



Klasifikasi Penyakit Daun Kentang dengan Transfer Learning Menggunakan CNN optimalisasi Arsitektur MobileNetV2

Rahmad Gunawan¹, Fauzan Salim², Adhe Indra Wahyudhy³, Angga Yudha Wibowo⁴, Gibril Yordan⁵, Refly Fauzan Filamori⁶

Email: ¹goengoen78@umri.ac.id, ²fauzansalim16@gmail.com, ³adhetugas@gmail.com, ⁴anggayudha515@gmail.com, ⁵gibrilyordan18@gmail.com, ⁶210401094@student.umri.ac.id

^{1,2,3,4,5,6}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

Diterima: 17 Januari 2025 | Direvisi: 29 April 2025 | Disetujui: 22 Mei 2025

©2024 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Kentang merupakan tanaman pangan utama dengan nilai ekonomi tinggi, tetapi rentan terhadap berbagai penyakit yang dapat mempengaruhi kualitas dan produktivitasnya. Penelitian yang dilakukan bertujuan untuk mendeteksi penyakit yang terdapat pada daun tanaman kentang dengan pemanfaatan metode *Convolutional Neural Network (CNN)* dan memanfaatkan *transfer learning* menggunakan arsitektur MobileNetV2. Dataset yang digunakan terdiri dari 4072 citra daun kentang dengan tiga kategori: daun sehat (*healthy*), terinfeksi *Early Blight*, dan *Late blight*. Dataset diproses melalui data augmentation dan normalisasi untuk meningkatkan kualitas data. Model yang dihasilkan menunjukkan performa tinggi dengan akurasi 95,31%, presisi 95,81%, recall 95,31%, dan F1-Score 95,38%. Hasil menunjukkan bahwa metode ini mampu mendeteksi kondisi daun kentang dengan tingkat kesalahan klasifikasi yang rendah, terutama pada kategori *healthy*. Namun, terdapat tantangan pada klasifikasi antara *Early Blight* dan *Late Blight* yang memerlukan analisis lanjutan dan peningkatan metode. Penelitian ini memberikan kontribusi dalam pengembangan sistem deteksi penyakit tanaman yang efisien dan akurat.

Kata kunci: Deteksi Penyakit, Daun Kentang, CNN, Transfer Learning, MobileNetV2

Potato Leaf Disease Classification with Transfer Learning Using CNN Optimization of MobileNetV2 Architecture

Abstract

Potatoes are a major food crop with high economic value, but they are susceptible to various Diseases impacting potato leaves can significantly influence their quality and productivity. This research focuses on identifying diseases in potato leaves through the *Convolutional Neural Network (CNN)* approach, leveraging transfer learning with the MobileNetV2 architecture. The dataset utilized comprises 4,072 images of potato leaves. categorized into three groups: non-infected leaves (*healthy*), *Early Blight*-infected leaves, and *Late Blight*-infected leaves. The dataset is processed through data augmentation and normalization to enhance data quality. The resulting model demonstrates excellent performance, achieving an accuracy of 95.31%, a precision of 95.81%, a recall of 95.31%, and an F1-Score of 95.38%. These findings indicate the approach demonstrates its ability to identify the condition of potato leaves with a low classification error rate, especially in the *healthy* category. However, there are challenges in classifying between *Early Blight* and *Late Blight* that require further analysis and method improvement. This study contributes to the development of efficient and accurate plant disease detection systems.

Keywords: Disease Detection, Potato Leaves, CNN, Transfer Learning, MobileNetV2.

1. PENDAHULUAN

Kentang adalah tanaman yang memiliki nilai ekonomi tinggi di sektor pertanian global. Setelah jagung, gandum, dan beras, kentang menempati urutan keempat sebagai salah satu bahan pangan utama di dunia. Berdasarkan data dari Badan Pusat Statistik, hasil dari produksi kentang di Indonesia pada tahun 2022 menyentuh angka 1,42 juta ton, mengalami peningkatan sebesar 4,21% dibandingkan produksi pada tahun 2021 yang tercatat sebesar 1,36 juta ton. Secara umum, produksi kentang di Indonesia menunjukkan tren yang fluktuatif namun cenderung meningkat. Angka produksi pada tahun lalu mencatatkan rekor tertinggi dalam satu dekade terakhir. Pada tahun 2022, sebanyak 21 provinsi di Indonesia memproduksi kentang, dengan produksi terbanyak berasal dari Jawa Timur, yaitu mencapai 381.090 ton [1].

Untuk menjaga kualitas kentang sebagai salah satu sumber pangan utama, penting untuk melakukan pencegahan dan pengendalian penyakit tanaman secara efektif. Penyakit tanaman dapat memberikan dampak negatif terhadap hasil pertanian. Jika penyakit pada tanaman kentang tidak terdeteksi secara dini, maka kerawanan terhadap serangan penyakit dapat meningkat [2]. Oleh karena itu, Dibutuhkan sebuah metode yang mampu membandingkan dan menunjukkan tingkat ketepatan dalam mendeteksi penyakit. Pada penelitian akan mengkategorikan lima jenis penyakit yang terdapat pada daun di tanaman kentang, yaitu daun yang busuk, daun yang memiliki bercak, daun yang berlubang, daun yang sehat, dan daun sakit, yang diidentifikasi melalui pemrosesan gambar. Berbeda dengan penelitian yang dilakukan sebelumnya yang mana membagi data menjadi tiga kategori, dataset yang terdapat dalam penelitian ini diperoleh dari situs Kaggle.


Dalam penelitian ini, digunakan metode CNN untuk melakukan klasifikasi citra, yang terbukti efektif dalam mengenali objek gambar dengan akurasi yang tinggi [3]. CNN memiliki kemampuan untuk secara otomatis mengekstrak fitur-fitur utama dari citra tanpa memerlukan proses ekstraksi fitur secara manual, sehingga mempermudah proses klasifikasi.

Penelitian ini juga memanfaatkan metode *Transfer Learning* dengan menggunakan arsitektur model MobileNetV2, yang merupakan model deep learning yang telah dilatih pada dataset besar seperti ImageNet. Model ini digunakan untuk memanfaatkan pengetahuan yang sudah ada dalam model tersebut dan diterapkan pada masalah klasifikasi baru, yaitu penyakit pada tanaman kentang. Penggunaan MobileNetV2 dapat menjadi alternatif yang efektif dalam arsitektur CNN yang sangat akurat [4].

Penelitian terdahulu tentang klasifikasi objek menggunakan *Transfer Learning* [4], menguji deteksi atribut wajah dengan arsitektur CNN. Hasilnya menunjukkan bahwa NASNetMobile memiliki akurasi terbaik (91,6%), sedikit lebih tinggi dibandingkan MobileNet (91,5%). Penelitian lain, yaitu [5], menggunakan arsitektur VGG16, ResNet50, RNN, dan LSTM untuk mengidentifikasi lima kelas: daun sehat, bercak, berlubang, busuk, dan bukan daun. Model terbaik adalah VGG16 dengan dense layer 75, yang mencapai presisi 0,87, recall 0,86, akurasi 0,86, dan f1-score 0,86, sementara ResNet50 memperoleh nilai 0,84, 0,81, 0,81, dan 0,81. Penelitian lainnya mengklasifikasikan lima jenis penyakit daun kentang, yaitu *Alternaria solani*, insect, virus, *Phytophthora infestans*, dan daun sehat. Dataset yang digunakan berupa citra berukuran 224x224 piksel dan dianalisis menggunakan metode CNN dengan arsitektur VGG16 dan VGG19, yang menghasilkan akurasi rata-rata 91% [6]. Mobilenetv2 digunakan pada penelitian [7] untuk mendeteksi penyakit pada daun kopi robusta menggunakan yang menghasilkan akurasi rata-rata 99.93%. yang didapatkan hasil yang lebih unggul dibandingkan dengan penggunaan model lain.

2. METODE PENELITIAN

Pada penelitian yang dilakukan ini akan melibatkan beberapa tahapan proses klasifikasi penyakit pada daun kentang, sebagaimana yang divisualisasikan pada Gambar 1.



Gambar 1. Rancangan Penelitian

Gambar 1 memperlihatkan alur dari penelitian yang dirancang untuk mendeteksi penyakit pada daun kentang. Alur penelitian tersebut mencakup beberapa langkah, dimulai dari penginputan dataset, persiapan data awal melalui proses pra-pemrosesan, dilanjutkan dengan langkah klasifikasi pada citra daun kentang yang dianalisis, hingga tahap akhir berupa evaluasi untuk mengukur efektivitas metode klasifikasi yang digunakan.

2.1. Dataset

Penelitian ini memanfaatkan data publik dari situs Kaggle yang terdiri dari 4.072 gambar daun kentang yang diambil dari daerah Punjab Tengah, Pakistan [8]. Dataset ini dikelompokkan menjadi tiga kategori: daun kentang yang memiliki kondisi sehat, daun yang terinfeksi virus *Early Blight*, dan daun yang terinfeksi virus *Late blight*. Untuk mempermudah proses analisis, data yang sebelumnya terpisah ke dalam bagian *training*, *validation*, dan *testing* digabung kembali berdasarkan kategorinya. Setelah penggabungan, persebaran data menjadi 1020 gambar untuk kategori daun sehat, 1628 gambar untuk daun yang termasuk dalam infeksi *Early Blight*, dan 1424 gambar untuk yang termasuk *Late blight*. Pendekatan ini dirancang untuk memastikan setiap kategori memiliki representasi yang cukup, sehingga memudahkan tahap klasifikasi selanjutnya dan meningkatkan akurasi model dalam mengidentifikasi kondisi daun kentang.

2.2. Preprocessing Data

Pada tahap preprocessing, dataset akan dibagi kedalam tiga bagian utama yaitu data untuk pelatihan (*training*), data untuk memvalidasi (*validation*), serta data untuk keperluan pengujian (*testing*). Setiap bagian kemudian dipisahkan lagi ke dalam tiga subfolder berdasarkan kategori gambar, yaitu *Early_Blight*, *Healthy*, *Late_Blight*. Pembagian ini bertujuan untuk memastikan bahwa data pelatihan yang ada dimanfaatkan untuk melatih model, sementara data validasi dimanfaatkan untuk menilai performa dari model selama proses pelatihan, dan data uji untuk mengukur performa model setelah pelatihan selesai.

Selanjutnya, data gambar diproses menggunakan generator data yang dilengkapi dengan beberapa tahap transformasi. Pada tahapan ini, proses yang dilakukan mencakup perubahan pada format data yang sebelumnya mentah dan tidak teratur menjadi lebih terstruktur dan lebih mudah dipahami. Hal ini penting karena kualitas data dapat mempengaruhi kinerja algoritma yang digunakan dalam analisis data [9]. Langkah-langkah yang dilakukan meliputi perubahan ukuran gambar (*resize image*) yang bertujuan untuk memastikan resolusi piksel yang sesuai pada penggunaan dalam proses citra daun kentang dengan resolusi 224 x 224 piksel. Selanjutnya, dilakukan *rescale* layer dengan faktor (1/255), yang berarti setiap nilai piksel dikalikan dengan 1/255, sehingga nilainya berada dalam rentang 0 hingga 1 untuk setiap data gambar. Data kemudian dikelompokkan dalam batch berukuran 32 untuk efisiensi komputasi dan untuk meningkatkan performa [4]. Data juga disusun ulang (*shuffle*) untuk meningkatkan generalisasi model. Selain itu, citra dinormalisasi untuk memastikan distribusi data lebih seragam, sementara informasi tentang kelas dikelola melalui atribut, yang memetakan hubungan antara nama kelas dan indeksnya. Langkah ini penting karena data mentah sering kali memiliki format yang tidak seragam [10] dan memastikan data citra siap digunakan oleh model pretrained seperti MobileNetV2.

2.3. Classification

Tahap selanjutnya dalam penelitian ini merupakan proses klasifikasi gambar dengan memanfaatkan metode CNN., dengan MobileNetV2 sebagai arsitektur dasar. Pada tahun 2017, Google memperkenalkan MobileNetV1, sebuah jaringan konvolusional ringan yang dirancang khusus untuk perangkat *mobile* dan *embedded*. Arsitektur MobileNetV1 mengandalkan teknik *depthwise separable convolution*, yang membagi input dan filter menjadi saluran-saluran terpisah, lalu menggabungkannya kembali menggunakan konvolusi 1x1 (*pointwise convolution*). Teknik ini menghasilkan output yang setara dengan konvolusi konvensional, namun lebih efisien karena memerlukan lebih sedikit parameter [11].

Mengembangkan MobileNetV1, MobileNetV2 menambahkan *Inverted Residuals* dan *Linear Bottlenecks* untuk meningkatkan kinerja dan efisiensi. *Inverted Residuals* mengatasi keterbatasan konvolusi mendalam yang tidak dapat mengubah jumlah saluran, mempercepat pembelajaran, dan mengurangi masalah gradien yang menghilang dengan menggunakan fungsi aktivasi ReLU. Di lapisan terakhir, MobileNetV2 menggantikan fungsi aktivasi ReLU dengan aktivasi linear untuk mengurangi kehilangan informasi pada fitur berdimensi rendah. Sementara itu, lapisan Linear Bottlenecks memungkinkan koneksi pintasan antara input dan output, mirip dengan residual connections pada CNN, yang mempercepat pelatihan dan meningkatkan akurasi model [12].

Untuk meningkatkan efisiensi dalam adaptasi model terhadap tugas klasifikasi baru, penelitian ini menggunakan *transfer learning*, yang mana dapat memungkinkan pemanfaatan model yang telah dilatih sebelumnya pada dataset besar dengan objek yang umum, sehingga proses penyesuaian terhadap tugas spesifik menjadi lebih cepat dan akurat [13]. Dengan memanfaatkan kesamaan antara domain sumber dan target, *Transfer Learning* mempercepat perolehan pengetahuan pada domain target [14].

Setelah model dilatih, tahap berikutnya adalah mengkompilasi model menggunakan Adam *optimizer* dan fungsi *loss* yang sesuai, yang dipilih karena kemampuannya yang baik dalam menangani masalah gradien pada model kompleks serta kecocokannya dengan dataset yang memiliki label terkodekan secara integer [15]. Proses ini membantu model untuk mempelajari dan membedakan kategori berdasarkan atribut visual yang dimiliki oleh gambar daun kentang, seperti tekstur, warna, dan pola

kerusakan. Dengan arsitektur MobileNetV2 yang efisien dan teknik *Transfer Learning*, model ini dirancang untuk menyesuaikan dengan dataset spesifik penelitian ini, sehingga dapat memberikan hasil klasifikasi yang lebih cepat dan akurat.


2.4 Model Evaluation

Proses klasifikasi dilakukan dengan menghitung nilai akurasi, yang merupakan ukuran untuk menilai kinerja suatu model klasifikasi. Akurasi akan dikalkulasi dengan membandingkan jumlah prediksi yang benar terhadap total prediksi yang dilakukan. Salah satu cara untuk menjalankan klasifikasi adalah dengan menggunakan *Confusion Matrix*, yaitu sebuah alat yang digunakan untuk mengevaluasi seberapa tepat atau salah prediksi yang dihasilkan oleh suatu algoritma dalam proses klasifikasi [16].

3. HASIL DAN PEMBAHASAN

Setelah melakukan proses pelatihan dan evaluasi dengan arsitektur MobileNetV2 dengan menggunakan dataset yang berjumlah 4072 file, Karena jumlah data yang digunakan cukup besar, diperlukan pembagian data dalam bentuk *rate per batch (batch_size)* yang telah disesuaikan dan memiliki hasil yang optimal saat menggunakan 32 *batch size*. Yang mana selanjutnya dilakukannya penambahan *Adam* sebagai *optimizer* dan *categorical_cross_entropy loss function* serta penggunaan *EarlyStopping*. Hasil dari pelatihan yang dilakukan yaitu sebanyak 9 Epoch dengan akurasi akhir sebesar 0.9842 dari proses *training*. dengan nilai loss yang menurun drastis menjadi 0,0489.

Model yang disimpan dan dilakukan testing mendapatkan hasil yang terlihat pada Gambar 2 dalam bentuk *confusion matrix*, yang menunjukkan bahwa model mampu mengklasifikasikan sebagian besar sampel dengan akurat, dengan nilai true positive untuk masing-masing kelas adalah 151 (*Early Blight*), 102 (*Healthy*), dan 133 (*Late blight*). Namun, terdapat beberapa kesalahan klasifikasi, seperti 9 sampel *Early Blight* yang salah diklasifikasikan sebagai *Healthy* dan 2 sampel yang salah sebagai *Late blight*. Selain itu, 7 sampel *Late blight* salah diklasifikasikan sebagai *Healthy*, dan 1 sampel sebagai *Early Blight*. Tidak ada kesalahan klasifikasi yang terjadi pada kelas *Healthy* ke kelas lain. Hasil tersebut memperlihatkan bahwa model memiliki performa yang baik ketika mendeteksi kelas *Healthy*, namun masih memerlukan peningkatan dalam membedakan antara kelas *Early Blight* dan *Late blight*. Analisis lanjutan seperti penghitungan metrik evaluasi (Precision, Recall, dan F1-Score) diperlukan untuk memberikan gambaran yang lebih komprehensif terkait akurasi model.



Gambar 2. *Confusion Matrix*

Pada table 2 model menunjukkan performa yang sangat baik dengan nilai akurasi sebesar 95,31%, presisi 95,81%, *recall* 95,31%, dan *F1-Score* 95,38%. Nilai akurasi yang tinggi mencerminkan kemampuan model dalam mengklasifikasikan 95,31% sampel dengan benar. Presisi sebesar 95,81% menunjukkan bahwa model mampu meminimalkan kesalahan klasifikasi positif palsu, sedangkan *recall* sebesar 95,31% menunjukkan bahwa model berhasil mendeteksi sebagian besar sampel positif tanpa banyak kesalahan prediksi negatif palsu. *F1-Score* yang tinggi, yaitu 95,38%, menunjukkan keseimbangan yang baik antara presisi dan recall, memberikan gambaran bahwa model memiliki kinerja yang konsisten dalam mendeteksi sampel secara akurat. Hasil ini menunjukkan bahwa model layak digunakan untuk klasifikasi dengan tingkat kesalahan yang rendah, meskipun perlu evaluasi lanjutan untuk memastikan bahwa model tidak bias terhadap kelas tertentu.

Table 2. Matriks Evaluasi

Akurasi	Presisi	Recall	F1-Score
0.9531	0.9581	0.9531	0.9538

4. KESIMPULAN

4.1 Kesimpulan

Berdasarkan hasil penelitian, model klasifikasi menggunakan arsitektur MobileNetV2 menunjukkan performa yang sangat baik dalam membedakan tiga kategori dari daun, yaitu kategori *Early Blight*, *Healthy* (sehat), dan kategori *Late blight*. Model mencapai nilai akurasi sebesar 95,31%, presisi 95,81%, recall 95,31%, dan F1-Score 95,38%. *Confusion matrix* menunjukkan sebagian besar sampel diklasifikasikan dengan benar, terutama pada kelas *Healthy* yang tidak mengalami kesalahan klasifikasi. Meski demikian, masih terdapat beberapa kesalahan klasifikasi pada kelas *Early Blight* dan *Late blight*, yang memerlukan peningkatan lebih lanjut. Secara keseluruhan, model ini layak digunakan untuk klasifikasi dengan tingkat kesalahan yang rendah.

4.2 Saran

Adapun saran bagi peneliti selanjutnya untuk meningkatkan kinerja model, beberapa langkah yang dapat dilakukan adalah melakukan *fine-tuning* pada parameter model, seperti *learning rate* dan *optimizer*, untuk mengurangi kesalahan klasifikasi pada kelas tertentu. Selain itu, peningkatan kualitas dan kuantitas dataset dengan data augmentation atau penambahan data dari sumber lain juga dapat membantu meningkatkan generalisasi model.

DAFTAR PUSTAKA

- [1] "Data Produksi Kentang di Indonesia 10 Tahun Terakhir hingga 2023." Accessed: Dec. 24, 2024. [Online]. Available: <https://dataindonesia.id/agribisnis-kehutanandetail/data-produksi-kentang-di-indonesia-10-tahun-terakhir-hingga-2023>
- [2] A. J. Rozaqi, A. Sunyoto, and R. Arief, "Deteksi Penyakit pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network Detection of Potato Leaves Disease Using Image Processing with Convolutional Neural Network Methods".
- [3] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network".
- [4] 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA). IEEE, 2019.
- [5] J. R. Aisya and A. Prasetyadi, "Klasifikasi Penyakit Daun Kentang dengan Metode CNN dan RNN," Jurnal Tekno Insentif, vol. 17, no. 1, pp. 1–10, Apr. 2023, doi: 10.36787/jti.v17i1.888.
- [6] A. Ampuh. Yunanto, 2020 International Electronics Symposium : September 29-30th 2020, Surabaya, Indonesia. IEEE, 2020.
- [7] Y. Aufar and T. P. Kaloka, "Robusta coffee leaf diseases detection based on MobileNetV2 model," International Journal of Electrical and Computer Engineering, vol. 12, no. 6, pp. 6675–6683, Dec. 2022, doi: 10.11591/ijece.v12i6.pp6675-6683.
- [8] "Potato Disease Leaf Dataset(PLD)." Accessed: Dec. 24, 2024. [Online]. Available: <https://www.kaggle.com/datasets/rizwan123456789/potato-disease-leaf-datasetpld>
- [9] R. A. Firmansah, H. Santoso, and A. Anwar, "TRANSFER LEARNING IMPLEMENTATION ON IMAGE RECOGNITION OF INDONESIAN TRADITIONAL HOUSES," Jurnal Teknik Informatika (Jutif), vol. 4, no. 6, pp. 1469–1478, Dec. 2023, doi: 10.52436/1.jutif.2023.4.6.767.
- [10] S. SATRIA, Sumijan, and Billy Hendrik, "Implementasi Convolutional Neural Network Untuk Klasifikasi Citra KTP-El," Jurnal CoSciTech (Computer Science and Information Technology), vol. 5, no. 1, pp. 169–176, May 2024, doi: 10.37859/coscitech.v5i1.6708.
- [11] A. G. Howard et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," Apr. 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>
- [12] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," Jan. 2018, [Online]. Available: <http://arxiv.org/abs/1801.04381>
- [13] A. Kaya, A. S. Keceli, C. Catal, H. Y. Yalic, H. Temucin, and B. Tekinerdogan, "Analysis of transfer learning for deep neural network based plant classification models," Comput Electron Agric, vol. 158, pp. 20–29, Mar. 2019, doi: 10.1016/j.compag.2019.01.041.
- [14] C. Biele, J. Kacprzyk, W. Kopeć, J. W. Owsinski, A. Romanowski, and M. Sikorski, "Lecture Notes in Networks and Systems 440." [Online]. Available: <https://link.springer.com/bookseries/15179>
- [15] T. Nurmayanti, D. Hartini, T. Rohana, S. Arum, P. Lestari, and D. Wahiddin, "Comparison of K-Nearest Neighbors and Convolutional Neural Network Algorithms in Potato Leaf Disease Classification," Jurnal Sistem Informasi dan Ilmu Komputer Prima, vol. 8, no. 1, 2024.
- [16] R. Firdaus, Joni Satria, and B. Baidarus, "Klasifikasi Jenis Kelamin Berdasarkan Gambar Mata Menggunakan Algoritma Convolutional Neural Network (CNN)," Jurnal CoSciTech (Computer Science and Information Technology), vol. 3, no. 3, pp. 267–273, Dec. 2022, doi: 10.37859/coscitech.v3i3.4360.