



KLASIFIKASI PENYAKIT DAUN SINGKONG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN ARSITEKTUR VGG16 BERBASIS ANDROID

Annisa Mustika Anggraeni¹, Teguh Iman Hermanto², Imam Maruf Nugroho³

^{1,2,3} Teknik Informatika, Sekolah Tinggi Teknologi Wastukana
Purwakarta, Jawa Barat, Indonesia, 41151

annisamustika20@wastukancana.ac.id , teguhiman@wastukancana.ac.id , imam.ma@wastukancana.ac.id

Abstract

Cassava plants play an important role as a national food source. However, their productivity has declined in recent years due to leaf disease. Manual disease identification is often inaccurate and slow. This study aims to develop an automatic classification system based on digital images to detect cassava leaf disease quickly and accurately. The method used is a Convolutional Neural Network (CNN) with a VGG16 architecture. The system was developed following the CRISP-DM approach and uses tools such as Python, Keras, TensorFlow, and TensorFlow Lite for integration into Android. The model was trained to recognize five leaf conditions: brown spots, bacterial blight, green mite, mosaic, and healthy. Testing over 50 epochs showed an accuracy of 96%, with precision, recall, and F1-score ranging from 0.93 to 0.98. This approach is superior to the research by Setyanto and Ariatmanto, which only achieved an accuracy of 72.84%. This system helps farmers perform early diagnosis by taking or uploading photos of leaves, enabling more effective disease control.

Keywords: Cassava Leaf, Convolutional Neural Network, Disease Detection, Image Classification, VGG16

Abstrak

Tanaman singkong berperan penting sebagai sumber pangan nasional. Namun, produktivitasnya menurun dalam beberapa tahun terakhir akibat penyakit daun. Identifikasi penyakit secara manual sering tidak akurat dan lambat. Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis berbasis citra digital untuk mendeteksi penyakit daun singkong secara cepat dan akurat. Metode yang digunakan adalah *Convolutional Neural Network* (CNN) dengan arsitektur VGG16. Sistem dikembangkan mengikuti pendekatan CRISP-DM dan menggunakan tools seperti Python, Keras, TensorFlow, dan TensorFlow Lite untuk integrasi ke Android. Model dilatih untuk mengenali lima kondisi daun: brown spots, bacterial blight, green mite, mosaic, dan healthy. Pengujian selama 50 epoch menunjukkan akurasi sebesar 96%, dengan precision, recall, dan F1-score pada kisaran 0,93–0,98. Pendekatan ini lebih baik dibandingkan penelitian oleh Setyanto dan Ariatmanto yang hanya mencapai akurasi 72,84%. Sistem ini membantu petani melakukan diagnosis dini melalui pengambilan atau unggah foto daun, sehingga pengendalian penyakit dapat dilakukan secara lebih efektif.

Kata kunci: Convolutional Neural Network, Daun Singkong, Deteksi Penyakit, Klasifikasi Citra, VGG16

1. PENDAHULUAN

Di Indonesia, singkong menjadi salah satu tanaman pertanian yang memiliki peranan strategis yang menempati urutan ketiga setelah padi dan jagung dalam hal konsumsi masyarakat. Tanaman ini dikenal karena kemampuannya bertahan hidup di berbagai kondisi iklim dan jenis tanah, sehingga banyak dibudidayakan di berbagai wilayah [1]. Meskipun demikian, potensi produktivitasnya yang besar belum sepenuhnya dapat dimanfaatkan secara optimal. Berdasarkan data dari Pusat Data dan Sistem Informasi Pertanian, terjadi tren penurunan produksi singkong secara

nasional dalam tiga tahun terakhir, yaitu dari 16,27 juta ton pada tahun 202 menjadi 15,73 juta ton pada tahun 2021, dan terus menurun hingga mencapai 14,98 juta ton pada tahun 2022 [2].

Salah satu penyebab utama penurunan produktivitas tersebut adalah serangan penyakit yang menyerang bagian daun tanaman. Kerusakan pada daun sangat mempengaruhi proses *fotosintesis* yang merupakan fungsi vital bagi pertumbuhan umbi dan batang. Penyakit pada daun singkong umumnya menunjukkan gejala berupa bercak, perubahan warna, serta pola visual yang menyimpang dari

kondisi normal [3]. Identifikasi dini menjadi langkah penting untuk meningkatkan efektivitas dalam pengendalian penyakit tanaman. Namun, dalam praktiknya, sebagian besar petani masih mengandalkan pengamatan visual secara manual yang bersifat subjektif dan rentan terhadap kesalahan identifikasi [4].

Perkembangan teknologi kecerdasan buatan, khususnya dalam bidang *computer vision*, membuka peluang baru dalam mendukung identifikasi penyakit tanaman secara otomatis dan akurat. Salah satu metode yang saat ini banyak digunakan dalam klasifikasi citra adalah *Convolutional Neural Network* (CNN), yang mampu mengenali karakteristik visual seperti bentuk, warna, dan pola tekstur secara mendalam [5]. Di antara berbagai arsitektur CNN yang telah dikembangkan, VGG16 merupakan salah satu yang populer digunakan karena memiliki struktur jaringan yang dalam dan kinerja akurasi yang baik dalam tugas-tugas klasifikasi gambar [6]. Beberapa studi terdahulu telah membuktikan efektivitas CNN dalam mendeteksi penyakit tanaman. Penelitian oleh Setyanto dan Ariatmanto berhasil mengklasifikasikan penyakit daun singkong ke dalam lima kategori menggunakan pendekatan *transfer learning* dengan arsitektur *Inception-V3* dan *EfficientNet-B4*. Model terbaik yang dikembangkan mencapai akurasi validasi sebesar 72,84% dengan performa lebih stabil pada kelas dengan jumlah data lebih besar [7]. Penelitian lainnya memanfaatkan arsitektur VGG16 untuk mengklasifikasikan 31 jenis rempah, dengan hasil akurasi mencapai 88,66% pada data pelatihan dan 84,02% pada data pengujian, menunjukkan performa tinggi meski menghadapi tantangan pada kelas dengan kemiripan visual [8]. Sementara itu, Hasan et al. menggabungkan segmentasi warna LAB, ekstraksi fitur menggunakan VGG16, dan klasifikasi berbasis CNN dalam deteksi penyakit daun anggur, menghasilkan akurasi hingga 97,25% [9].

Di sebagian besar studi terdahulu lebih berfokus pada pemanfaatan model *pre-trained* dan dataset publik, tanpa melanjutkan ke tahap pengembangan aplikasi nyata di lapangan [10][11][12][13].

Oleh karena itu, diperlukan sistem klasifikasi penyakit daun singkong berbasis citra digital yang tidak hanya akurat secara teknis, tetapi juga diwujudkan dalam bentuk aplikasi yang aplikatif dan mudah digunakan oleh petani secara langsung di lapangan untuk mempercepat proses identifikasi penyakit secara mandiri..

CNN bekerja dengan menyusun sejumlah lapisan konvolusional untuk mengekstraksi fitur dari citra input secara hierarkis, diikuti oleh proses klasifikasi melalui lapisan terhubung [14]. Arsitektur VGG16 merupakan arsitektur CNN yang terdiri dari beberapa lapisan konvolusi dan *fully connected* yang berfungsi untuk mengekstraksi dan mengklasifikasi fitur dari citra berukuran 224x224 piksel RGB [15]. Dalam proses pengembangan sistem klasifikasi citra seperti ini, CRISP-DM memberikan alur

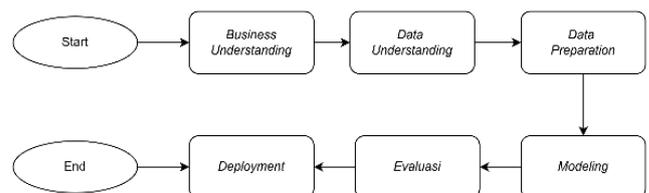
kerja sistematis mulai dari pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, hingga implementasi sistem [16].

Permasalahan yang diangkat dalam penelitian ini adalah belum tersedianya sistem klasifikasi penyakit daun singkong yang dapat digunakan secara praktis oleh petani untuk mengidentifikasi jenis penyakit secara cepat dan tepat. Pengamatan manual yang masih umum digunakan sering kali menimbulkan ketidaktepatan dalam diagnosa penyakit tanaman. Tujuan dari penelitian ini adalah untuk membangun sistem klasifikasi penyakit daun singkong menggunakan arsitektur CNN VGG16 dan mengimplementasikan dalam bentuk aplikasi. Sistem ini dirancang untuk mengenali lima kategori utama, yaitu *Cassava Bacterial Blight*, *Cassava Mosaic Disease*, *Cassava Green Mite*, *Cassava Brown Spot*, dan kondisi *Healthy*.

Ruang lingkup penelitian ini dibatasi pada identifikasi penyakit berdasarkan citra visual daun singkong dalam lima kategori tersebut, tanpa mempertimbangkan pengaruh variabel eksternal seperti iklim, jenis tanah, atau metode budidaya lainnya. Dengan pendekatan ini, diharapkan sistem yang dikembangkan dapat menjadi alat bantu yang efektif bagi petani maupun penyuluh pertanian dalam melakukan identifikasi dini terhadap penyakit daun singkong, sehingga pengambilan tindakan preventif atau kuratif dapat dilakukan dengan lebih cepat dan efisien.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan CRISP-DM sebagai metodologi penelitian dalam pembuatan sistem klasifikasi penyakit daun singkong. Alur metodologi dapat dilihat pada Gambar 1.



Gambar 1. Alur Metodologi CRISP-DM yang digunakan dalam penelitian ini

Sebelum memasuki tahapan utama dalam proses pembuatan sistem, penelitian ini diawali dengan kegiatan pengumpulan data dan telaah terhadap berbagai studi terdahulu yang relevan.

2.1 Business Understanding

Tahap ini berfokus pada identifikasi konteks permasalahan dan urgensi pembuatan sistem deteksi penyakit daun singkong secara otomatis berbasis citra digital. Permasalahan utama yang diangkat adalah kesulitan petani dalam mengenali jenis penyakit pada tanaman singkong secara manual, yang disebabkan oleh keterbatasan pengetahuan teknis serta minimnya akses terhadap tenaga ahli.

2.2 Data Understanding

Pada tahap ini bertujuan untuk memahami struktur dan karakteristik dataset yang digunakan dalam proses pelatihan model. Dataset diperoleh dari platform *Kaggle* dan diunduh melalui API ke dalam *Google Colab* untuk mendukung efisiensi pengolahan data. Dataset terdiri atas 7.508 citra digital berwarna (RGB) yang terbagi ke dalam lima kategori, yaitu *Cassava Bacterial Blight* (2.614 citra), *Cassava Brown Spot* (1.481 citra), *Cassava Green Mite* (1.015 citra), *Cassava Mosaic* (1.205 citra), dan *Cassava Healthy* (1.193 citra). Struktur dataset tersusun dalam direktori yang dikelompokkan berdasarkan label kelas, sehingga memudahkan proses identifikasi dan klasifikasi selama tahap pemodelan. Contoh citra dari setiap kategori ditampilkan pada Gambar 2.



Gambar 2. Visualisasi Contoh Kelas Citra Daun Singkong

2.3 Data Preparation

Tahapan ini bertujuan untuk menyiapkan data agar memenuhi kriteria yang dibutuhkan dalam proses pelatihan model. Tiga langkah utama dilakukan, yaitu:

1. Persiapan Data

Dataset dibagi menjadi tiga *subset*, yakni data latih (80%), data validasi (10%), dan data uji (10%). Strategi ini bertujuan untuk melatih model secara optimal, melakukan validasi selama proses pelatihan, serta menguji performa model terhadap data yang belum pernah dikenali sebelumnya.

2. Augmentasi Data

Untuk meningkatkan variasi dan jumlah data latih, dilakukan augmentasi citra melalui berbagai transformasi seperti *rotasi*, *translasi*, *shear*, *zoom*, dan pembalikan *horizontal* hingga 20%. Tujuan dari proses ini adalah memperluas distribusi data sehingga model dapat melakukan generalisasi dengan lebih baik terhadap data baru.

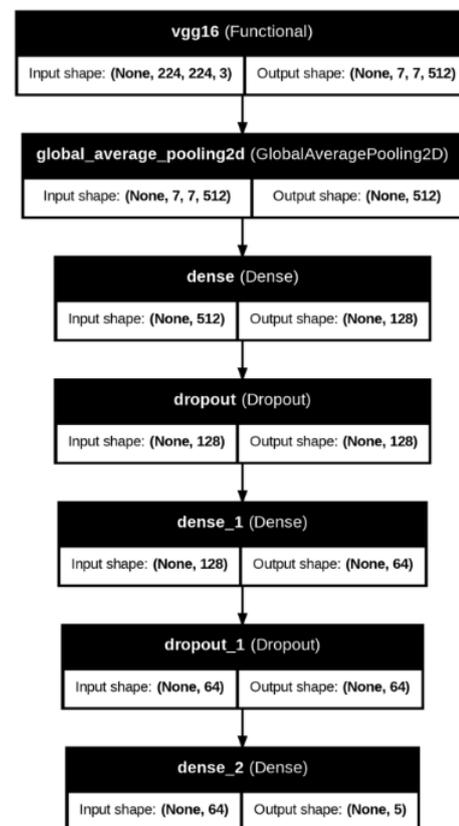
3. Penyesuaian Ukuran Citra

Seluruh citra diubah ukurannya menjadi 224x224 piksel agar sesuai dengan kebutuhan input arsitektur CNN yang digunakan, khususnya VGG16. Penyeragaman ini juga

bertujuan untuk menjaga konsistensi dimensi dan efisiensi proses komputasi selama pelatihan.

2.4 Modeling

Proses pemodelan sistem klasifikasi citra daun singkong dalam penelitian ini dilakukan dengan menerapkan algoritma *Convolutional Neural Network* (CNN). Seluruh proses pelatihan dan evaluasi dilakukan menggunakan platform *Google Colab* dengan dukungan pustaka TensorFlow dan Keras berbasis bahasa pemrograman *Python*, yang memungkinkan komputasi GPU untuk mempercepat proses *training*. Arsitektur VGG16 diadopsi sebagai model dasar untuk mengekstraksi fitur visual dari citra. Struktur model ditampilkan pada Gambar 3.



Gambar 3. Model Arsitektur VGG16

2.5 Evaluasi

Dilakukan untuk mengukur kinerja model klasifikasi yang telah dibangun. Beberapa metrik evaluasi digunakan, meliputi *confusion matrix*, *precision*, *recall*, dan *F1-score*, guna memberikan gambaran menyeluruh terhadap tingkat akurasi, sensitivitas, dan keseimbangan performa model dalam mengklasifikasikan berbagai kategori penyakit daun singkong.

a. Confusion Matrix

Merupakan *matriks* kontingensi yang merepresentasikan keluaran klasifikasi model secara kuantitatif terhadap kondisi riil objek uji, dalam hal ini

citra daun singkong. *Matriks* ini terdiri atas empat parameter utama sebagai berikut:

True Positive (TP): Citra daun singkong yang memang terindikasi penyakit dan diklasifikasikan secara tepat sebagai positif.

True Negative (TN): Citra daun yang sehat dan dikenali secara akurat oleh sistem sebagai negatif (tidak terinfeksi).

False Positive (FP): Citra daun yang secara aktual tidak menunjukkan gejala penyakit, namun sistem secara keliru menandainya sebagai positif.

False Negative (FN): Citra daun yang mengandung penyakit tetapi gagal dikenali oleh sistem sehingga diklasifikasikan sebagai sehat.

b. *Precision*

Mencerminkan proporsi prediksi positif yang bersifat akurat atau relevan, dihitung dengan membandingkan jumlah kasus positif yang tepat dengan total prediksi positif yang dihasilkan.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

c. *Recall*

Menggambarkan kemampuan sistem dalam mengidentifikasi seluruh entitas yang benar-benar positif, khususnya pada konteks klasifikasi penyakit.

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

d. *F1-Score*

Merupakan ukuran harmonik rata-rata antara *precision* dan *recall*, yang berperan penting ketika keseimbangan antara keduanya dibutuhkan dalam konteks diagnosis citra.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

2.6 *Deployment*

Tahap implementasi menandai fase akhir dalam proses pembangunan sistem, di mana model yang telah dilatih dan dievaluasi diintegrasikan ke dalam aplikasi berbasis Android melalui konversi ke format *TensorFlow Lite*. Aplikasi ini memungkinkan pengguna melakukan klasifikasi dengan mengunggah atau mengambil gambar daun secara langsung melalui kamera dan galeri di perangkat. Hasil klasifikasi disajikan dalam bentuk label nama penyakit yang terdeteksi beserta deskripsi informatif, sehingga siap dimanfaatkan secara praktis oleh pengguna, khususnya petani atau pelaku pertanian dalam kegiatan identifikasi penyakit daun singkong secara cepat dan efisien.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Eksperimen

Implementasi arsitektur VGG16 dalam CNN pada penelitian ini menghasilkan beberapa *output* yang dapat dilihat dan dievaluasi sebagaimana Gambar 4 dan Gambar 5 berikut:

1. Eksplorasi Akurasi Model



Gambar 4. Tren Akurasi pada Proses Pembelajaran

Pada Gambar 4 tampak tren peningkatan signifikan dalam tingkat akurasi pada data pelatihan maupun data validasi selama 50 *epoch*. Terjadi percepatan perbaikan di awal pelatihan, kemudian melandai mendekati nilai maksimum. Fakta bahwa kurva validasi stabil di atas kurva pelatihan mengindikasikan kemampuan model dalam mengenali pola baru tanpa menunjukkan tanda-tanda *overfitting*.

2. Penelusuran *Loss* Model



Gambar 5. Evaluasi Nilai *Loss* pada Tahap Pelatihan

Sesuai dengan Gambar 5, nilai *loss* pada kedua data menunjukkan penurunan yang konsisten sepanjang pelatihan. Penurunan yang cepat di fase awal berlanjut menuju kestabilan, dengan *loss* validasi tetap berada di bawah *loss* pelatihan, tanda bahwa model memiliki kemampuan generalisasi yang baik tanpa cenderung *overfitting* ataupun *underfitting*.

3. Metrik Evaluasi Berdasarkan Kategori

```

=== Classification Report ===
              precision    recall  f1-score   support

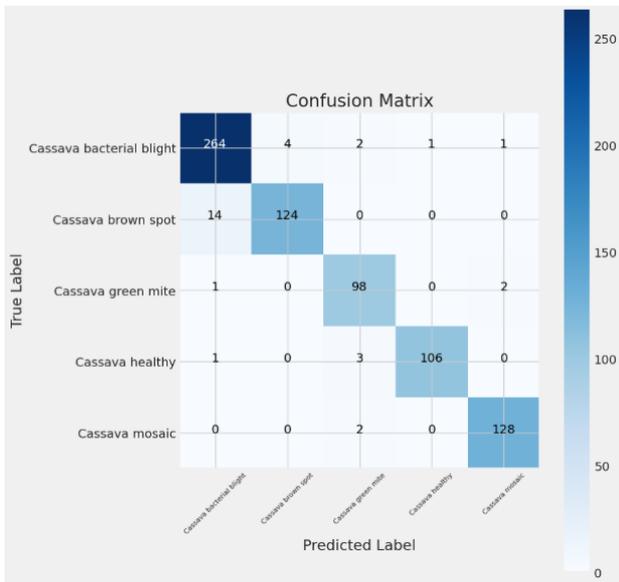
Cassava bacterial blight    0.94    0.97    0.96     272
Cassava brown spot         0.97    0.90    0.93     138
Cassava green mite         0.93    0.97    0.95     101
Cassava healthy            0.99    0.96    0.98     110
Cassava mosaic             0.98    0.98    0.98     130

   accuracy                   0.96     751
  macro avg                   0.96     751
 weighted avg                  0.96     751
    
```

Gambar 6. Pemetaan Kuantitatif Presisi, Recall dan F1-score

Berdasarkan visualisasi pada Gambar 6, model mencapai akurasi keseluruhan sebesar 96%. Metrik *precision*, *recall*, dan *F1-score* pada masing-masing kelas berada dalam kisaran 0,93–0,98. Kelas “*Cassava Healthy*” serta “*Cassava Mosaic*” menunjukkan performa paling unggul, sedangkan kelas “*Cassava Brown Spot*” memperoleh nilai *recall* terendah. Keseimbangan nilai rata-rata makro dan tertimbang, keduanya 0,96, mengindikasikan distribusi performa yang merata antar kelas.

4. Analisis Matriks Klasifikasi Daun Singkong



Gambar 7. Confusion Matrix

Visualisasi *confusion matrix* pada Gambar 7 memperlihatkan bahwa model cenderung mengelompokkan data secara akurat, ditunjukkan oleh dominasi nilai tinggi pada diagonal utama. Prediksi benar paling menonjol terdapat pada kelas *Cassava bacterial blight* (264 data), *Cassava mosaic* (128 data), dan *Cassava healthy* (106 data). Meskipun demikian, masih terdapat pergeseran klasifikasi, terutama pada kelas *Cassava brown spot* yang sejumlah 14 data dikenali sebagai *Cassava bacterial blight*. Namun, penyebaran kesalahan bersifat minor dan tidak terpusat pada satu pola tertentu. Secara keseluruhan, persebaran nilai dalam matriks menunjukkan bahwa model memiliki respons yang stabil dalam membedakan kelima kelas, tanpa menunjukkan kecenderungan bias signifikan terhadap salah satu kategori.

5. Penerapan Aplikasi



Gambar 8. Tampilan Halaman Utama Aplikasi

Pada Gambar 8 merupakan tampilan halaman utama aplikasi yang terdapat beberapa jenis penyakit daun singkong yang bisa diakses. Serta menu info aplikasi dan menu untuk memulai deteksi penyakit daun singkong.



Gambar 9. Tampilan Halaman Deteksi Penyakit

Pada Gambar 9 merupakan tampilan halaman deteksi, di mana pengguna dapat mengambil gambar dari galeri atau kamera untuk dilakukan klasifikasi penyakit daun singkong. Setelah gambar dipilih, aplikasi akan mendeteksi penyakit daun tersebut serta akan menampilkan hasil klasifikasi berupa penyakit daun singkong, hasil akurasi dan detail penyakit untuk mengetahui lebih lanjut mengenai penyakit tersebut.



Gambar 10. Tampilan Halaman Detail Penyakit

Pada Gambar 10 merupakan tampilan halaman detail penyakit berupa penjelasan, gejala, dan penanganan.

Pada hasil penerapan aplikasi memperlihatkan antarmuka utama layar hasil deteksi serta detail penyakit pada aplikasi Android. Aplikasi ini mengintegrasikan model VGG16 yang sudah diubah ke format *TensorFlow Lite*, sehingga pengguna dapat langsung mengunggah atau memotret daun singkong, lalu mendapatkan prediksi secara instan dan pengguna bisa melihat penjelasan penyakit secara informatif.

3.2 Pembahasan

Hasil yang diperoleh menunjukkan bahwa arsitektur VGG16 memberikan performa yang sangat baik dalam klasifikasi penyakit daun singkong. Akurasi keseluruhan sebesar 96%, disertai dengan nilai *precision*, *recall*, dan *f1-score* yang konsisten pada rentang 0,93-0,98, menegaskan stabilitas dan akurasi model dalam mengenali pola visual dari berbagai jenis penyakit daun. Kurva akurasi dan *loss* yang stabil serta tidak menunjukkan tanda-tanda *overfitting* menunjukkan bahwa proses pelatihan berlangsung optimal.

Jika dibandingkan dengan penelitian oleh Setyanto dan Ariatanto [7], yang menggunakan *transfer learning* dengan arsitektur *Inception-V3* dan *EfficientNet-B4* dan hanya mencapai akurasi validasi sebesar 72,84%, pendekatan yang digunakan dalam penelitian ini menunjukkan peningkatan signifikan. Hal ini menunjukkan bahwa pelatihan dari awal menggunakan VGG16, dikombinasikan dengan strategi augmentasi data dan penyesuaian *preprocessing*, mampu memberikan hasil yang lebih unggul dan stabil di seluruh kelas.

Selain peningkatan performa model, kontribusi penting dari penelitian ini terletak pada implementasi praktisnya. Berbeda dengan sebagian besar penelitian terdahulu yang

hanya fokus pada tahap pengembangan model dan pengujian terbatas, penelitian ini mengintegrasikan model klasifikasi ke dalam sebuah aplikasi Android yang dapat digunakan secara langsung di lapangan. Aplikasi tersebut memanfaatkan format *TensorFlow Lite*, sehingga dapat berjalan secara lokal tanpa memerlukan koneksi internet maupun perangkat keras khusus.

Kebermanfaatan ini sangat signifikan, terutama bagi petani di wilayah terpencil yang memiliki keterbatasan akses terhadap teknologi dan tenaga ahli. Dengan bantuan aplikasi ini, petani dapat melakukan identifikasi penyakit secara mandiri hanya melalui pengambilan gambar daun menggunakan kamera *smartphone*. Hal ini tidak hanya meningkatkan kecepatan dalam diagnosis, tetapi juga memungkinkan tindakan pengendalian dilakukan lebih awal, yang pada akhirnya berkontribusi pada peningkatan produktivitas tanaman singkong.

4. KESIMPULAN

Implementasi arsitektur VGG16 dalam klasifikasi penyakit daun singkong menghasilkan performa yang stabil dan efektif. Konsistensi grafik akurasi dan *loss* selama 50 *epoch* mengindikasikan proses pembelajaran yang optimal tanpa kebocoran data atau ketidakmampuan memahami pola. Analisis kuantitatif mengungkap akurasi tinggi (96%) dan metrik pendukung (*precision*, *recall*, *F1-score*) yang kuat dan seragam di semua kelas. *Matriks* klasifikasi mempertegas keandalan model dalam mengenali kategori-aplikasi yang benar, dengan kesalahan minimal. Keberhasilan model dalam bentuk aplikasi menunjukkan relevansi praktis dan kesiapan untuk implementasi lapangan, membuka jalan bagi solusi diagnostik *mobile* yang dapat digunakan petani secara langsung. Untuk penelitian selanjutnya, pengembangan dapat diarahkan pada klasifikasi gejala multipenyakit, deteksi otomatis tingkat keparahan, serta integrasi sistem pemantauan berbasis *cloud* guna mendukung pengambilan keputusan kolektif oleh penyuluh pertanian.

DAFTAR PUSTAKA

- [1] A. Fahrezantara, S. Rizal, N. Kumalasari, and C. Pratiwi, "Pemanfaatan *Convolutional Neural Network* Dalam Klasifikasi Penyakit Tanaman Singkong Menggunakan Arsitektur Densenet Use Of *Convolutional Neural Networks* On Classifying Cassava Diseases With Densenet Architecture," 2022.
- [2] Pusat Data dan Sistem Informasi Pertanian, "Buku Statistik Penunjang Data Ekonomi Pertanian, 2023 Pusat Data dan Sistem Informasi Pertanian," 2023.
- [3] H. R. Ayu, A. Surtono, and D. K. Apriyanto, "Deep learning for detection cassava leaf disease," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Jan. 2021. doi: 10.1088/1742-6596/1751/1/012072.

- [4] J. Tandean, R. Indrawan, I. Intan, and S. Arifin Ramadhani, "Pengaruh Penerapan Stochastic Gradient Descent Dan Adam Optimizer Pada Hyperparameter Tuning Untuk Klasifikasi Penyakit Tanaman Ubi Kayu," 2023.
- [5] A. Tsany and R. Dzaky, "Deteksi Penyakit Tanaman Cabai Menggunakan Metode *Convolutional Neural Network*," 2021.
- [6] N. B. Pamungkas and A. Suhendar, "Penerapan Metode *Convolutional Neural Network* pada Sistem Klasifikasi Penyakit Tanaman Apel berdasarkan Citra Daun," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, pp. 675–684, Dec. 2024, doi: 10.29408/edumatic.v8i2.27958.
- [7] T. Anton, A. Setyanto, and D. Ariatmanto, "Penerapan Transfer Learning dengan Inception-V3 Dan Efficientnet-B4 Pada Studi Kasus Klasifikasi Penyakit Pada Daun Singkong," 2024. [Online]. Available: <https://www.kaggle.com/datasets/gauravduttakiit/cassava-leaf-disease-classification>.
- [8] R. Maulana, R. D. Z. Putri, T. A. Amelia, H. Syahputra, and F. Ramadhani, "Identifikasi Jenis Rempah-Rempah Indonesia dengan *Convolutional Neural Network* (CNN) menggunakan Arsitektur VGG16," *JATI*, vol. 8, no. 4, pp. 6034–6039, 2024.
- [9] M. A. Hasan, Y. Riyanto, and D. Riana, "Klasifikasi Penyakit Citra Daun Anggur Menggunakan Model CNN-VGG16," *Jurnal Teknologi dan Sistem Komputer*, vol. 9, no. 4, pp. 218–223, Oct. 2021, doi: 10.14710/jtsiskom.2021.14013.
- [10] F. A. Arafat, M. N. Ichsan, and M. F. Pramoeद्या, "Pemanfaatan Arsitektur MOBILENET-CNN Untuk Mendiagnosis Penyakit Pada Daun Singkong Melalui Teknologi Citra Digital," *Stains*, vol. 4, no. 1, pp. 73–78, 2025.
- [11] G. A. Pratama, E. Y. Puspaningrum, and H. Maulana, "*Convolutional Neural Network* dan faster region *Convolutional Neural Network* untuk klasifikasi kualitas biji kopi arabika," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4887.
- [12] M. D. Pratama, R. Gustriansyah, and E. Purnamasari, "Klasifikasi Penyakit Daun Pisang Menggunakan *Convolutional Neural Network* (CNN)," 2024.
- [13] E. L. I. P. Sari, "Revitalizing Strawberry Leaves: Developing a Tipburn and Leaf Spot Disease Detection System Through Convolution Analysis Using CNN Method," *JIMPS: Jurnal Ilmiah Mahasiswa Pendidikan Sejarah*, vol. 8, no. 3, pp. 1468–1474, 2023, doi: 10.24815/jimps.v8i3.25210.
- [14] I. N. Husna, M. Ulum, A. K. Saputro, Haryanto, D. T. Laksono, and D. N. Purnamasari, "Rancang Bangun Sistem Deteksi dan Perhitungan Jumlah Orang Menggunakan Metode *Convolutional Neural Network* (CNN)," *Seminar Nasional Fortei Regional*, vol. 5, 2022.
- [15] A. Z. Noorizki and W. I. Kusumawati, "Perbandingan Performa Algoritma VGG16 Dan VGG19 Melalui Metode CNN Untuk Klasifikasi Varietas Beras," *Journal of Computer, Electronic, and Telecommunication*, vol. 4, no. 2, Dec. 2023, doi: 10.52435/complete.v4i2.387.
- [16] Y. Yudiana, A. Y. Agustina, and dan N. Khofifah, "Prediksi Customer Churn Menggunakan Metode CRISP-DM Pada Industri Telekomunikasi Sebagai Implementasi Mempertahankan Pelanggan," 2023. [Online]. Available: <http://ejournal.lp2m.uinjambi.ac.id/ojp/index.php/ijoieb>