi lebih jauh tanpa degradasi akurasi signifikan.

5. Integrasi dengan Platform Manajemen Rantai Pasok Digital: Sistem klasifikasi ini perlu dikembangkan lebih lanjut untuk diintegrasikan dengan platform manajemen rantai pasok berbasis *cloud*, memungkinkan pengumpulan data agregat dari banyak petani untuk analisis tren kualitas panen secara temporal dan geospasial sebagai dasar program pembinaan kualitas berbasis data.