

## **BAB 5**

### **PENUTUP**

#### **5.1 KESIMPULAN**

Dalam penelitian ini, sebuah sistem telah dilakukan klasifikasi penyakit pada daun jagung dengan metode CNN pada 2 arsitektur, yaitu VGG16 dan VGG19. Penggunaan citra penyakit daun jagung sebagai data uji memberikan hasil sebagai berikut:

1. Penelitian ini melibatkan dua skenario yaitu skenario A menggunakan arsitektur VGG16 dan skenario B menggunakan arsitektur VGG19. Data uji sebanyak 20% dari total citra, sedangkan 80% adalah data latih. Pengujian dilakukan dengan menggunakan *optimizer* SGD karena pada penelitian sebelumnya penggunaan optimasi SGD memiliki hasil yang lebih baik dibandingkan dengan menggunakan optimasi yang lain dan parameter lainnya, seperti *learning rate* sebesar 0,001 dengan 900 *decay steps*, 0.9 *decay rate*, dan *batch size* yaitu 32. Pengujian yang dilakukan adalah optimasi, *resize* dan jumlah *epoch* yang berbeda-beda digunakan pada setiap arsitektur untuk mencapai akurasi tertinggi.
2. Perbandingan antara dua arsitektur tersebut menunjukkan bahwa VGG19 lebih unggul daripada VGG16. Pada arsitektur VGG19, nilai akurasi mencapai 92,74%, *precision* 91%, *recall* 91%, dan *F1-Score* 91% pada *resize* 224x 224 dan *epoch* 50. Sedangkan pada VGG16, akurasi sebesar 92,62%, *precision* 91%, *recall* 89%, dan *F1-Score* 90% pada *resize* 224x 224 dan *epoch* 50. Perbedaan ini disebabkan oleh jumlah *layer* yang berbeda antara VGG16 (16 *layer*) dan VGG19 (19 *layer*). Metode CNN dengan arsitektur VGG16 dan VGG19 memungkinkan klasifikasi penyakit daun jagung dengan sistem *transfer learning*. Dengan adanya pengklasifikasian ini, sistem dapat membantu petani dalam mendeteksi penyakit yang menyerang tanaman jagung.

## 5.2 SARAN

Berdasarkan hasil penelitian ini, penulis memberikan saran untuk mendukung pengembangan penelitian selanjutnya, antara lain:

1. Melakukan perancangan sistem dengan mempertimbangkan penggunaan arsitektur yang lain seperti ResNet50, Mobilenet, dan lain-lain untuk memperluas variasi dan pemahaman tentang performa model yang berbeda.
2. Memperluas parameter pengujian dengan menambahkan variasi optimasi dan nilai *learning rate* yang berbeda pada proses pengujian. Hal ini dapat meningkatkan pemahaman yang lebih mendalam terhadap dampak parameter pada kinerja sistem dan memungkinkan perbandingan yang lebih komprehensif terhadap hasil dari pengujian.