



Performance Analysis of Baseline Convolutional Neural Networks for Identifying Potato Disease Types

Analisis Kinerja Convolutional Neural Networks Baseline untuk Identifikasi Jenis Jenis Penyakit Kentang

Khoir Prasetyo¹, Ridwan Mahendra^{2*}

^{1,2}Fakultas Teknik dan Ilmu Komputer, Universitas Teknokrat, Lampung, Indonesia

E-Mail: ¹Khoirprasetyo87@gmail.com, ²ridwanmahendra@teknokrat.ac.id

Received Nov 29th 2024; Revised Feb 16th 2025; Accepted Feb 22th 2025; Available Online Mar 21th 2025, Published Jan 21th 2025

Corresponding Author: Ridwan Mahendra

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

This research aims to develop and evaluate a baseline Convolutional Neural Network (CNN) model in identifying disease types in potato leaves. The dataset used consists of infected and healthy potato leaf images, which are classified into several disease categories such as late blight, early blight, and bacterial disease. The CNN model was designed with a basic architecture that includes multiple convolution, pooling, and fully connected layers, and trained using Adam's optimizer with a categorical cross-entropy loss function. Evaluation results showed that the model achieved 82% accuracy on the validation set and an average of 95% on random data. Although the model performed well in classifying the images, indications of overfitting were seen from the difference between training and validation accuracies. Further analysis identified prediction errors that occurred, especially in classes with similar visual symptoms. This research recommends the application of regulation techniques, data augmentation, and the use of more complex architectures to improve the accuracy of the model. The results of this research are expected to contribute to the development of a more efficient artificial intelligence-based plant disease detection system.

Keyword: Convolutional Neural Network, Deep Learning, Plant Disease Identification, Potato Leaf Image

Abstrak

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model *Convolutional Neural Network* (CNN) baseline dalam mengidentifikasi jenis-jenis penyakit pada daun kentang. *Dataset* yang digunakan terdiri dari citra daun kentang yang terinfeksi dan sehat, yang diklasifikasikan ke dalam beberapa kategori penyakit seperti *late blight*, *early blight*, dan penyakit bakteri. Model CNN dirancang dengan arsitektur dasar yang meliputi beberapa lapisan *konvolusi*, *pooling*, dan *fully connected*, serta dilatih menggunakan *Optimizer* Adam dengan fungsi *loss categorical cross-entropy*. Hasil evaluasi menunjukkan bahwa model mencapai akurasi 82% pada *validation set* dan rata-rata 95% pada data acak. Meskipun model menunjukkan performa yang baik dalam mengklasifikasikan citra, indikasi *overfitting* terlihat dari perbedaan antara akurasi *training* dan *validation*. Analisis lebih lanjut mengidentifikasi kesalahan prediksi yang terjadi, terutama pada kelas dengan gejala visual yang mirip. Penelitian ini merekomendasikan penerapan teknik regulasi, augmentasi data, dan penggunaan arsitektur lebih kompleks untuk meningkatkan akurasi model. Hasil penelitian ini diharapkan dapat memberikan kontribusi bagi pengembangan sistem deteksi penyakit tanaman berbasis kecerdasan buatan yang lebih efisien.

Kata Kunci: Citra Daun Kentang, Convolutional Neural Networks, Deep Learning, Identifikasi Penyakit Tanaman

1. PENDAHULUAN

Pertanian merupakan sektor yang sangat penting dalam perekonomian global, terutama bagi negara-negara agraris seperti Indonesia. Salah satu komoditas penting dalam pertanian adalah kentang (*Solanum tuberosum*), yang tidak hanya menjadi bahan pangan utama tetapi juga memiliki nilai ekonomi yang tinggi [1]. Produksi kentang yang optimal sangat bergantung pada kualitas dan kesehatan tanaman. Namun, tanaman kentang rentan terhadap berbagai penyakit seperti *early blight*, *late blight*, dan infeksi bakteri, yang dapat menyebabkan penurunan hasil panen secara signifikan [2]. Oleh karena itu, deteksi dan identifikasi dini

terhadap jenis-jenis penyakit kentang menjadi sangat krusial untuk mengoptimalkan hasil pertanian dan menjaga kualitas produk.

Pada beberapa dekade terakhir, perkembangan teknologi kecerdasan buatan *Artificial Intelligence* (AI) dan pengolahan citra telah memberikan peluang besar dalam bidang pertanian. Salah satu pendekatan yang banyak digunakan adalah *Convolutional Neural Network* (CNN), sebuah teknik dalam *deep learning* yang sangat efektif dalam pengenalan pola dan pengolahan citra [3]. CNN telah terbukti mampu memberikan hasil yang sangat baik dalam identifikasi dan klasifikasi objek pada berbagai domain, termasuk dalam bidang pertanian untuk mendeteksi penyakit pada tanaman melalui citra daun [4]. CNN bekerja dengan mengekstraksi fitur-fitur dari citra input secara otomatis dan memetakan pola-pola yang relevan, sehingga sangat cocok untuk mengidentifikasi penyakit berdasarkan gejala visual yang muncul pada daun tanaman kentang.

Beberapa penelitian sebelumnya telah menggunakan CNN untuk identifikasi penyakit tanaman berbasis citra. Adegbola et al. (2024) [5] mengembangkan model CNN untuk mengidentifikasi penyakit pada tanaman tomat dengan akurasi mencapai 99,35%. Studi ini menunjukkan bahwa CNN mampu menangani variasi dalam citra daun dengan baik. Selain itu, Sandhi (2024) [6] menggunakan arsitektur CNN untuk mendeteksi penyakit pada tanaman apel, mencapai akurasi 96,3%. Penelitian lain oleh Sarada et al. (2024) [7] mengimplementasikan CNN untuk mendeteksi penyakit pada berbagai tanaman dengan akurasi 99,53%. Hasil-hasil ini menunjukkan bahwa CNN memiliki potensi besar dalam bidang pertanian, terutama dalam identifikasi penyakit tanaman. Selain itu, Balasubramanian et al. (2024) [8] menggunakan pendekatan transfer learning untuk mengidentifikasi penyakit pada tanaman padi dan jagung, mencapai akurasi 98,2%. Namun, sebagian besar penelitian tersebut menggunakan arsitektur CNN yang kompleks dan memerlukan sumber daya komputasi yang besar. Oleh karena itu, analisis terhadap model CNN baseline menjadi penting untuk memahami kinerja dasar sebelum mengembangkan model yang lebih kompleks.


Namun, meskipun CNN telah menunjukkan potensi besar dalam klasifikasi penyakit tanaman, ada beberapa tantangan yang perlu diatasi, terutama dalam hal kinerja model baseline. Model baseline biasanya digunakan sebagai titik awal untuk mengevaluasi kemampuan jaringan saraf dalam tugas tertentu [9]. Analisis terhadap kinerja CNN baseline dalam identifikasi penyakit kentang dapat memberikan wawasan tentang seberapa efektif model tersebut dalam menangani variasi data yang sering terjadi pada citra daun, seperti perubahan pencahayaan, sudut pandang, serta variasi morfologi daun akibat penyakit yang berbeda. Selain itu, hasil analisis ini dapat menjadi dasar pengembangan model yang lebih kompleks dan efektif di masa mendatang.

Penelitian ini memiliki beberapa kelebihan dibandingkan dengan penelitian terdahulu. Pertama, fokus pada analisis kinerja model CNN baseline memberikan dasar yang kuat untuk pengembangan model yang lebih canggih di masa depan. Kedua, penelitian ini menggunakan dataset citra daun kentang yang dilabeli secara spesifik, yang memungkinkan analisis yang lebih mendalam terhadap variasi gejala penyakit. Ketiga, penelitian ini mengeksplorasi keterbatasan dan potensi model baseline dalam menangani variasi data citra, yang sering kali diabaikan dalam penelitian sebelumnya. Keempat, hasil penelitian ini diharapkan dapat memberikan rekomendasi praktis bagi pengembangan model CNN yang lebih efisien dan efektif dalam konteks pertanian presisi. Dengan demikian, penelitian ini tidak hanya berkontribusi pada pengembangan teknologi AI, tetapi juga memiliki implikasi praktis dalam meningkatkan produktivitas pertanian.

Penelitian ini bertujuan untuk menganalisis kinerja model CNN *baseline* dalam mengidentifikasi jenis-jenis penyakit pada tanaman kentang dengan menggunakan dataset citra daun yang telah dilabeli. Studi ini diharapkan dapat memberikan kontribusi dalam mengidentifikasi keterbatasan dan kekuatan model *baseline* sehingga dapat menjadi landasan untuk pengembangan model yang lebih baik. Dengan demikian, hasil penelitian ini diharapkan dapat mendukung penggunaan teknologi AI dalam meningkatkan efisiensi pertanian dan pengendalian penyakit tanaman secara tepat waktu dan efektif.

2. METODE PENELITIAN


Penelitian ini bertujuan untuk menganalisis kinerja model CNN *baseline* dalam mengidentifikasi jenis-jenis penyakit pada tanaman kentang berdasarkan citra daun. Metode penelitian yang digunakan terdiri dari beberapa tahap utama, yaitu pengumpulan data, pra-pemrosesan data, pembangunan model CNN *baseline*, pelatihan dan evaluasi model, serta analisis hasil yang dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah kumpulan citra daun kentang yang terpengaruh oleh berbagai jenis penyakit seperti *late blight*, *early blight*, daun normal. Data diambil dari *dataset* publik yang tersedia secara online atau dikumpulkan melalui pengambilan gambar langsung di lapangan dengan menggunakan kamera digital beresolusi tinggi. Setiap citra di-label sesuai dengan jenis penyakitnya. *Dataset* tersebut kemudian dibagi menjadi tiga *subset Training Set*: Digunakan untuk melatih model CNN agar mampu mengenali pola penyakit dengan jumlah 70% dari total *dataset*. *Validation Set*: Digunakan untuk memantau dan mengoptimalkan kinerja model selama pelatihan dengan jumlah 15% dari total *dataset*. *Test Set*: Digunakan untuk evaluasi akhir kinerja model dengan jumlah 15% dari total *dataset* [10]. Sampel data daun kentang dapat dilihat pada gambar 2.



Gambar 2. Sampel Data Daun Kentang

2.2. Pra-pemrosesan Data

Pra-pemrosesan dilakukan untuk memastikan kualitas dan konsistensi *data input* sehingga meningkatkan kinerja model CNN. Tahapan pra-pemrosesan meliputi *Resizing* yaitu semua citra diubah ukurannya menjadi 256x256 piksel untuk memastikan keseragaman *input* [11]. Normalisasi yaitu Nilai piksel citra dinormalisasi dalam rentang 0-1 untuk mempercepat konvergensi model saat pelatihan *Augmentasi Data* yang merupakan teknik *augmentasi* seperti rotasi, *flipping*, *zooming*, dan penyesuaian pencahayaan diterapkan untuk memperkaya variasi data dan mencegah *overfitting* [12].

2.3. Model CNN Baseline

Model *baseline* CNN dalam penelitian ini dirancang dengan menggunakan arsitektur dasar yang terdiri dari beberapa lapisan untuk memproses citra daun kentang. Pada awalnya, citra daun dengan dimensi 256x256 piksel dan 3 kanal warna (RGB) diterima melalui lapisan *input* [13]. Setelah itu, citra tersebut diproses melalui dua lapisan konvolusi yang masing-masing dilengkapi dengan filter berukuran 3x3 untuk mengekstraksi fitur-fitur penting dari citra. Setiap lapisan konvolusi diikuti oleh fungsi aktivasi *Rectified Linear Unit* (ReLU) yang berfungsi untuk mengaktifkan neuron-neuron yang relevan dan mempercepat proses konvergensi. Selanjutnya, untuk mengurangi dimensi citra dan mempercepat komputasi, setiap lapisan konvolusi diikuti oleh lapisan *pooling* (*max pooling*) dengan ukuran 2x2 [14]. Lapisan *pooling* ini berfungsi untuk mengambil nilai maksimal dari area 2x2 piksel pada fitur map yang dihasilkan oleh lapisan konvolusi. Setelah melalui proses konvolusi dan *pooling*, fitur-fitur yang telah diekstraksi kemudian dihubungkan ke dua lapisan *fully connected* (*dense*) [15]. Lapisan *fully connected* ini menghubungkan semua neuron dari lapisan sebelumnya dan digunakan untuk mengintegrasikan informasi fitur sebelum melakukan klasifikasi. Lapisan *output* diatur dengan jumlah neuron yang sesuai dengan jumlah kelas penyakit kentang, dan menggunakan fungsi aktivasi softmax untuk menghasilkan probabilitas klasifikasi dari setiap kelas. Model CNN *baseline* ini dilatih menggunakan optimizer *Adam* dengan *learning rate* awal sebesar 0.001. Untuk mengukur seberapa baik model mengklasifikasikan jenis penyakit, digunakan *loss function categorical cross-entropy*, yang cocok untuk masalah klasifikasi multi-kelas [16].

Tabel 1. Konfigurasi Model CNN *Baseline*

Lapisan	Jenis	Detail
1	<i>Input Layer</i>	Citra daun dengan dimensi 256x256 piksel dan 3 kanal warna (RGB)
2	<i>Convolutional Layer</i>	Filter berukuran 3x3, diikuti oleh fungsi aktivasi ReLU
3	<i>Pooling Layer</i>	<i>Max pooling</i> berukuran 2x2
4	<i>Convolutional Layer</i>	Filter berukuran 3x3, diikuti oleh fungsi aktivasi ReLU
5	<i>Pooling Layer</i>	<i>Max pooling</i> berukuran 2x2
6	<i>Fully Connected (Dense) Layer</i>	Menghubungkan semua neuron dari lapisan sebelumnya
7	<i>Fully Connected (Dense) Layer</i>	Menghubungkan semua neuron dari lapisan sebelumnya
8	<i>Output Layer</i>	Jumlah neuron sesuai jumlah kelas (jenis penyakit), fungsi <i>softmax</i>

2.4. Pelatihan dan Evaluasi Model

Model CNN baseline dilatih menggunakan *subset training* dengan metode *backpropagation* dan *batch size* sebesar 32 selama 30 *epoch*. Proses pelatihan dimonitor menggunakan *subset validation* untuk mengevaluasi *loss* dan akurasi pada setiap *epoch*. Jika terjadi *overfitting*, dilakukan penyesuaian parameter model seperti penurunan *learning rate* atau penerapan *dropout* pada lapisan *fully connected* untuk mengurangi kompleksitas model [17]. Setelah proses pelatihan selesai, model dievaluasi menggunakan subset test untuk mengukur kinerjanya dalam hal akurasi, presisi, *recall*, dan *F1-score* [18]. Matriks kebingungan (*confusion matrix*) juga disajikan untuk memberikan informasi tentang klasifikasi yang benar dan salah pada masing-masing kelas penyakit.


2.5. Analisis Hasil

Hasil kinerja model dianalisis untuk mengevaluasi kemampuan CNN baseline dalam mengidentifikasi jenis-jenis penyakit pada tanaman kentang. Hasil tersebut akan dibandingkan dengan model lain atau dengan literatur terdahulu untuk mengetahui apakah model baseline cukup efektif sebagai titik awal pengembangan model lebih lanjut [19]. Selain itu, faktor-faktor yang mempengaruhi akurasi model, seperti kualitas data, augmentasi, dan konfigurasi arsitektur, juga dibahas untuk memberikan wawasan lebih lanjut tentang cara meningkatkan performa model di masa depan [20].


3. HASIL DAN PEMBAHASAN

3.1. Hasil Pelatihan Model

Pada tahap pelatihan model CNN baseline, dilakukan pengamatan terhadap metrik akurasi dan *loss* pada *training* dan *validation set* selama 30 *epoch*. Evaluasi ini dilakukan untuk menilai seberapa baik model belajar dari data dan apakah model mengalami *overfitting* atau *underfitting*. Hasil pelatihan ini divisualisasikan melalui plot akurasi dan *loss* untuk memberikan gambaran yang lebih jelas tentang performa model selama proses pelatihan. Selama proses pelatihan, akurasi pada *training set* menunjukkan peningkatan yang konsisten, terutama pada 10 *epoch* pertama, di mana akurasi meningkat secara signifikan. Akurasi model pada *training set* akhirnya mencapai sekitar 95% pada akhir pelatihan, yang menunjukkan bahwa model berhasil mempelajari pola-pola yang terdapat dalam *dataset* dengan baik. Di sisi lain, akurasi pada *validation set* juga mengalami peningkatan, meskipun tidak setinggi *training set*, dengan akurasi maksimum sebesar 90%. Perbedaan ini mengindikasikan di mana model sangat baik dalam memprediksi data belum pernah dilihat sebelumnya, plot akurasi model dapat dilihat pada Gambar 3.

**Gambar 3.** Plot Akurasi Model

Selain akurasi, *loss* model juga dipantau selama proses pelatihan. *Training loss* terus menurun secara bertahap seiring dengan bertambahnya *epoch*, menunjukkan bahwa model berhasil meminimalkan kesalahan prediksi pada data validasi. Namun, *validation loss* cenderung stabil setelah mencapai titik terendah pada sekitar *epoch* ke-20 dan bahkan sedikit meningkat setelahnya. Hal ini menunjukkan bahwa setelah titik tertentu, model mulai terlalu menyesuaikan diri (*overfitting*) dengan *data training* dan kehilangan kemampuan generalisasi terhadap data *validation*, tapi kembali menurun sampai *epoch* ke-30. , plot *lost* model dapat dilihat pada Gambar 4.



Gambar 4. Plot Loss Model

3.2. Hasil Evaluasi Kinerja Model CNN Baseline

Setelah model CNN *baseline* dilatih menggunakan dataset citra daun kentang yang telah dilabeli, hasil evaluasi kinerja model terhadap test set menunjukkan bahwa model mencapai akurasi keseluruhan sebesar 82%. Selain akurasi, metrik lain yang digunakan untuk mengevaluasi model meliputi presisi, *recall*, dan *F1-score* untuk setiap kelas penyakit. Nilai presisi rata-rata mencapai 80%, yang menunjukkan bahwa model memiliki tingkat keakuratan yang cukup baik dalam mengklasifikasikan jenis penyakit tertentu. *Recall* rata-rata sebesar 78% menunjukkan bahwa model dapat mengenali sebagian besar citra yang benar termasuk dalam setiap kelas, meskipun ada beberapa kesalahan deteksi pada beberapa jenis penyakit. *F1-score* rata-rata sebesar 79% menunjukkan keseimbangan antara presisi dan *recall*, yang mencerminkan performa model secara keseluruhan dalam mengidentifikasi penyakit kentang. Tabel 2 merupakan hasil evaluasi kinerja model berdasarkan metrik akurasi, presisi, *recall*, dan *F1-score* untuk masing-masing kelas penyakit

Tabel 2. Hasil Evaluasi Kinerja Model


Kelas Penyakit	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Daun Normal	90	88	85	86
Late Blight	85	83	80	81
Early Blight	80	78	75	76

Hasil tersebut menunjukkan bahwa model CNN *baseline* mampu mengenali daun sehat dengan tingkat akurasi yang lebih tinggi dibandingkan penyakit-penyakit lainnya. Hal ini mungkin disebabkan oleh kontras yang lebih jelas antara daun sehat dan daun yang terinfeksi, di mana daun yang terinfeksi menunjukkan pola kerusakan tertentu yang mungkin mirip di antara berbagai jenis penyakit. Kinerja model sedikit menurun pada kelas penyakit seperti *early blight* dan infeksi bakteri, di mana terdapat kemungkinan pola gejala yang lebih mirip, sehingga menyulitkan model untuk membedakan di antara kedua kelas tersebut.

3.3. Prediksi Pada Data Acak

Untuk menguji kinerja dan kemampuan generalisasi model CNN *baseline* yang telah dilatih, dilakukan evaluasi menggunakan data acak yang dipilih dari test set. Data acak ini dipilih untuk mensimulasikan skenario nyata di mana model dihadapkan pada citra yang belum pernah dilihat sebelumnya dan bertujuan untuk menilai akurasi model dalam mengidentifikasi jenis penyakit secara langsung. Pada eksperimen ini, sebanyak 20 sampel citra daun kentang dipilih secara acak dari test set yang telah dipisahkan sebelumnya dan tidak pernah digunakan selama proses pelatihan. Citra-citra tersebut mewakili berbagai kelas penyakit, termasuk daun sehat, *early blight*, *late blight*, dan penyakit bakteri. Setiap citra diolah melalui model CNN, yang kemudian

memberikan *output* berupa probabilitas untuk masing-masing kelas penyakit. Kelas dengan probabilitas tertinggi dianggap sebagai prediksi akhir untuk setiap citra. Hasil *output* prediksi dapat dilihat pada Gambar 5.



Gambar 4. Hasil Prediksi Data Acak

3.4. Performa Model

Model CNN *baseline* yang digunakan dalam penelitian ini memberikan hasil yang cukup memuaskan dengan akurasi yang mencapai 82%. Namun, terdapat beberapa keterbatasan yang perlu diperhatikan. Pertama, model *baseline* ini hanya menggunakan dua lapisan konvolusi dan lapisan pooling yang mungkin belum cukup kompleks untuk mengekstraksi fitur-fitur yang lebih halus, terutama dalam membedakan penyakit dengan gejala visual yang serupa. Keterbatasan ini menjadi dasar bagi penelitian lanjutan untuk mengeksplorasi arsitektur CNN yang lebih dalam atau penggunaan teknik lain seperti transfer learning yang dapat meningkatkan performa model. Kedua, *dataset* yang digunakan, meskipun telah dipra-pemrosesan dan diaugmentasi, mungkin belum sepenuhnya representatif dari variasi kondisi lapangan. Penggunaan dataset yang lebih beragam dan mencakup berbagai kondisi lingkungan dan jenis penyakit yang lebih luas diharapkan dapat memperkuat performa model. Ketiga, implementasi *hyperparameter* yang lebih optimal dan eksperimen dengan berbagai optimizer lain juga dapat dilakukan untuk meningkatkan akurasi dan kestabilan model.

4. KESIMPULAN

Penelitian ini telah berhasil mengembangkan dan mengevaluasi model CNN *baseline* untuk mengidentifikasi jenis-jenis penyakit pada daun kentang. Berdasarkan hasil pelatihan dan evaluasi, model CNN *baseline* mencapai akurasi keseluruhan sebesar 82% pada *validation set*, menunjukkan bahwa arsitektur model yang digunakan cukup efektif dalam mengenali pola visual penyakit pada citra daun kentang. Namun, hasil evaluasi juga menunjukkan adanya indikasi *overfitting*, di mana akurasi pada *training set* lebih tinggi dibandingkan *validation set*, yang menandakan bahwa model memerlukan peningkatan lebih lanjut untuk memperkuat kemampuan generalisasinya. Dari hasil prediksi menggunakan data acak, model mampu mengklasifikasikan sebagian besar citra dengan benar. Secara keseluruhan, penelitian ini menunjukkan bahwa CNN memiliki potensi besar sebagai metode untuk mendeteksi dan mengidentifikasi penyakit tanaman secara otomatis. Namun, untuk mencapai performa yang lebih optimal, diperlukan pengembangan lebih lanjut dan eksperimen dengan berbagai teknik untuk mengatasi tantangan dalam membedakan penyakit dengan karakteristik visual yang serupa. Hasil penelitian ini diharapkan dapat menjadi dasar bagi pengembangan sistem deteksi penyakit tanaman berbasis kecerdasan buatan yang lebih akurat dan efisien di masa depan.

REFERENSI

- [1] M. Hasrialdy Qamalpasha Muchransyah, mun Sarma, and M. Najib, "Analisis Internal dan Eksternal Kentang Indonesia dalam Menghadapi Masyarakat Ekonomi ASEAN (MEA) Indonesian Potential Internal and External Analysis in Facing the ASEAN Economic Community (MEA)," *Jurnal Manajemen dan Organisasi (JMO)*, vol. 9, no. 2, pp. 115–121, 2018.

- [2] R. R. Kumar, A. K. Jain, V. Sharma, N. Jain, P. Das, and P. Sahni, "Advanced Deep Learning Model for Multi-Disease Prediction in Potato Crops: A Precision Agriculture Approach," in *2024 IEEE International Conference on Information Technology, Electronics and Intelligent Communication Systems, ICITEICS 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICITEICS61368.2024.10625281.
- [3] Olabimpe Banke Akintuyi, "AI in agriculture: A comparative review of developments in the USA and Africa," *Open Access Research Journal of Science and Technology*, vol. 10, no. 2, pp. 060–070, Apr. 2024, doi: 10.53022/oarjst.2024.10.2.0051.
- [4] S. Veldandi, . N., and K. M. Reddy, "Identification of Plant Leaf Disease Using CNN and Image Processing," *Journal of Image Processing and Intelligent Remote Sensing*, no. 44, pp. 1–10, Jun. 2024, doi: 10.55529/jipirs.44.1.10.
- [5] A. Adegbola, J. Ampitan, O. M. Akande, O. B. Adewuyi, E. Mgbeahuruike, and A. Adebajo, "A Convolutional Neural Network Model for Crop Disease Detection System," *British journal of computer, networking and information technology*, vol. 7, no. 4, pp. 94–102, 2024, doi: 10.52589/bjcnit-z1blvyo8.
- [6] A. Sandhi, "A Comprehensive Hybrid Model For Apple Fruit Disease Detection Using Multi-Architecture Feature Extraction," 2024, doi: 10.20944/preprints202410.1894.v1.
- [7] J. Sarada, J. Ramachandraiah, V. Neerugatti, C. R. Raman, A. Taranum, and A. Sinha, "Early stage disease classification in potato leaves using convolutional neural network (CNN)," pp. 707–712, 2024, doi: 10.1201/9781003559092-122.
- [8] D. Balasubramanian, K. Mruthika, G. Sushaan, Y. V, and B. K., "Enhancing Plant Disease Detection Through Transfer Learning With Ensemble Techniques: A Novel Approach For Precision Agriculture," pp. 1–6, 2024, doi: 10.1109/nmitcon62075.2024.10698982.
- [9] G. S. Hukkeri, B. C. Soundarya, H. L. Gururaj, and V. Ravi, "Classification of Various Plant Leaf Disease Using Pretrained Convolutional Neural Network On Imagenet," *Open Agric J*, vol. 18, no. 1, May 2024, doi: 10.2174/0118743315305194240408034912.
- [10] M. Talaat, X. Si, and J. Xi, "Multi-Level Training and Testing of CNN Models in Diagnosing Multi-Center COVID-19 and Pneumonia X-ray Images," *Applied Sciences (Switzerland)*, vol. 13, no. 18, Sep. 2023, doi: 10.3390/app131810270.
- [11] P. Kumar and D. Singh, "Pre-Processing Techniques for Enhancing CNN Performance," in *2024 11th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions), ICRITO 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICRITO61523.2024.10522352.
- [12] L. Huang, J. Qin, Y. Zhou, F. Zhu, L. Liu, and L. Shao, "Normalization Techniques in Training DNNs: Methodology, Analysis and Application," Sep. 2020, [Online]. Available: <http://arxiv.org/abs/2009.12836>
- [13] S. Hadiani, F. Aziz, D. Nur Sulistyowati, D. Riana, R. Saputra, and Kurniawanoro, "Identification of Potato Plant Pests Using the Convolutional Neural Network VGG16 Method," *Journal Medical Informatics Technology*, pp. 39–44, Jun. 2024, doi: 10.37034/medinftech.v2i2.37.
- [14] C. Liu and L. Hui, "ReLU soothes the NTK condition number and accelerates optimization for wide neural networks," May 2023, [Online]. Available: <http://arxiv.org/abs/2305.08813>
- [15] N. I. Galanis, P. Vafiadis, K. G. Mirzaev, and G. A. Papakostas, "Convolutional Neural Networks: A Roundup and Benchmark of Their Pooling Layer Variants," *Algorithms*, vol. 15, no. 11, Nov. 2022, doi: 10.3390/a15110391.
- [16] Z. Chen, Y. Du, and T. T. Toe, "Line Average Pooling: A Better Way to Handle Feature Maps on CNN for Skin Cancer Classification," in *Proceedings - 2022 Asia Conference on Algorithms, Computing and Machine Learning, CACML 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 522–526. doi: 10.1109/CACML55074.2022.00094.
- [17] E. Zhang, M. Wahib, R. Zhong, and M. Munetomo, "Learning from the Past Training Trajectories: Regularization by Validation," *Journal of Advanced Computational Intelligence and Intelligent Informatics*, vol. 28, no. 1, pp. 67–78, Jan. 2024, doi: 10.20965/jaciii.2024.p0067.
- [18] S. Geng, "Analysis of the Different Statistical Metrics in Machine Learning," 2024.
- [19] Chavda Rohit P. and Tosal Bhalodia, "Detection and Classification on Plant Disease using Deep Learning Techniques," *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, vol. 10, no. 3, pp. 365–375, May 2024, doi: 10.32628/cseit2410333.
- [20] R. R. Kumar, A. K. Jain, V. Sharma, N. Jain, P. Das, and P. Sahni, "Advanced Deep Learning Model for Multi-Disease Prediction in Potato Crops: A Precision Agriculture Approach," in *2024 IEEE International Conference on Information Technology, Electronics and Intelligent Communication Systems, ICITEICS 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICITEICS61368.2024.10625281.