

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan penelitian yang telah dilakukan, maka dapat diperoleh kesimpulan sebagai berikut :

1. YOLOv8 secara konsisten menghasilkan akurasi deteksi yang lebih tinggi dibandingkan YOLOv7 di setiap konfigurasi data latih dan uji. Pada rasio data 80:20, YOLOv8 mencapai akurasi tertinggi sebesar 85.75%, sedangkan YOLOv7 hanya 63.25%. Selisih tertinggi juga terlihat pada rasio 70:30 dengan YOLOv8 sebesar 83% dan YOLOv7 hanya 72.5%.
2. Pada pengujian mAP@50, YOLOv8 juga menunjukkan hasil lebih baik di rasio data 70:30 (83.5%) dan 80:20 (88.7%), dibanding YOLOv7 masing-masing sebesar 76.5% dan 87.6%. Namun, pada rasio data lebih kecil (50:50 dan 60:40), YOLOv7 justru memiliki keunggulan tipis di atas YOLOv8.
3. YOLOv8 unggul dalam kecepatan downloading dan extracting data, terutama pada rasio 80:20 dengan kecepatan download 13.518 it/s dan extracting 7.012 it/s, lebih cepat dibanding YOLOv7 yang hanya 12.701 it/s dan 6.939 it/s. Ini menunjukkan efisiensi dalam pengolahan awal dataset.
4. YOLOv7 unggul dalam hal kecepatan training dan validasi model. Contohnya, pada rasio 70:30, kecepatan training YOLOv7 adalah 2.246 it/s dan validasi 1.683 it/s, sedangkan YOLOv8 lebih rendah dengan 1.794 it/s untuk training dan 1.052 it/s untuk validasi. Ini menunjukkan bahwa meskipun YOLOv8 lebih akurat, prosesnya sedikit lebih lambat.
5. Dari segi efisiensi waktu, YOLOv8 menunjukkan durasi pelatihan yang jauh lebih singkat ketika melakukan training dengan 60 epoch. Pada konfigurasi 80:20, YOLOv8 hanya membutuhkan waktu 1.318 jam dibandingkan dengan YOLOv7 yang membutuhkan 2.313 jam. Hal ini membuktikan bahwa YOLOv8 lebih hemat waktu dalam pelatihan model.
6. Pengujian klasifikasi menggunakan YOLOv8 dengan konfigurasi 80% data latih dan 20% data uji menunjukkan hasil yang memuaskan. Semua kelas (bercak, kuning, keriting, dan sehat) berhasil dideteksi dengan nilai

kepercayaan tinggi, seperti bercak (0.91, 0.90), kuning (0.89, 0.88), keriting (0.89, 0.88), dan sehat (0.88). Meskipun terdapat satu kesalahan prediksi dengan skor rendah (0.30), secara keseluruhan model mampu mengenali kelas dengan baik dan presisi tinggi.

Dengan demikian, YOLOv8 terbukti lebih unggul dalam aspek akurasi, efisiensi waktu pelatihan, dan keandalan klasifikasi, menjadikannya pilihan yang lebih efektif untuk sistem deteksi otomatis penyakit daun pada tanaman cabai.

5.2. Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dipertimbangkan untuk penelitian selanjutnya serta implementasi lebih lanjut dari algoritma YOLOv7 dan YOLOv8 dalam klasifikasi penyakit daun cabai rawit:

1. Diperlukan penelitian lanjutan dengan pengujian dataset lebih variatif dan optimasi efisiensi sumber daya untuk YOLOv7 dan YOLOv8.
2. Dalam penelitian lanjutan, disarankan untuk menambahkan lebih banyak kelas penyakit daun atau buah pada tanaman cabai agar sistem deteksi dapat digunakan secara lebih komprehensif dan aplikatif dalam dunia pertanian.
3. Sebagai pengembangan, model deteksi penyakit daun cabai ini dapat diterapkan dalam bentuk aplikasi mobile atau sistem embedded yang dapat digunakan langsung oleh petani secara real-time di lapangan.
4. Implementasi algoritma YOLOv8 dalam aplikasi dunia nyata seperti deteksi penyakit tanaman dapat memperluas manfaat penelitian ini.
5. Disarankan untuk melakukan validasi lebih lanjut menggunakan data langsung dari lapangan (real field data), agar diketahui sejauh mana model mampu mengatasi noise, pencahayaan tidak ideal, dan kondisi daun yang kompleks.

Dengan menerapkan saran-saran ini, diharapkan penelitian dapat berkembang menjadi sistem deteksi penyakit tanaman yang lebih akurat, cepat, dan praktis untuk membantu sektor pertanian secara nyata.