

Research Article

Open Access (CC-BY-SA)

Penggunaan Residual Network (ResNet) untuk Klasifikasi Penyakit pada Daun Kentang

Ichsan Haikal^{*1}, David Hasiholan Nadeak², Lukman Hakim³

^{1,2,3}Jurusan Teknik Informatika, FASILKOM UMB, Jakarta

e-mail: ^{*}415210101@student.mercubuana.ac.id,

²41521010099@student.mercubuana.ac.id, ³lukman.hakim@mercubuana.ac.id

Abstrak

Penyakit pada tanaman kentang dapat memiliki dampak serius terhadap hasil panen dan kesehatan keseluruhan tanaman, mengancam keberlangsungan produksi pertanian. Dalam rangka meningkatkan akurasi dan efisiensi deteksi penyakit daun kentang, penelitian ini mengusulkan pendekatan baru dengan memanfaatkan arsitektur Residual Network, sebuah teknik yang menjanjikan dalam analisis citra. Dataset yang digunakan diperoleh dari sumber publik Kaggle, menyediakan keragaman yang diperlukan untuk melatih model secara efektif. Proses pembagian dataset menjadi data pelatihan dan pengujian diperlukan untuk mengoptimalkan kinerja algoritma Residual Network, memastikan bahwa model mampu menggeneralisasi pola penyakit dengan baik. Temuan penelitian menegaskan bahwa skenario 1, yang mengadopsi rasio pembagian data pelatihan dan pengujian sebesar 90:10, muncul sebagai pilihan yang paling optimal, dalam pengujian, model menunjukkan kinerja yang unggul dibandingkan skenario lainnya, dengan tingkat akurasi tertinggi yang dicapai sebesar 76%, mengindikasikan performanya yang menjanjikan dalam mengklasifikasikan data dengan tingkat keakuratan yang tinggi. Hasil ini menunjukkan potensi besar pendekatan ini dalam aplikasi praktis untuk deteksi penyakit daun kentang dengan efektif dan efisien, sehingga dapat meningkatkan produktivitas pertanian dan menjaga ketahanan pangan

Kata kunci—Penyakit Daun Kentang, *Residual Network*, Akurasi, dan Klasifikasi.

Abstract

Diseases in potato plants can have serious impacts on crop yield and overall plant health, threatening the sustainability of agricultural production. To enhance the accuracy and efficiency of potato leaf disease detection, this study proposes a new approach utilizing Residual Network architecture, a promising technique in image analysis. The dataset used is sourced from the public Kaggle repository, providing the necessary diversity to effectively train the model. The process of splitting the dataset into training and testing data is essential to optimize the performance of the Residual Network algorithm, ensuring that the model can generalize disease patterns well. The research findings highlight that Scenario 1, which adopts a training-to-testing data ratio of 90:10, emerges as the most optimal choice. In testing, this scenario demonstrated superior performance compared to other scenarios, achieving the highest accuracy rate of 76%, indicating its promising performance in classifying data with high accuracy. These results suggest significant potential for this approach in practical

applications for effective and efficient potato leaf disease detection, thereby enhancing agricultural productivity and ensuring food security.

Keywords—*Potato Leaf Disease, Residual Network, Accuracy, and Classification.*

1. PENDAHULUAN

Kentang adalah salah satu tanaman yang tergolong menyimpan kandungan karbohidrat dan membuatnya termasuk makanan utama bagi manusia [1]. Kentang merupakan Tanaman hortikultura yang berharga karena penggunaannya yang rutin dalam konsumsi sehari-hari seperti di rumah tangga, menu makanan hotel maupun restoran, dan juga sebagai bahan baku makanan ringan [2]. Menurut Badan Pusat Statistik (BPS), pengolahan kentang di Indonesia pada tahun 2022 menjangkau 1,42 juta ton, mengalami peningkatan sebesar 4,21% dibandingkan dengan 1,36 juta ton pada tahun sebelumnya [2]. Pada tahun 2022, konsumsi kentang oleh sektor rumah tangga mencapai 874,25 ribu ton, mengalami kenaikan sebesar 13,32% (102,79 ribu ton) dibandingkan tahun 2021. Partisipasi rumah tangga dalam konsumsi kentang tercatat sebesar 32,05% [3]. Kenaikan ini menandakan bahwa permintaan kentang terus mengalami peningkatan setiap tahunnya. Dalam upaya memenuhi permintaan konsumen yang terus berkembang, diharapkan produksi kentang akan terus meningkat di masa depan.

Namun, seperti halnya dengan semua tanaman, pengelolaan pertanian yang baik sangat penting untuk memastikan hasil panen yang optimal. Pengelolaan pertanian kentang menghadapi beberapa masalah, termasuk penyakit yang ada di daun kentang, yang jika tidak dikelola dengan tepat dapat mengakibatkan hasil produksi yang tidak bagus atau bahkan gagal panen [4]. Ketidapahaman petani kentang terkait perawatan daun dapat mengakibatkan sejumlah kentang yang diproduksi selama panen terbuang percuma, padahal kondisi daun berfungsi sebagai tanda pertama dari masalah tanaman yang tidak sehat, seperti kurangnya nutrisi, terkena penyakit, atau bahkan serangan hama [5]. Kesulitan yang dialami oleh petani kentang dalam membedakan kondisi daun kentang menyebabkan dibutuhkan *Artificial Intelligence* untuk pengolahan citra terhadap kondisi daun pada tanaman kentang.

Pengolahan citra adalah teknik yang memungkinkan pemrosesan data gambar untuk mengungkapkan informasi spesifik tentang objek yang diamati [6]. Kemudian, Machine learning merupakan cabang dari Artificial Intelligence yang berfokus pada penggunaan algoritma dan metode khusus untuk melakukan prediksi, pengenalan pola, serta klasifikasi [7]. Dengan memanfaatkan Machine Learning, data citra daun tebu dapat dianalisis untuk mengidentifikasi pola dan karakteristik yang menandakan adanya penyakit. Selanjutnya, pendekatan ini ditingkatkan dengan menggunakan Deep Learning yang merupakan cabang dari Machine Learning. Deep Learning adalah subbidang dari Machine Learning yang menggunakan algoritma yang terinspirasi oleh struktur otak manusia, yang dikenal sebagai Artificial Neural Networks [8]. Dalam penelitian ini, model Deep Learning yang diterapkan adalah Residual Network.


Dalam beberapa dekade terakhir, kemajuan *Machine Learning* telah memberikan kontribusi besar dalam upaya deteksi dan identifikasi penyakit tanaman dengan lebih cepat dan akurat. Salah satu pendekatan yang sedang berkembang adalah teknik khusus dalam *machine learning* yaitu *Deep Learning* yang memanfaatkan jaringan saraf tiruan (*artificial neural networks*) untuk memodelkan dan memahami data yang kompleks. Dengan memanfaatkan metode terbaru dalam bidang *Machine Learning*, kami berupaya meningkatkan akurasi dan efisiensi dalam mendeteksi serta mengklasifikasikan berbagai penyakit yang umumnya menginfeksi daun kentang.

Dalam penelitian yang dilakukan oleh Ridhovan dan kolega, metode *Residual Network* (ResNet) terbukti efektif untuk mendeteksi penyakit pada daun gandum. Dengan dilakukannya perbandingan data *training* dan *testing* sebesar 90:10, studi tersebut mencatat nilai matriks kebingungan (*confusion matrix*) sebesar 0,35, studi tersebut mencapai tingkat akurasi 98% [9]. Berdasarkan temuan ini, peneliti mencoba mengoptimalkan penggunaan model *Residual Network* untuk klasifikasi penyakit daun mangga menggunakan berbagai skenario pelatihan dan pengujian data untuk mencapai tujuan ini.

Penelitian ini bertujuan guna melihat performa arsitektur model *Residual Network* dalam mengklasifikasikan penyakit daun kentang dengan melakukan optimasi pada data *training* dan data *testing*. Dari capaian penelitian ini dapat menyajikan wawasan yang berguna terkait efektivitas metode *Residual Network* dalam pendeteksian penyakit pada daun kentang. Temuan ini dapat dijadikan acuan penting bagi para peneliti yang berminat untuk menjalankan penelitian serupa dalam konteks klasifikasi gambar menggunakan pendekatan *Residual Network*. Penelitian ini akan diperoleh hasil nilai akurasi, presisi, *recall*, dan *f-1 score*.

2. METODE PENELITIAN


Proses pada penelitian ini diawali adanya ulasan literatur yang terkait, Selanjutnya melakukan pembuatan model *deep learning* dengan melakukan pengumpulan data yang diperlukan. Kemudian data akan dibersihkan dan dilakukan augmentasi citra untuk meningkatkan jumlah gambar. Langkah berikutnya adalah pembagian data menjadi dua bagian, yakni data latih dan data uji. Kemudian, perancangan serta pelatihan model dilakukan, diikuti dengan evaluasi model yang telah dilatih sebagai tahap akhir. Gambar 1 menggambarkan tahapan penelitian tersebut.



Gambar 1 Tahapan Metodologi Penelitian

2.1 Pengumpulan Data

Ilustrasi yang diaplikasikan dalam penelitian ini merupakan dataset umum yang diambil dari [Kaggle: Potato Leaf Disease Dataset](#). *Potato*, dengan total 3076 gambar yang tersebar dalam beberapa kategori yang terdiri dari 201 gambar daun yang sehat, 569 gambar daun yang terinfeksi oleh *bacteria*, 748 gambar daun yang terinfeksi oleh *fungi*, 68 gambar daun yang terinfeksi oleh *nematode*, 611 gambar daun yang terinfeksi oleh *pest*, 347 gambar daun yang terinfeksi oleh *phytophthora*, dan 532 gambar daun yang terinfeksi oleh *virus*. Semua gambar tersebut memiliki ukuran 1500 x 1500 *pixel* dan berformat .jpg. Data ini diperoleh dari beberapa kebun kentang yang terletak di Jawa Tengah, Indonesia dengan menggunakan beberapa kamera *smartphone* [10]. Pada gambar 2 menunjukkan daun yang sehat, terinfeksi *bacteria*, terinfeksi *fungi*, terinfeksi *nematode*, terinfeksi *pest*, terinfeksi *phytophthora*, dan terinfeksi *virus*.



Gambar 2 Gambar dari Daun Kentang a) Sehat, b) Terinfeksi *Bacteria*, c) Terinfeksi *Fungi*, d) Terinfeksi *Nematode*, e) Terinfeksi *Pest*, f) Terinfeksi *Phytophthora*, g) Terinfeksi *Virus*.

2.2 Pembersihan Data

Ketidakmerataan persebaran data pada setiap kategori bisa menyebabkan kesalahan dalam klasifikasi objek. Untuk mengatasi masalah tersebut, dilakukan pengurangan jumlah data lebih hingga setiap kategori mempunyai total yang sama atau biasa disebut dengan nama *under sampling*. Dalam *under sampling*, sampel acak diambil dari kelas mayoritas kemudian ditambahkan ke kelas minoritas, sehingga menghasilkan dataset pelaksanaan yang lebih seimbang. [11]. Misalnya, dalam kasus ini, jumlah data untuk klasifikasi daun kentang sehat dan yang terinfeksi penyakit *bacteria*, penyakit *fungi*, penyakit *pest*, penyakit *phytophthora*, dan penyakit *virus* dikurangi hingga jumlahnya sama seperti penyakit *nematode* pada masing-masing kategori, Seperti terlihat pada Tabel 1.

Tabel 1 Proses Pembersihan Data (*Under Sampling*)

Kategori	Jumlah Data Sebelum Proses <i>Under Sampling</i>	Jumlah Data Sesudah Proses <i>Under Sampling</i>
Sehat	201	68
Bacteria	569	68
Fungi	748	68
Nematode	68	68
Pest	611	68
Phytophthora	347	68
Virus	532	68

2.3 Augmentasi Citra

Dalam menghadapi keterbatasan data untuk pelatihan jaringan saraf, pendekatan ini melibatkan pengambilan sampel kebisingan dari data pelatihan dan mengubahnya menjadi data baru yang dapat memberikan informasi tambahan kepada model. Salah satu solusi efektif adalah dengan melakukan augmentasi citra yaitu suatu proses di mana gambar dimodifikasi atau diubah sedemikian rupa sehingga komputer dapat mengenali bahwa perubahan yang terjadi pada gambar tersebut sebenarnya masih mencerminkan gambar yang sama [12]. Dengan demikian, augmentasi citra merupakan teknik yang berguna sebagai cara meningkatkan jumlah data pelatihan dan secara efektif meningkatkan kinerja model yang dihasilkan.

2.4 Pemisahan Data

Pada tahap proses pembangunan model *deep learning*, langkah pertama adalah menentukan ukuran untuk setiap set data, yang melibatkan pemisahan data menjadi data latih dan data uji. Data yang telah dilatih kemudian digunakan untuk memperbarui model *deep learning*. Setelah proses pelatihan selesai, model akan dijalankan menggunakan data uji yang telah tersedia, dan hasil klasifikasinya akan dievaluasi berdasarkan pengujian tersebut [13]. Saat mencari model *deep learning* yang optimal, berbagai pengujian harus dilakukan, Proses ini juga mencakup pengujian dengan perbandingan yang bervariasi antara data latih dan data uji, sebagaimana disajikan dalam Tabel 2.

Tabel 2 Distribusi Data

Skenario	Perbandingan Data Latih dan Data Uji	Jumlah Data Latih	Jumlah Data Uji
1	90:10	61	7
2	90:10	54	14
3	90:10	47	21
4	90:10	40	28
5	90:10	34	34

2.5 Perancangan Model

Dalam penelitian ini, penggunaan *deep learning* diterapkan menggunakan model ResNet152V2 untuk memperoleh evaluasi model yang tinggi. Karena ResNet152V2 adalah model *pre-trained*, tidak diperlukan penyesuaian *layer* tambahan. ResNet, yang merupakan singkatan dari *Residual Network*, adalah sebuah arsitektur jaringan saraf yang diperkenalkan oleh Kaiming He pada tahun 2015, Shaoqing Ren, Xiangyu Zhang serta Jian Sun. Di luar ResNet152V2, terdapat berbagai varian lain, seperti ResNet101V2, ResNet50, ResNet152, ResNet50V2, dan juga ResNet101. Perbedaan utama antara varian ini adalah pada jumlah lapisan yang digunakan, dengan ResNetV2 menyertakan lapisan normalisasi *batch* ditempatkan sebelum lapisan bobot. Arsitektur dasar ResNet melibatkan penggunaan *pooling layer*, *convolutional layer*, dan *fully connected layer*, dan juga integrasi *skip connection* pada sebagian *convolution layer* [9].

2.6 Pelatihan Model

ResNet152V2 adalah model CNN Pra-Pelatihan yang disingkat sebagai ResNet yang tidak hanya dapat digunakan untuk klasifikasi gambar tetapi juga untuk deteksi objek dan segmentasi semantik. ResNet memiliki keunggulan dalam melatih jaringan dengan jumlah lapisan yang besar [14]. Secara umum, CNN memiliki jumlah lapisan yang terbatas dan tidak dapat mencapai lapisan terdalam. Karena semakin dalam lapisan, semakin besar kesalahan dalam akurasi data uji, sering disebut *overfitting*. Oleh karena itu, ResNet menawarkan konsep blok sisa untuk mengatasi kemunculan *overfitting* dan memungkinkan jaringan mencapai lapisan terdalam. ResNet memiliki berbagai jenis kedalaman lapisan, mulai dari 18, 34, 50, 101, hingga 152. Dalam penelitian ini, 152 lapisan akan digunakan untuk mengklasifikasikan gambar. Alasan memilih 152 lapisan adalah karena memiliki akurasi terbaik. Model akan dilatih selama 10 *epoch* atau iterasi, dengan skala ukuran input lapisan sebesar 150x150, mengoptimalkan durasi pelatihan. Adapun di bawah ini disajikan rincian model ResNet152V2 dalam Tabel 3.

Tabel 3 Rincian Model ResNet152V2

Layar (<i>type</i>)	<i>Output Shape</i>	Parameter
ResNet152V2	(None, 7, 7, 2048)	5275648
GlobalAveragePooling2D	(None, 2048)	0
Dense	(None, 512)	1049088
Dense1	(None, 7)	3591

2.7 Evaluasi Metrik

Dengan menggunakan Evaluasi metrik yang diperlukan untuk mencari kombinasi model apa saja yang paling efektif. Evaluasi ini melibatkan pertimbangan nilai akurasi dengan *confusion matrix*. Adapun *Confusion matrix* merupakan sebuah perangkat untuk penilaian visual dalam *machine learning* yang akan menampilkan kolom untuk hasil nilai kelas prediksi serta baris untuk hasil kelas yang sebenarnya, memungkinkan perhitungan kasus dalam sebuah masalah klasifikasi [15]. *Confusion matrix* mencakup berbagai metrik evaluasi yang penting seperti presisi, *recall*, serta *f1 score*. Dari hasil nilai Akurasi tersebut menunjukkan rasio prediksi yang benar pada jumlah data. Selain itu presisi merupakan suatu perbandingan antara jumlah prediksi benar positif dengan total prediksi positif yang dilakukan. Adapun *Recall* terbentuk dari perbandingan antara jumlah prediksi benar positif dengan jumlah data yang benar

positif. Selain itu *F1 score* adalah rata-rata harmonis dari presisi dan *recall*. Tingkat Akurasi serta *metrik confusion matrix* dapat dihitung dengan menggunakan Persamaan (1), (2), (3), dan (4).

$$\text{Akurasi} = \frac{\text{True Positive} + \text{True Negative}}{\text{True Positive} + \text{True Negative} + \text{True Positive} + \text{True Negative}} \quad (1)$$


$$\text{Presisi} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (2)$$

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (3)$$

$$\text{F1 Score} = \frac{2 \times \text{Recall} \times \text{Presisi}}{\text{Recall} + \text{Presisi}} \quad (4)$$


3. HASIL DAN PEMBAHASAN

Dalam Skenario 1, dengan membagi data pelatihan dan pengujian dalam rasio 90:10, di mana terdapat 61 data untuk pelatihan dan 7 data untuk pengujian, model berhasil mencapai tingkat akurasi sebesar 76% setelah proses pelatihan. Hasil evaluasi model menggunakan matriks kebingungan menunjukkan nilai presisi sebesar 0.76, nilai *recall* sebesar 0.76, dan skor *f1* sebesar 0.75. Tampilan akurasi dan matriks kebingungan dapat dilihat pada Gambar 3.




Gambar 3. Visualisasi a) Akurasi dan b) *Confusion Matrix*


Dalam Skenario 2, dengan membagi data pelatihan dan pengujian dalam rasio 80:20, terdapat 54 data untuk pelatihan dan 14 data untuk pengujian, model berhasil mencapai tingkat akurasi sebesar 73% setelah proses pelatihan. Hasil evaluasi model menggunakan matriks kebingungan menunjukkan nilai presisi sebesar 0.73, nilai *recall* sebesar 0.73, dan skor *f1* sebesar 0.73. Tampilan akurasi dan matriks kebingungan dapat dilihat pada Gambar 4.

Gambar 4. Visualisasi a) Akurasi dan b) *Confusion Matrix*

Dalam Skenario 3, dengan membagi data pelatihan dan pengujian dalam rasio 70:30, di mana terdapat 47 data untuk pelatihan dan 21 data untuk pengujian, model berhasil mencapai tingkat akurasi sebesar 67% setelah proses pelatihan. Hasil evaluasi model menggunakan matriks kebingungan menunjukkan nilai presisi sebesar 0.66, nilai *recall* sebesar 0.67, dan skor f1 sebesar 0.66. Tampilan akurasi dan matriks kebingungan dapat dilihat pada Gambar 5.


Gambar 5. Visualisasi a) Akurasi dan b) *Confusion Matrix*

Dalam Skenario 4, dengan membagi data pelatihan dan pengujian dalam rasio 60:40, di mana terdapat 40 data untuk pelatihan dan 28 data untuk pengujian, model berhasil mencapai tingkat akurasi sebesar 65% setelah proses pelatihan. Hasil evaluasi model menggunakan matriks kebingungan menunjukkan nilai presisi sebesar 0.66, nilai *recall* sebesar 0.65, dan skor f1 sebesar 0.66. Tampilan akurasi dan matriks kebingungan dapat dilihat pada Gambar 6.



Gambar 6. Visualisasi a) Akurasi dan b) *Confusion Matrix*

Dalam Skenario 5, dengan membagi data pelatihan dan pengujian dalam rasio 50:50, di mana terdapat 34 data untuk pelatihan dan 34 data untuk pengujian, model berhasil mencapai tingkat akurasi sebesar 66% setelah proses pelatihan. Hasil evaluasi model menggunakan matriks kebingungan menunjukkan nilai presisi sebesar 0.66, nilai *recall* sebesar 0.66, dan skor f1 sebesar 0.66. Tampilan akurasi dan matriks kebingungan dapat dilihat pada Gambar 7.



Gambar 7. Visualisasi a) Akurasi dan b) *Confusion Matrix*

Berikut ditampilkan perbandingan akurasi seperti yang ditunjukkan di dalam Tabel 4 di bawah ini.

Tabel 4 Perbandingan Akurasi dari Semua Skenario

Skenario	Perbandingan Data Training & Data Testing	Akurasi (%)
1	90:10	76
2	80:20	73
3	70:30	67

4	60:40	65
5	50:50	66

4. KESIMPULAN

Bisa ditarik kesimpulan berdasarkan evaluasi hasil dan diskusi bahwa skenario 1, yang melibatkan alokasi data pelatihan dan pengujian dengan perbandingan 90:10, menunjukkan kinerja paling unggul dibandingkan dengan skenario pembagian data lainnya. Hasil pengujian menunjukkan tingkat akurasi terbaik sebesar 76%, mencerminkan kemampuan model untuk secara akurat mengklasifikasikan data.

Keunggulan kinerja pada skenario ini dapat disebabkan oleh proporsi data *training* yang lebih besar yaitu 90% dari total dataset. Dengan memiliki lebih banyak data untuk melatih model, kemampuannya untuk memahami pola dan fitur yang kompleks dalam dataset semakin meningkat. Hasil ini menunjukkan bahwa strategi pembagian data dengan memberikan penekanan pada jumlah data *training* dapat menghasilkan model yang lebih unggul.

5. SARAN

1. Penelitian ini diharapkan dapat mengeksplorasi potensi *Residual Network* dalam meningkatkan akurasi klasifikasi penyakit daun kentang melalui optimalisasi parameter dan arsitektur jaringan.
2. Disarankan untuk memfokuskan penelitian pada implementasi dan evaluasi kinerja ResNet dalam mendeteksi dan mengklasifikasikan berbagai jenis penyakit daun kentang secara otomatis.
3. Direkomendasikan untuk menyelidiki bagaimana penggunaan arsitektur ResNet dapat meningkatkan akurasi dalam klasifikasi penyakit daun kentang dibandingkan dengan metode konvensional lainnya.
4. Penelitian ini dapat memanfaatkan ResNet untuk mengidentifikasi penyakit pada daun kentang, dengan tujuan meningkatkan efisiensi dan akurasi deteksi penyakit.
5. Disarankan untuk menilai efektivitas ResNet dalam tugas klasifikasi dan deteksi penyakit daun kentang dengan membandingkan hasilnya dengan metode machine learning lainnya.
6. Disarankan untuk menerapkan dan mengevaluasi metode *deep learning*, khususnya ResNet, dalam klasifikasi penyakit daun kentang untuk memahami potensi dan keterbatasannya.
7. Direkomendasikan untuk melakukan studi komparatif antara ResNet dan metode *deep learning* lainnya untuk menentukan metode yang paling efektif dalam klasifikasi penyakit daun kentang.
8. Penelitian ini dapat fokus pada analisis kinerja ResNet dalam klasifikasi penyakit daun kentang, dengan maksud untuk memahami faktor-faktor yang mempengaruhi performa jaringan.
9. Disarankan untuk mempelajari penerapan arsitektur ResNet dalam identifikasi penyakit daun kentang, dengan fokus pada peningkatan akurasi dan kecepatan deteksi.

10. Penelitian ini dapat mengevaluasi pengaruh penggunaan ResNet terhadap akurasi klasifikasi penyakit daun kentang, serta membandingkannya dengan teknik lain yang telah ada.

UCAPAN TERIMA KASIH

Dalam penulisan ini, kami tentu mengakui kontribusi bantuan dari pihak lain, baik dalam bentuk dukungan moral maupun materiil. Maka, dengan ini kami ingin mengungkapkan penghargaan dan rasa terima kasih kepada Nirmal Sankalana, selaku *publisher* dataset *Potato Leaf Disease Dataset* pada platform *Kaggle*.

Peneliti mengucapkan terima kasih yang sebesar-besarnya kepada Bapak Lukman Hakim, ST, M.Kom., yang telah memberikan bimbingan, dukungan, dan motivasi selama proses penyusunan jurnal ini. Terima kasih atas ilmu, waktu, dan perhatian yang telah diberikan, sehingga peneliti dapat menyelesaikan jurnal ini dengan baik.

DAFTAR PUSTAKA

- [1] A. J. Rozaqi, A. Sunyoto, and M. rudyanto Arief, "Deteksi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network," *Creative Information Technology Journal*, vol. 8, no. 1, pp. 22–31, 2021.
- [2] B. P. Statistik, "Statistik Indonesia 2023," 2023. [Online]. Available: <https://www.bps.go.id/id/publication/2023/06/09/03847c5743d8b6cd3f08ab76/statistik-hortikultura-2022.html>
- [3] B. P. Statistik, "Statistik Hortikultura 2022," 2023. [Online]. Available: <https://www.bps.go.id/id/publication/2023/02/28/18018f9896f09f03580a614b/statistik-indonesia-2023.html>
- [4] A. M. Lesmana, R. P. Fadhillah, and C. Rozikin, "Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN)," *Jurnal Sains Dan Informatika*, vol. 8, no. 1, pp. 21–30, 2022.
- [5] F. B. Setiawan and I. P. Kurnia, "Pemilah Jenis Daun Mangga Melalui Deteksi RGB Menggunakan Sistem Pengolahan Citra," *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, vol. 13, no. 2, pp. 171–182, 2023.
- [6] A. R. Putri, "Pengolahan citra dengan menggunakan web cam pada kendaraan bergerak di jalan raya," *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, vol. 1, no. 01, 2016.
- [7] N. R. Muntiari and K. H. Hanif, "Klasifikasi penyakit kanker payudara menggunakan perbandingan algoritma machine learning," *Jurnal Ilmu Komputer dan Teknologi*, vol. 3, no. 1, pp. 1–6, 2022.
- [8] M. R. S. Alfarizi, M. Z. Al-farish, M. Taufiqurrahman, G. Ardiansah, and M. Elgar, "Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning," *Karimah Tauhid*, vol. 2, no. 1, pp. 1–6, 2023.
- [9] A. Ridhovan and A. Suharso, "Penerapan metode residual network (RESNET) dalam klasifikasi penyakit pada daun gandum," *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, vol. 7, no. 1, pp. 58–65, 2022.
- [10] N. Sankalana, "Potato Leaf Disease Dataset," 2023. [Online]. Available: <https://www.kaggle.com/datasets/nirmalsankalana/potato-leaf-disease-dataset/data>
- [11] E. Saputro and D. Rosiyadi, "Penerapan Metode Random Over-Under Sampling Pada Algoritma Klasifikasi Penentuan Penyakit Diabetes," *Bianglala Informatika*, vol. 10, no. 1, pp. 42–47, 2022.
- [12] B. Elia and I. D. M. B. A. Darmawan, "Klasifikasi Kesegaran Daging Sapi Menggunakan Deep Learning Arsitektur VGG16 Dengan Augmentasi Citra," *Jurnal Nasional Teknologi Informasi dan Aplikasinya*, vol. 1, no. 1, 2022.

- [13] J. S. P. Sibarani, S. T. Damanik, R. Nurkhalizah, S. Mulyana, and B. Nasution, “Klasifikasi Tanaman Hias Menggunakan Algoritma Convolutional Neural Network,” *Journal of Information Technology Ampera*, vol. 4, no. 3, pp. 286–297, 2023.
- [14] A. N. A. Thohari, L. Triyono, I. Hestningsih, B. Suyanto, and A. Yobioktobera, “Performance Evaluation of Pre-Trained Convolutional Neural Network Model for Skin Disease Classification,” *JUITA: Jurnal Informatika*, vol. 10, no. 1, pp. 9–18, 2022.
- [15] J. Xu, Y. Zhang, and D. Miao, “Three-way confusion matrix for classification: A measure driven view,” *Inf Sci (N Y)*, vol. 507, pp. 772–794, 2020.