

Implementasi Arsitektural Resnet-34 Dalam Klasifikasi Gambar Penyakit Pada Daun Kentang

Made Doddy Adi Pranatha¹, M Azman Maricar², Gede Herdian Setiawan³

¹Program Studi Bisnis Digital, Fakultas Bisnis dan Vokasi, Institut Teknologi dan Bisnis STIKOM Bali

^{2,3}Program Studi Sistem Komputer, Fakultas Informatika dan Komputer, Institut Teknologi dan Bisnis STIKOM Bali

¹doddy@stikom-bali.ac.id, ²azman@stikom-bali.ac.id ³herdian@stikom-bali.ac.id

Submitted: 09-06-2024, Reviewed: 15-06-2024, Accepted 04-07-2024

<https://doi.org/10.47233/jteksis.v6i3.1431>

Abstract

Potato leaf diseases such as early blight and late blight pose significant threats to crop yields. Early and accurate identification of these diseases can help farmers take appropriate actions to control their spread. This research developed a method for image classification using the Residual Network (ResNet) architecture to identify potato leaf diseases. The aim is to develop a model capable of classifying potato leaves into three categories: early blight, late blight, and healthy, with high accuracy. The method used is ResNet-34, a CNN architecture that addresses the vanishing gradient problem and allows training of very deep networks. The dataset consists of 2152 images of potato leaves. Data augmentation was performed to increase dataset diversity and prevent overfitting, along with hyperparameter optimization to maximize model performance. Model evaluation includes accuracy, precision, recall, and F1 score. The research results show that ResNet-34 achieved 97% accuracy on test data, with precision of 0.9629, recall of 0.9630, and F1 score of 0.9628 after 50 training epochs. In conclusion, the CNN architecture with ResNet-34 is effective in classifying potato leaf diseases and shows great potential in plant disease image classification applications. Future research can focus on improving the performance and application of this developed model.

Keywords: Deep Learning, Resnet-34, CNN, Potato Leaf Disease, Image Classification.

Abstrak

Penyakit daun kentang seperti early blight dan late blight merupakan ancaman signifikan bagi hasil panen. Identifikasi dini dan akurat terhadap penyakit ini dapat membantu petani mengambil tindakan yang tepat untuk mengendalikan penyebaran penyakit. Penelitian ini mengembangkan metode klasifikasi gambar menggunakan arsitektur Residual Network (ResNet) untuk mengidentifikasi penyakit daun kentang. Tujuannya adalah mengembangkan model yang mampu mengklasifikasikan daun kentang ke dalam tiga kelas: early blight, late blight, dan healthy dengan akurasi tinggi. Metode yang digunakan adalah ResNet-34, arsitektur CNN yang mengatasi masalah vanishing gradient dan memungkinkan pelatihan jaringan yang sangat dalam. Dataset terdiri dari 2152 gambar daun kentang. Augmentasi data dilakukan untuk meningkatkan keragaman dataset dan mencegah overfitting, serta optimisasi hyperparameter untuk memaksimalkan performa model. Evaluasi model meliputi akurasi, precision, recall, dan F1 score. Hasil penelitian menunjukkan bahwa ResNet-34 mencapai akurasi 97% pada data uji, dengan nilai precision 0.9629, recall 0.9630, dan F1 score 0.9628 setelah 50 epoch pelatihan. Kesimpulannya, arsitektur CNN dengan ResNet-34 efektif dalam mengklasifikasikan penyakit daun kentang dan memiliki potensi besar dalam aplikasi klasifikasi gambar penyakit tanaman. Penelitian di masa depan dapat difokuskan pada peningkatan kinerja dan aplikasi model ini.

Keywords: Deep Learning, Resnet-34, CNN, Penyakit Daun Kentang, Klasifikasi Gambar.

This work is licensed under Creative Commons Attribution License 4.0 CC-BY International license



PENDAHULUAN

Klasifikasi gambar merupakan salah satu aplikasi utama dari pembelajaran mendalam (deep learning) yang telah menunjukkan performa luar biasa dalam berbagai bidang, termasuk pengenalan objek, deteksi wajah, dan diagnosis medis. Dalam konteks pertanian, klasifikasi gambar dapat digunakan untuk mendeteksi penyakit tanaman secara otomatis, yang sangat penting untuk meningkatkan produktivitas dan efisiensi manajemen pertanian. Salah satu penyakit pada tanaman yang signifikan adalah penyakit daun kentang.

Penyakit daun kentang seperti *early blight* dan *late blight* merupakan ancaman signifikan bagi hasil

panen. Identifikasi dini dan akurat terhadap penyakit ini dapat membantu petani mengambil tindakan yang tepat untuk mengendalikan penyebaran penyakit dan mengurangi kerugian. Teknik tradisional untuk identifikasi penyakit tanaman seringkali memerlukan keahlian khusus dan dapat memakan waktu, sehingga penggunaan teknologi pembelajaran mendalam dapat menjadi solusi yang efektif, salah satunya adalah penggunaan arsitektur Residual Network (ResNet).

Arsitektur Residual Network (ResNet), yang diperkenalkan oleh He et al. [1], telah menjadi salah satu arsitektur jaringan saraf konvolusional yang paling efektif dan banyak digunakan. ResNet mengatasi masalah vanishing gradient yang sering

terjadi pada jaringan yang sangat dalam dengan memperkenalkan residual blocks, yang memungkinkan pelatihan jaringan yang jauh lebih dalam tanpa kehilangan akurasi [1]. ResNet-34, salah satu varian dari ResNet, telah digunakan dalam berbagai aplikasi klasifikasi gambar dan menunjukkan hasil yang mengesankan dalam hal akurasi dan efisiensi [1].

Dalam penelitian ini, dikembangkan dan diimplementasikan metode klasifikasi gambar menggunakan ResNet-34 untuk mengidentifikasi penyakit daun kentang dengan dataset yang terdiri dari 2152 gambar daun kentang yang dikategorikan ke dalam tiga kelas: early blight, late blight, dan healthy. Model dilatih menggunakan teknik augmentasi data dan optimisasi hyperparameter untuk meningkatkan performa model. Dengan dilakukannya penelitian ini diharapkan mampu menghasilkan model klasifikasi yang memiliki akurasi yang baik.

Beberapa penelitian sebelumnya telah menunjukkan keberhasilan penggunaan ResNet dalam klasifikasi penyakit tanaman. Penelitian mengenai klasifikasi gambar dan deteksi penyakit tanaman menggunakan pembelajaran mendalam telah menunjukkan kemajuan yang signifikan dalam beberapa tahun terakhir. Salah satu tonggak penting dalam bidang ini adalah pengembangan Convolutional Neural Networks (CNNs) yang berhasil diterapkan dalam berbagai aplikasi, termasuk pengenalan objek, deteksi wajah, dan analisis citra medis. CNNs memiliki kemampuan untuk secara otomatis mengekstraksi fitur dari data gambar tanpa memerlukan intervensi manual, yang menjadikannya alat yang sangat efektif untuk tugas-tugas klasifikasi gambar [2].

Dalam konteks penyakit tanaman, penelitian oleh Mohanty et al. [3] menjadi salah satu yang pertama mengaplikasikan CNNs untuk mendeteksi penyakit tanaman. Mereka menggunakan jaringan saraf konvolusional untuk mengklasifikasikan gambar daun dari berbagai tanaman yang terinfeksi penyakit, dan berhasil mencapai tingkat akurasi yang sangat tinggi, yaitu sekitar 99.35% [3]. Ini menunjukkan bahwa pembelajaran mendalam dapat secara efektif mengenali pola-pola penyakit pada daun tanaman.

Selanjutnya, Zhang et al. [4] menggunakan arsitektur ResNet, yang diperkenalkan oleh He et al. [1], untuk mendeteksi penyakit pada daun sayuran. ResNet mengatasi masalah vanishing gradient yang sering terjadi pada jaringan yang sangat dalam dengan memperkenalkan residual blocks, yang memungkinkan pelatihan jaringan yang jauh lebih dalam tanpa kehilangan akurasi [1]. Penelitian ini menunjukkan bahwa ResNet-50 mampu mencapai akurasi sekitar 98.6% dalam klasifikasi penyakit daun sayuran, yang lebih baik dibandingkan dengan

arsitektur CNN tradisional [4]. Hasil ini menegaskan bahwa ResNet dapat meningkatkan akurasi klasifikasi penyakit tanaman dengan lebih efektif.

Penelitian terkait penyakit daun kentang, seperti yang didokumentasikan oleh Jones [5] dan Fry [6], menunjukkan bahwa early blight dan late blight adalah dua penyakit utama yang mempengaruhi produksi kentang. Early blight, disebabkan oleh *Alternaria solani*, menyebabkan bercak-bercak hitam pada daun, batang, dan buah kentang, yang mengurangi kemampuan fotosintesis tanaman. Late blight, disebabkan oleh *Phytophthora infestans*, adalah penyakit yang lebih parah yang dapat menghancurkan seluruh tanaman dalam kondisi lembap. Penelitian ini menekankan pentingnya deteksi dini dan akurat untuk mengurangi kerugian panen dan meningkatkan produktivitas.

Penelitian oleh Too et al. [7] juga menyoroti pentingnya pembelajaran mendalam dalam deteksi penyakit tanaman. Mereka membandingkan beberapa arsitektur CNN, termasuk VGG16, InceptionV3, dan ResNet50, untuk klasifikasi penyakit daun tanaman dan menemukan bahwa ResNet50 mencapai akurasi terbaik dengan 97.13% [7]. Ini menunjukkan keunggulan ResNet dalam menangani tugas-tugas klasifikasi gambar yang kompleks.

Selain itu, augmentasi data dan optimisasi hyperparameter memainkan peran penting dalam meningkatkan kinerja model pembelajaran mendalam. Shorten dan Khoshgoftar [8] menekankan bahwa teknik augmentasi data seperti rotasi, flipping, zooming, dan translasi dapat membantu mencegah overfitting dan meningkatkan generalisasi model. Bergstra dan Bengio [9] menunjukkan bahwa optimisasi hyperparameter melalui pencarian acak dan pencarian grid dapat secara signifikan meningkatkan kinerja model pembelajaran mendalam.

Liu et al. [10] mengeksplorasi penggunaan DenseNet untuk deteksi penyakit tanaman dan menemukan bahwa DenseNet dapat mencapai akurasi yang tinggi dengan jumlah parameter yang lebih sedikit dibandingkan dengan ResNet. Penelitian ini menunjukkan bahwa arsitektur yang lebih dalam dan padat dapat memberikan hasil yang lebih baik dalam beberapa kasus.

Penelitian oleh Sladojevic et al. [11] menggunakan CNN untuk deteksi penyakit tanaman dan menunjukkan bahwa model mereka dapat mengenali berbagai penyakit pada daun dengan akurasi tinggi. Mereka menggunakan dataset besar yang mencakup berbagai jenis tanaman dan penyakit, yang membantu meningkatkan generalisasi model.

Yu et al. [12] mengusulkan metode baru untuk segmentasi dan klasifikasi penyakit daun menggunakan kombinasi CNN dan Conditional

Random Fields (CRF). Metode ini menunjukkan peningkatan dalam deteksi dan klasifikasi yang lebih akurat dibandingkan dengan metode CNN saja.

Ferentinos [13] mengembangkan model CNN yang dilatih dengan gambar penyakit tanaman dari berbagai sumber dan menunjukkan bahwa model ini dapat mencapai akurasi tinggi dalam mendeteksi berbagai jenis penyakit tanaman. Mereka juga menekankan pentingnya data yang bervariasi untuk meningkatkan kinerja model.

Ghosal et al. [14] mengembangkan sistem berbasis CNN untuk deteksi penyakit tanaman yang dapat diintegrasikan dengan aplikasi mobile. Sistem ini memungkinkan petani untuk mengambil gambar daun dan mendapatkan diagnosis penyakit secara real-time.

Singh et al. [15] membandingkan beberapa arsitektur CNN untuk deteksi penyakit daun dan menemukan bahwa arsitektur InceptionV3 memberikan kinerja yang sangat baik dalam hal akurasi dan efisiensi komputasi.

Arsenovic et al. [16] menggunakan transfer learning untuk meningkatkan kinerja model deteksi penyakit tanaman. Mereka menunjukkan bahwa menggunakan model yang telah dilatih sebelumnya pada dataset besar dapat secara signifikan meningkatkan akurasi deteksi penyakit.

Sun et al. [17] mengusulkan penggunaan attention mechanism dalam arsitektur CNN untuk meningkatkan kinerja deteksi penyakit tanaman. Penelitian mereka menunjukkan bahwa mekanisme perhatian dapat membantu model untuk fokus pada bagian gambar yang relevan dengan penyakit.

Nagaraju dan Chawla [18] menggunakan metode hybrid yang menggabungkan fitur dari CNN dan metode klasifikasi tradisional untuk mendeteksi penyakit tanaman. Mereka menunjukkan bahwa pendekatan hybrid ini dapat meningkatkan kinerja dibandingkan dengan penggunaan CNN saja.

Walleign et al. [19] mengembangkan sistem berbasis CNN untuk mendeteksi penyakit tanaman dan menunjukkan bahwa sistem ini dapat diimplementasikan pada perangkat mobile dengan akurasi tinggi.

Kamilaris dan Prenafeta-Boldú [20] melakukan survei komprehensif tentang penggunaan pembelajaran mendalam dalam pertanian dan menemukan bahwa teknologi ini memiliki potensi besar untuk berbagai aplikasi, termasuk deteksi penyakit tanaman.

Rizky dan Ardiansyah[21] menggunakan Random Forest menunjukkan tingkat akurasi sebesar 97.02%. Sedangkan metode CNN dengan menggunakan ResNet50 menunjukkan tingkat akurasi yang lebih tinggi, yaitu antara 98.75% - 100%. Dengan demikian, penelitian ini mengkonfirmasi keunggulan CNN dalam proses

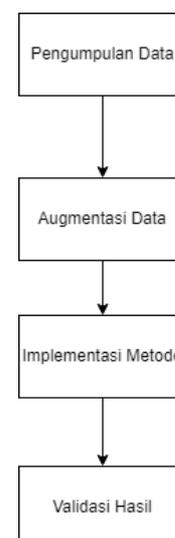
klasifikasi ini, dan menunjukkan potensi untuk penggunaan lebih lanjut dalam pendeteksian dini penyakit jantung.

Penelitian yang dilakukan oleh Enggari dan Ramadhanu[22] mengeksplorasi penerapan teknik pengolahan citra digital, termasuk segmentasi warna, deteksi tepi, dan analisis kontur, untuk mendeskripsikan jamur dan menentukan kelayakan konsumsi jamur tersebut. Dengan menggunakan Back Propagation Neural Network (BPNN), penelitian ini mencapai akurasi sebesar 80% dalam mengklasifikasikan jamur yang dapat dimakan dan yang tidak dapat dimakan. Sistem ini bertujuan untuk mengurangi insiden keracunan jamur dengan menyediakan metode yang andal untuk membedakan antara jamur yang aman dan beracun.

Penelitian ini memperkenalkan pendekatan baru dalam klasifikasi penyakit pada daun kentang menggunakan arsitektur ResNet-34, dengan memanfaatkan dataset terbaru dari Kaggle yang mencakup berbagai jenis penyakit daun kentang. Keunggulan ResNet-34 dalam mengatasi masalah degradasi jaringan dalam memungkinkan pelatihan model yang lebih dalam dan akurat. Penelitian ini juga menggunakan teknik augmentasi data dan fine-tuning untuk mengoptimalkan kinerja model. Dengan pendekatan ini, diharapkan dapat meningkatkan akurasi deteksi penyakit daun kentang, memberikan kontribusi signifikan dalam pengembangan sistem deteksi dini berbasis AI yang dapat diterapkan dalam industri pertanian untuk meningkatkan produktivitas dan mengurangi kerugian ekonomi akibat penyakit tanaman.

METODE PENELITIAN

Penelitian ini bertujuan untuk mengembangkan model klasifikasi gambar menggunakan ResNet-34 untuk mendeteksi penyakit daun kentang dengan akurasi tinggi. Tahapan penelitian yang akan dilakukan ditunjukkan pada gambar 1.



Gambar 1. Tahapan Penelitian

Metode penelitian menjelaskan pendekatan, rancangan kegiatan, ruang lingkup atau objek, bahan dan alat utama, tempat, teknik pengumpulan data, definisi operasional variabel penelitian, dan teknik analisis.

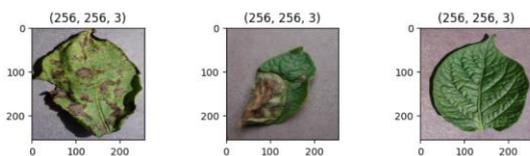
2.1 Pengumpulan Data

Langkah pertama adalah pengumpulan data dimana data yang diambil berasal dari kaggle dengan jumlah 2152 gambar yang terdiri dari 3 kelas data antara lain kelas *early blight*, *late blight* dan *healthy* dimana kemudian data tersebut dibagi ke dalam 3 kategori data antara lain data *training*, *validation* dan *test*, detail jumlah gambar dapat dilihat pada Tabel 1.

Tabel 1. Detail Jenis Data Yang Digunakan

Type Data	Kelas	Jumlah
Training	<i>Early Blight</i>	810
	<i>Late Blight</i>	781
	<i>Healthy</i>	130
Validation	<i>Early Blight</i>	87
	<i>Late Blight</i>	117
	<i>Healthy</i>	11
Test	<i>Early Blight</i>	103
	<i>Late Blight</i>	102
	<i>Healthy</i>	11

Dimana data gambar memiliki ukuran 256 X 256 pixels seperti disajikan dalam Gambar 2.



Gambar 2. Detail Data Gambar

2.2 Augmentasi Data

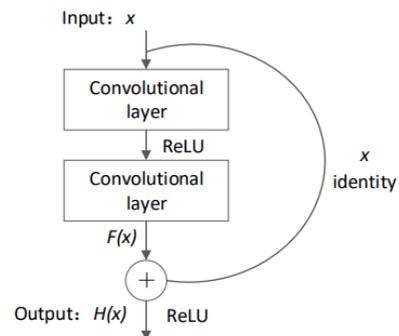
Tahapan augmentasi data adalah tahapan untuk memodifikasi gambar untuk menambahkan variasi dataset menjadi lebih beragam dimana tahapan augmentasi yang dilakukan antara lain adalah me *resize* ke ukuran 224 X 224 dan *random resize crop* ke ukuran 224 juga dan melakukan *random horizontal flip*.

2.3 Implementasi

Pada tahap ini dibangun sebuah arsitektur model dengan algoritma *CNN* dengan memanfaatkan model yang telah ada yaitu ResNet-34 sebagai *pre-trained* model dan kemudian hasil akhirnya akan mem *flatten* gambar yang awalnya dalam bentuk 3 dimensi kemudian akan diubah menjadi 1 dimensi sehingga dapat dilakukan training

menggunakan *fully connected layer* yang hasil keluarannya berupa hasil klasifikasi gambar.

Pada arsitektur Resnet-34 menggunakan blok residual dimana sebuah blok residual terdiri dari dua atau lebih lapisan konvolusi, di mana output dari blok tersebut diperoleh dengan menambahkan input dari blok tersebut ke output dari lapisan terakhir dalam blok. Ini memungkinkan jaringan untuk belajar representasi residual, yang berarti bahwa ia belajar perbedaan antara input dan output yang diinginkan daripada mencoba untuk mengaproksimasi output secara langsung. Penjelasan mengenai blok residual dapat dilihat pada Gambar 3.



Gambar 3. Blok Residual pada Arsitektur ResNet
Dimana perhitungan matematis untuk residual blok disajikan dalam persamaan 1.

$$H(x) = F(x) + x \quad (1)$$

SoftMax diperkenalkan sebagai aktivasi untuk meramalkan tergantung pada likelihood maksimum sehingga dapat digunakan dalam mengklasifikasi gambar multi kelas karena dapat menentukan probabilitas prediksi pada masing-masing kelas. Persamaan untuk fungsi SoftMax diberikan pada persamaan 2.

$$S^{e,j} = \frac{e^{z_{i,j}}}{\sum_{l=1}^L e^{z_{i,l}}} \quad (2)$$

Pada tahap *training* pada *fully connected layer* data akan menggunakan data training akan menggunakan data training yang telah dibagi pada tahap sebelumnya dimana proses training di jalankan di atas mesin GPU CUDA A100 dengan menggunakan *hyperparameter* seperti yang ditunjukkan pada Tabel 2.

Tabel 2. *Hyperparameter* Yang Digunakan

<i>Hyperparameter</i>	<i>Value</i>
<i>Epoch</i>	50
<i>Batch Size</i>	32
<i>Learning Rate</i>	0.001

Proses training menggunakan tools Google Colab, Google Colab adalah sebuah IDE untuk

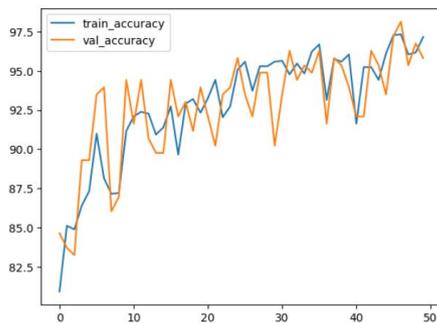
pemrograman Python dimana pemrosesan akan dilakukan oleh server Google yang memiliki perangkat keras dengan performa yang tinggi[23]

2.4 Evaluasi

Evaluasi menggunakan *metrics Accuracy, Precision, Recall* dan *F1 Score* berdasarkan *Confussion Matrix* setelah diujikan pada data testing, dari hasil evaluasi ini untuk menentukan kelayakan metode yang digunakan.

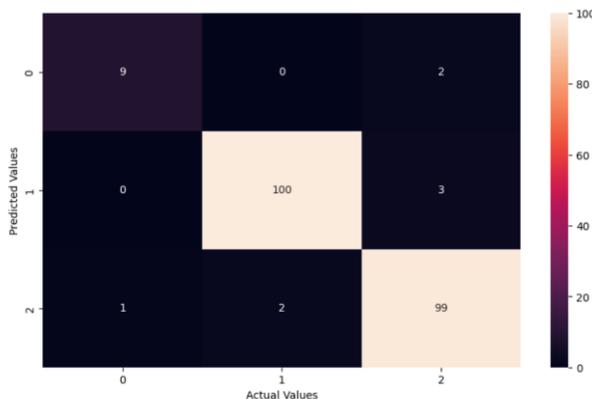
HASIL DAN PEMBAHASAN

Hasil pengujian dari implementasi diatas pada proses training didapatkan hasil *accuracy* 97.15 % pada data *training* dan 95.81% pada data *validation* pada *epoch* terakhir yaitu *epoch* ke 50 dimana *accuracy* pada data *training* dan *validation* disajikan pada Gambar 4.



Gambar 4. Grafik Accuracy

Pada grafik *accuracy* diatas dapat dilihat hasil prediksi pada data *training* dan *validation* pada masing-masing *epoch*, dapat dilihat pada grafik nilai akurasi bertambah di setiap *epoch* dan tidak terjadi *overfit* pada hasil data *training* dan hasil prediksi data *validation*. Pada proses pengujian menggunakan data *testing* didapatkan hasil akurasi sekitar 97% yang disajikan dalam *confussion matrix* pada Gambar 5.



Gambar 5. Confussion Matrix

Pada *confussion matrix* tersebut nilai 0, 1 dan 2 melambangkan jenis kelas dimana 0 merupakan *healthy*, 1 adalah *early blight* dan 2 adalah *late blight*, pada *matrix* tersebut terlihat pada data *healthy* berhasil memprediksi 9 data dan gagal memprediksi 2 buah data, pada kelas *early blight* berhasil memprediksi 100 data dan gagal memprediksi 3 data, begitu pula pada kelas *late blight* berhasil memprediksi 99 data dan gagal memprediksi 3 buah data, hasil prediksi dapat dilihat pada Gambar 6.



Gambar 6. Hasil Penelitian

Dari *confussion matrix* didapatkan nilai *precision* adalah 0.9629, *recall* adalah 0.9630 dan *F1 score* 0.9628

SIMPULAN

Pada implementasi metode yang telah dilakukan sebelumnya dapat ditarik kesimpulan bahwa arsitektur CNN yang dikembangkan dengan menggunakan ResNet-34 sebagai *pre-trained* model didapatkan bahwa arsitektur tersebut sudah dikatakan mampu dalam mengklasifikasikan jenis penyakit pada daun tanaman kentang dengan tingkat akurasi 97% dengan nilai *precision* adalah 0.9629, *recall* adalah 0.9630 dan *F1 score* 0.9628 dimana menggunakan sekitar 50 kali pengulangan *epoch* dalam pelatihannya untuk mencapai nilai akurasi tersebut. Penelitian di masa depan dapat difokuskan pada beberapa aspek untuk meningkatkan kinerja dan aplikasi dari model yang telah dikembangkan. Eksplorasi arsitektur CNN yang lebih dalam atau penggunaan teknik ensemble dapat dilakukan untuk mencapai akurasi yang lebih tinggi. Implementasi model pada aplikasi mobile atau sistem berbasis IoT juga merupakan langkah penting untuk memberikan solusi yang praktis dan mudah diakses bagi petani di lapangan. Terakhir, pengujian dan validasi model dengan data real-time di lapangan perlu dilakukan untuk memastikan kehandalan dan robustitas model dalam kondisi nyata.

DAFTAR PUSTAKA

- [1] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., 2016, pp. 770-778.
- [2] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436-444, 2015.
- [3] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using Deep Learning for Image-Based Plant Disease Detection," *Front. Plant Sci.*, vol. 7, p. 1419, 2016.
- [4] S. Zhang, W. Huang, and C. Zhang, "Deep Learning Based on ResNet for Plant Disease Detection," *IEEE Access*, vol. 7, pp. 167019-167029, 2019.
- [5] J. B. Jones, "Diseases caused by bacteria," in *Compendium of Tomato Diseases*, St. Paul, MN: APS Press, 1991, pp. 27-28.
- [6] W. E. Fry, *Phytophthora infestans: The Plant (and R Gene) Destroyer*, New York, NY: Springer, 2008.
- [7] E. C. Too, L. Yujian, S. Njuki, and L. Yingchun, "A comparative study of fine-tuning deep learning models for plant disease identification," *Comput. Electron. Agric.*, vol. 161, pp. 272-279, 2019.
- [8] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 60, 2019.
- [9] J. Bergstra and Y. Bengio, "Random Search for Hyper-Parameter Optimization," *J. Mach. Learn. Res.*, vol. 13, pp. 281-305, 2012.
- [10] B. Liu, Y. Zhang, D. He, and Y. Li, "Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks," *Symmetry*, vol. 10, no. 11, p. 272, 2018.
- [11] S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk, and D. Stefanovic, "Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification," *Comput. Intell. Neurosci.*, vol. 2016, Article ID 3289801, 2016.
- [12] X. Yu, Y. Zhang, Y. Yang, and S. Zhang, "Leaf Disease Detection and Classification Based on Improved Convolutional Neural Network," *IEEE Access*, vol. 8, pp. 189162-189174, 2020.
- [13] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Comput. Electron. Agric.*, vol. 145, pp. 311-318, 2018.
- [14] S. Ghosal, A. Blystone, A. Singh, S. K. Sarkar, L. Ganapathysubramanian, A. Singh, and B. Ganapathysubramanian, "An explainable deep machine vision framework for plant stress phenotyping," *Proc. Natl. Acad. Sci. U.S.A.*, vol. 115, no. 18, pp. 4613-4618, 2018.
- [15] D. Singh, M. Singh, A. K. Singh, and S. S. Gill, "PlantDoc: A Dataset for Visual Plant Disease Detection," in Proc. 6th ACM Intl. Conf. on Multimedia Systems, 2019, pp. 214-218.
- [16] M. Arsenovic, S. Sladojevic, A. Anderla, and D. Culibrk, "Solving Current Limitations of Deep Learning Based Approaches for Plant Disease Detection," *Symmetry*, vol. 11, no. 7, p. 939, 2019.
- [17] Y. Sun, Y. Liu, G. Wang, and H. Zhang, "Deep Learning for Plant Identification in Natural Environment," *Comput. Intell. Neurosci.*, vol. 2017, Article ID 7361042, 2017.
- [18] J. Nagaraju and P. Chawla, "Systematic Review of Deep Learning Techniques in Plant Disease Detection," *Int. J. Eng. Adv. Technol.*, vol. 9, no. 2, pp. 349-352, 2019.
- [19] W. Walleign, S. Ali, and D. Habte, "Tomato Plant Disease Identification Using Convolutional Neural Networks," *J. Adv. Res. Dyn. Control Syst.*, vol. 11, no. 2, pp. 71-79, 2019.
- [20] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Comput. Electron. Agric.*, vol. 147, pp. 70-90, 2018.
- [21] M. Rizkya and R. Andarsyah, "Klasifikasi MIT-BIH Arrhythmia Database Metode Random Forest dan CNN dengan Model ResNet-50: A Systematic Literature Review," *JTEKSIS*, vol. 5, no. 3, Jun. 2023.
- [22] S. Enggari, A. Ramadhanu, dan H. Marfalino, "Peningkatan Digital Image Processing dalam Mendeskripsikan Tumbuhan Jamur dengan Segmentasi Warna, Deteksi Tepi dan Kontur," *Jurnal Teknologi dan Sistem Informasi Bisnis*, vol. 4, no. 1, hal. 70-75, Jan. 2022.
- [23] R. G. Guntara, "Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7," *Jurnal Teknologi dan Sistem Informasi Bisnis*, vol. 5, no. 1, pp. 55-60, Jan. 2023.