

BAB V

KESIMPULAN

5.1 Kesimpulan

Penelitian mengenai Sistem Deteksi Kekurangan Nutrisi Daun Cabai menggunakan algoritma *Convolutional Neural Network* (CNN) telah berhasil dilakukan dengan hasil yang cukup baik. Dataset yang digunakan berasal langsung dari lapangan, di mana pengambilan gambar daun cabai dilakukan secara nyata dan pelabelan dilakukan melalui observasi terhadap kondisi tanaman, baik sehat maupun dengan gejala kekurangan unsur hara seperti Nitrogen (N), Fosfor (P), Kalium (K), dan Magnesium (Mg). Hasil pengujian model menunjukkan bahwa CNN mampu melakukan klasifikasi dengan akurasi sebesar 81%, nilai rata-rata *precision* 0.85, *recall* 0.82, dan *F1-Score* 0.80. Beberapa kelas seperti Kekurangan Fosfor (P), Kalium (K), dan Sehat dapat diklasifikasikan dengan sangat baik, namun terdapat tantangan pada kelas Kekurangan Magnesium (Mg) dan Nitrogen (N) yang masih mengalami kesalahan deteksi akibat kemiripan gejala visual. Secara keseluruhan, penelitian ini membuktikan bahwa algoritma *Convolutional Neural Network* (CNN) dapat digunakan untuk mendeteksi kondisi daun cabai dengan hasil yang cukup efektif, meskipun masih diperlukan pengembangan lebih lanjut untuk meningkatkan performa terutama pada kelas yang sulit dibedakan.

5.2 Saran

Berdasarkan hasil pengujian dalam penelitian ini, penulis memberikan beberapa rekomendasi kepada peneliti di masa mendatang untuk meningkatkan efektivitas dan efisiensi sistem deteksi nutrisi daun cabai. Beberapa saran untuk pengembangan penelitian berikutnya antara lain:

1. Peningkatan Kemampuan Model dalam Membedakan Daun Cabai dan Non-Cabai. Mengingat masih terdapat kelemahan sistem dalam membedakan daun cabai dengan daun tanaman lain atau objek yang bukan daun, serta sulitnya membedakan daun cabai sehat dengan cabai yang terserang penyakit, maka

2. pada penelitian berikutnya disarankan untuk menambahkan kelas data pelatihan khusus untuk “bukan daun cabai” dan “daun cabai berpenyakit”. Dengan demikian, sistem dapat lebih selektif dalam melakukan prediksi sehingga tingkat kesalahan dapat diminimalkan[18].
3. Menggunakan arsitektur CNN yang lebih kompleks atau *transfer learning* seperti VGG16, *ResNet*, atau *EfficientNet* untuk meningkatkan akurasi dan generalisasi model[8].
4. Menambahkan fitur integrasi lokasi GPS dan catatan riwayat lahan untuk memudahkan penelusuran rekomendasi pemupukan berdasarkan kondisi geografis lahan petani.
5. Memperluas jumlah kelas prediksi dengan menambahkan jenis defisiensi unsur hara lain seperti Kalsium (Ca), Sulfur (S), atau kombinasi defisiensi ganda.