

## DEEP LEARNING UNTUK DIAGNOSTIK PENYAKIT DAUN JAGUNG SEBAGAI KONTRIBUSI TERHADAP PENCAPAIAN SDG 2

Viqhy Amrulloh Elhaq<sup>1</sup>, Mas Muhammad Aqil Salim<sup>2</sup>

<sup>1,2</sup> Program Studi Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur

<sup>1</sup> korespondensi: viqhyamrullohelhaq@gmail.com

### ABSTRACT

*Diseases on maize leaves are among the main factors that reduce agricultural productivity and threaten food security. Manual identification through visual observation is still commonly practiced by farmers, which requires a long time and may result in inaccurate diagnoses. This study aims to develop an automatic diagnostic system based on Deep Learning to classify maize leaf diseases quickly and accurately. The method applied is the Pre-Trained MobileNetV2 and Fine-Tuning Model, which utilizes an efficient architecture for visual pattern recognition and adjusts its parameters to match local data characteristics. The dataset consists of four categories: healthy, gray leaf spot, common rust, and blight. The images were processed using augmentation techniques and divided into training, validation, and testing data. The model was trained using the Adam optimization algorithm with a low learning rate and a categorical loss function. The experimental results show that the model achieved approximately 96 percent accuracy in classifying maize leaf diseases. The findings indicate that the implementation of Deep Learning with a transfer learning approach provides accurate diagnostic results, supports early detection of plant diseases, and contributes to increasing agricultural productivity as well as achieving Sustainable Development Goal number 2, Zero Hunger.*

*Keywords: Deep Learning, MobileNetV2, Fine-Tuning, Plant Disease Detection, Zero Hunger.*

### ABSTRAK

*Serangan penyakit pada daun jagung merupakan salah satu faktor utama yang menyebabkan penurunan produktivitas pertanian dan mengancam ketahanan pangan nasional. Proses identifikasi penyakit secara manual masih banyak dilakukan oleh petani melalui pengamatan visual yang membutuhkan waktu lama dan berpotensi menghasilkan diagnosis yang tidak akurat. Penelitian ini bertujuan mengembangkan sistem diagnostik otomatis berbasis Deep Learning untuk mengklasifikasikan penyakit daun jagung secara cepat dan tepat. Metode yang digunakan adalah Pre-Trained MobileNetV2 and Fine-Tuning Model, dengan memanfaatkan arsitektur yang efisien untuk pengenalan pola citra dan melakukan penyesuaian parameter agar sesuai dengan karakteristik data lokal. Dataset yang digunakan terdiri dari empat kelas, yaitu daun sehat, gray leaf spot, common rust, dan blight, yang diproses melalui teknik augmentasi citra serta pembagian data latih, validasi, dan uji. Model dilatih menggunakan algoritma optimisasi Adam dengan tingkat pembelajaran rendah dan fungsi kehilangan kategorikal. Hasil pengujian menunjukkan bahwa model mencapai tingkat akurasi sekitar 96 persen dalam mengklasifikasikan jenis penyakit daun jagung. Kesimpulan dari penelitian ini adalah bahwa penerapan Deep Learning dengan pendekatan transfer pengetahuan mampu memberikan hasil diagnosis yang akurat, mendukung deteksi dini penyakit tanaman, serta berkontribusi terhadap peningkatan produktivitas pertanian dan pencapaian Sustainable Development Goals poin ke-2, yaitu Zero Hunger.*

*Kata Kunci: Deep Learning, MobileNetV2, Fine-Tuning, Deteksi Penyakit Tanaman, Zero Hunger.*


### PENDAHULUAN

Jagung merupakan komoditas pangan utama yang memiliki kontribusi besar terhadap ketahanan pangan dan stabilitas ekonomi nasional di Indonesia (1). Kegagalan panen serta menurunnya kuantitas dan kualitas hasil

panen jagung merupakan salah satu masalah utama di Indonesia. Kondisi ini disebabkan oleh kurangnya pengetahuan petani tentang dampak serangan hama dan penyakit yang menyerang tanaman jagung, sehingga merugikan petani. Produktivitas tanaman ini

sering menurun akibat serangan penyakit pada daun seperti *gray leaf spot*, *common rust*, dan *blight* yang sulit dikenali secara dini sebagaimana bisa dilihat pada Gambar 1.

Metode deteksi penyakit tradisional yang mengandalkan inspeksi manual pada daun tanaman bersifat *labor-intensive*, subjektif, dan rentan terhadap kesalahan (2).



Gambar 1: Contoh Penyakit pada Daun Jagung (3)

Proses identifikasi secara manual masih banyak dilakukan dengan pengamatan visual yang membutuhkan waktu lama, tenaga ahli khusus, dan sering kali menghasilkan diagnosis yang kurang akurat. Kondisi ini menunjukkan perlunya sistem cerdas yang mampu mengenali penyakit tanaman secara otomatis dan efisien untuk membantu petani dalam pengambilan keputusan cepat di lapangan.

Pengembangan model diagnostik penyakit daun jagung berbasis *Deep Learning* dilakukan dengan menerapkan algoritma *Pre-Trained MobileNetV2* and *Fine-Tuning Model* untuk mengklasifikasikan penyakit secara

cepat dan akurat. *MobileNetV2* juga memiliki keunggulan pada jumlah parameter pelatihan yang lebih sedikit, sehingga kebutuhan komputasinya lebih ringan dan efisien dalam memproses citra pada perangkat dengan kemampuan komputasi terbatas (3), sementara proses *fine-tuning* dilakukan dengan menyesuaikan kembali beberapa lapisan teratas pada arsitektur *MobileNetV2* serta menambahkan lapisan klasifikasi khusus untuk memprediksi jenis penyakit pada daun (4). Dataset terdiri atas empat kelas, yaitu daun sehat, *gray leaf spot*, *common rust*, dan *blight*, yang diolah melalui teknik augmentasi citra untuk memperluas variasi data. Melalui

penelitian ini, diharapkan sistem yang dikembangkan mampu memberikan hasil klasifikasi yang akurat, mempercepat proses deteksi dini penyakit tanaman, serta berkontribusi pada pencapaian *Sustainable Development Goals* poin ke-2, yaitu *Zero Hunger*, melalui peningkatan produktivitas pertanian berkelanjutan.

Penerapan *Deep Learning* dalam bidang pertanian telah terbukti memberikan hasil yang signifikan pada berbagai penelitian terdahulu, terutama dalam tugas deteksi objek dan klasifikasi citra tanaman. Metode ini mampu menghasilkan prediksi yang lebih akurat karena bekerja dengan prinsip yang meniru cara kerja otak manusia. Salah satu pendekatan *Deep Learning* yang memberikan hasil signifikan dalam pengenalan objek pada citra adalah *Convolutional Neural Network* (CNN) (5). Teknologi tersebut mampu mengekstraksi fitur kompleks dari citra daun yang sulit dikenali secara konvensional, sehingga menghasilkan sistem identifikasi yang lebih presisi. Selain itu, pendekatan berbasis *transfer learning* memungkinkan pemanfaatan model yang telah dilatih pada dataset besar untuk disesuaikan dengan dataset baru berukuran lebih kecil, tanpa memerlukan waktu pelatihan yang lama atau sumber daya komputasi yang besar. *Transfer Learning* adalah teknik yang menggunakan model yang sudah ditraining sebelumnya (*pre-trained* model) untuk melakukan klasifikasi pada dataset baru, sehingga proses training tidak perlu dimulai dari awal (6). Hal tersebut menjadikan metode *Pre-Trained*

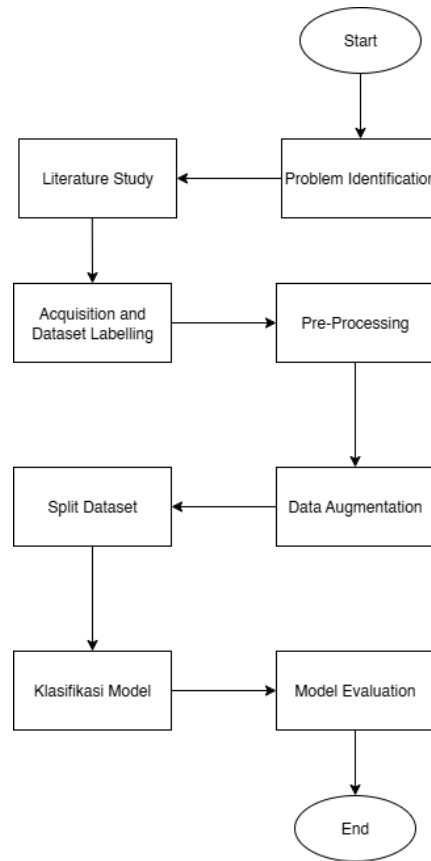
*MobileNetV2* and *Fine-Tuning* Model sangat relevan dan efisien untuk diterapkan dalam konteks pertanian digital di Indonesia.

Fokus penelitian diarahkan tidak hanya pada aspek teknis pengenalan penyakit daun jagung, tetapi juga pada kontribusinya dalam meningkatkan efisiensi serta produktivitas pertanian. Dengan tersedianya sistem diagnostik otomatis yang akurat, petani dapat mengambil tindakan pencegahan lebih cepat untuk mengurangi penyebaran penyakit tanaman. *Smart Farming* berperan dalam mendukung ketahanan pangan dengan meningkatkan hasil panen secara konsisten dan efisien. Teknologi ini juga memberikan kontribusi terhadap keberlanjutan pertanian dan pengelolaan lingkungan secara lebih optimal (7). Secara jangka panjang, penerapan teknologi berbasis *Deep Learning* diharapkan mampu mendorong transformasi menuju pertanian cerdas (*smart agriculture*), yang sejalan dengan agenda nasional dalam memperkuat ketahanan pangan dan mendukung pencapaian *Sustainable Development Goals* poin *Zero Hunger*.

Penerapan teknologi *Deep Learning* dalam diagnosa penyakit tanaman tidak hanya memberikan nilai tambah dari sisi teknis dan produktivitas, tetapi juga memiliki implikasi sosial dan ekonomi yang signifikan dalam mendukung pencapaian *Sustainable Development Goal* (SDG) 2, yaitu *Zero Hunger*. Melalui peningkatan akurasi deteksi penyakit pada daun jagung, teknologi ini dapat digunakan untuk mendeteksi masalah

sejak dini guna meningkatkan hasil panen dan efisiensi produksi (8).

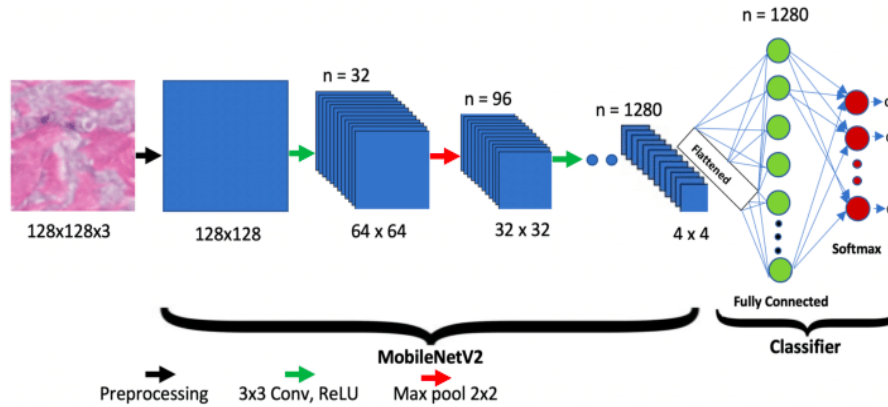
## METODE



**Gambar 2: Diagram Alir Penelitian**

Penelitian ini menggabungkan pendekatan kuantitatif berbasis kajian literatur dengan metode eksperimental berbasis *transfer learning* menggunakan arsitektur *MobileNetV2* untuk klasifikasi penyakit daun jagung (9). Alur lengkap dari proses penelitian ini dapat dilihat pada Gambar 2. Tujuan utama dari penelitian ini adalah untuk mengeksplorasi bagaimana teknologi kecerdasan buatan, khususnya *deep learning*, dapat berkontribusi terhadap Tujuan Pembangunan Berkelanjutan (SDGs), terutama SDG 2 (*Zero Hunger*).

Kajian literatur dilakukan untuk menganalisis hubungan antara ketidakefisienan pengelolaan sumber daya pertanian dan meningkatnya emisi karbon, serta bagaimana penerapan teknologi digital seperti klasifikasi penyakit tanaman dapat meningkatkan efisiensi produksi dan mengurangi penggunaan pestisida secara berlebihan (10). Sumber kajian meliputi artikel ilmiah, laporan dari Bank Dunia, UNEP, dan IEA, serta studi kasus dari wilayah agrikultur yang telah mengadopsi sistem pertanian presisi berbasis AI.



Gambar 3: Arsitektur Model MobileNetV2 (10)

Secara teknis, model yang digunakan adalah *MobileNetV2* yang telah pre-trained pada dataset *ImageNet*, kemudian di *fine-tune* menggunakan dataset *PlantVillage* yang berisi gambar daun jagung sehat dan terinfeksi, yang diilustrasikan pada Gambar 3. Arsitektur model mencakup (11) :

1. Base Model: *MobileNetV2* dengan bobot awal dari *ImageNet*.
2. *Global Average Pooling Layer*: Mengurangi dimensi spasial tanpa menambah parameter.
3. *Dropout Layer*: Dengan *rate* 0.5 untuk menghindari *overfitting*.
4. *Dense Prediction Layer*: Dengan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas.

Rumus Utama yang digunakan dalam proses pelatihan model meliputi:

1. Fungsi Aktivasi (12):

$$ReLU(x) = \max(0, x) \dots \dots \dots (1)$$

2. *Loss Function (Sparse Categorical Crossentropy)* (13):

$$L_{SCCE} = -\frac{1}{N} \sum_{i=1}^N y_i \log(y_i, y_i) \dots \dots \dots (2)$$

3. Update Bobot (*Adam Optimizer*) (14):

$$w_{t+1} = w_t - n \cdot \frac{\partial L}{\partial w_1} \dots \dots \dots (3)$$

4. *Fine-Tuning Constraint* (15):

$$\frac{\partial L}{\partial w_{frozen}} = 0 \dots \dots \dots (4)$$

### HASIL DAN PEMBAHASAN

Pada Bagian ini menyajikan evaluasi hasil kinerja model berdasarkan efektifitas proses pre-trained dengan proses *fine-tuning* dengan menggunakan metode algoritma Transfer Learning *MobileNetV2*. Kinerja model yang di evaluasi yaitu menilai bagaimana rasio peningkatan akurasi model dari proses *pre-trained* ke proses *fine-tuning* yang dapat dinilai mempengaruhi hasil klasifikasi penyakit tanaman daun jagung. Dataset yang digunakan berjumlah total 4186 sampel gambar daun jagung yang telah melalui proses labelisasi dan mewakili 4 kelas penyakit daun jagung: *Gray Leaf*, *Common Rust*, *Blight*, dan satu kelas pembanding (Daun Sehat). Skenario pertama yang di evaluasi adalah Skenario *Pre-Trained* dengan ukuran *epoch*

30 dan *batch size* 32 serta menerapkan augmentasi data. Untuk Skenario kedua yang di evaluasi adalah skenario *Fine-Tuning* dengan melatih ulang Layer ke-50 ke atas

dengan menerapkan *epoch* 20, dengan *batch size default*, dan menerapkan *callbacks reduce learning rate* model untuk mengatasi *overfitting*.

	precision	recall	f1-score	support
Healthy	0.77	0.90	0.83	116
Gray Leaf	1.00	0.95	0.97	150
Common Rust	0.68	0.53	0.59	51
Blight	0.99	0.99	0.99	125
accuracy			0.90	442
macro avg	0.86	0.84	0.85	442
weighted avg	0.90	0.90	0.90	442

Gambar 4: Classification Report Pre-Trained

Pada proses *Pre-Trained*, dengan pembagian dataset (80:10:10) menunjukkan hasil klasifikasi yang cukup baik, dengan akurasi mencapai 90%, sebagaimana yang disajikan dalam *Classification Report* pada Gambar 4. Model mengenali pola masing-masing data, terutama pada data yang dominan, seperti pada data kelas *Gray Leaf*, dan *Blight* dengan F1 Score mencapai 97% dan 99% yang menunjukkan kekuatan model dalam mengenali kelas-kelas berbeda secara pola-

pola data pada data ini. Pada analisis lebih lanjut, model sedikit kesulitan mempertahankan akurasi *F1-Score* yang stabil pada kelas *Common Rust* (*F1-Score*: 59%). *Macro* dan *Weighted Average* untuk skor *precision*, *recall*, dan *F1-Score* semuanya berkisar antara 0,84 - 0,90 yang menunjukkan konsistensi dan pengenalan model yang sangat baik terhadap *Testing Data* yang tersedia.

	precision	recall	f1-score	support
Healthy	0.97	0.89	0.93	125
Gray Leaf	0.99	0.96	0.98	142
Common Rust	0.77	0.97	0.86	60
Blight	1.00	1.00	1.00	121
accuracy			0.95	448
macro avg	0.93	0.95	0.94	448
weighted avg	0.96	0.95	0.95	448

Gambar 5: Classification Report Fine-Tuning

Proses *fine-tuning* yang dilakukan terhadap model *MobileNetV2* menunjukkan peningkatan performa yang signifikan dibandingkan dengan model *pre-trained* awal. Dengan menggunakan pembagian dataset secara default, akurasi model meningkat dari 90% menjadi 95%, sebagaimana ditunjukkan pada Gambar 5. Peningkatan ini mencerminkan kemampuan model yang lebih baik dalam mengenali dan mengklasifikasikan pola visual pada gambar daun jagung.

Evaluasi performa berdasarkan metrik *F1-Score* per kelas menunjukkan peningkatan yang konsisten:

1. Kelas *Healthy* mengalami peningkatan dari 83% menjadi 93%.
2. Kelas *Gray Leaf Spot* meningkat dari 97% menjadi 98%.
3. Kelas *Common Rust* menunjukkan lonjakan signifikan dari 59% menjadi 86%.
4. Kelas *Blight* meningkat dari 99% menjadi 100%.

Peningkatan ini mengindikasikan bahwa proses *fine-tuning* tidak hanya meningkatkan akurasi keseluruhan, tetapi juga memperbaiki distribusi prediksi antar kelas, terutama pada kelas yang sebelumnya memiliki performa rendah seperti *Common Rust*.

Selain itu, skor *Macro Average* dan *Weighted Average* untuk metrik *Precision*, *Recall*, dan *F1-Score* juga mengalami peningkatan, dengan nilai berkisar antara 93% hingga 96%. Hal ini menunjukkan bahwa model memiliki konsistensi yang lebih baik dalam melakukan klasifikasi terhadap seluruh kelas, serta mampu mengenali pola-pola visual secara lebih akurat pada data uji (*testing set*).

Secara keseluruhan, hasil ini menegaskan bahwa strategi *fine-tuning* yang diterapkan berhasil mengoptimalkan kemampuan generalisasi model *MobileNetV2* terhadap data spesifik daun jagung. Dengan peningkatan performa di berbagai metrik evaluasi, model kini lebih andal untuk digunakan dalam sistem deteksi penyakit tanaman secara otomatis, sehingga berpotensi membantu petani dalam mengambil

keputusan yang lebih cepat dan akurat terkait pengendalian penyakit pada tanaman jagung.

**Tabel 1: Perbandingan Hasil Pre-Trained & Fine-Tuning**

Kategori	Rentang Skor	Pre-Trained		Fine-Tuning	
		Data	F1-Score	Data	F1-Score
Healthy	0 - 100	116	83%	125	95%
Gray Leaf	0 - 100	150	97%	142	98%
Common Rust	0 - 100	51	59%	60	86%
Blight	0 - 100	125	99%	121	100%
<i>Accuracy</i>		442	90%	448	95%

Sumber: Hasil data Classification Report

Berdasarkan hasil evaluasi model, pendekatan *fine-tuning* menunjukkan peningkatan performa yang signifikan dibandingkan dengan model *pre-trained* awal. Rincian hasil evaluasi performa model tersebut disajikan pada Tabel 1. Pada tahap *pre-trained*, model yang dilatih dengan pembagian dataset 80:10:10 menghasilkan akurasi sebesar 90%, dengan performa yang sangat baik pada kelas dominan seperti *Gray Leaf Spot* dan *Blight*, masing-masing mencapai *F1-Score* sebesar 97% dan 99%. Namun, model mengalami kesulitan dalam mempertahankan stabilitas klasifikasi pada kelas *Common Rust*, dengan *F1-Score* hanya sebesar 59%, yang menunjukkan keterbatasan model dalam mengenali pola visual yang lebih kompleks atau kurang representatif.

Sebaliknya, setelah dilakukan *fine-tuning* terhadap 50 layer terakhir dari arsitektur

*MobileNetV2*, akurasi model meningkat menjadi 95%. Peningkatan ini juga tercermin dalam skor F1 pada masing-masing kelas, terutama pada kelas *Common Rust* yang mengalami lonjakan signifikan dari 59% menjadi 86%. Kelas *Healthy* juga menunjukkan peningkatan dari 83% menjadi 93%, sedangkan *Gray Leaf Spot* dan *Blight* masing-masing meningkat menjadi 98% dan 100%.

Skor *Macro Average* dan *Weighted Average* untuk metrik *Precision*, *Recall*, dan *F1-Score* juga mengalami peningkatan dari kisaran 0,84 – 0,90 pada model *pre-trained* menjadi 0,93 – 0,96 pada model *fine-tuned*. Hal ini menunjukkan bahwa model tidak hanya lebih akurat, tetapi juga lebih konsisten dalam mengenali pola antar kelas secara seimbang.

Secara keseluruhan, hasil ini menegaskan bahwa strategi *fine-tuning* yang diterapkan

berhasil meningkatkan generalisasi model dan mengurangi risiko *overfitting*, sehingga model lebih adaptif terhadap variasi data yang terdapat dalam citra daun jagung. Hasil penelitian menunjukkan bahwa arsitektur yang ringan dan efisien seperti MobileNetV2 memiliki keunggulan yang signifikan pada dataset pertanian dengan jumlah terbatas, khususnya ketika dilatih menggunakan strategi fine-tuning bertahap yang efektif dalam mengoptimalkan transfer pengetahuan dari tahap *pre-training* (16). Peningkatan performa ini juga mendukung tujuan penelitian dalam menyediakan solusi teknologi berbasis *deep learning* untuk diagnostik penyakit tanaman secara efisien dan berkelanjutan, sejalan dengan pencapaian SDG 2: *Zero Hunger*.

## SIMPULAN

Penelitian ini menunjukkan bahwa penerapan arsitektur *Deep Learning* berbasis *MobileNetV2* dengan pendekatan *fine-tuning* mampu meningkatkan performa model secara signifikan dalam melakukan klasifikasi penyakit daun jagung, dibandingkan model *pre-trained* awal. Melalui pelatihan ulang pada 50 lapisan terakhir, akurasi model meningkat dari 90% menjadi 95%, dengan perbaikan mencolok pada kelas *Common Rust* dari 59% menjadi 86% serta peningkatan konsistensi skor *Precision*, *Recall*, dan *F1-Score* hingga 0,96. Hasil ini membuktikan efektivitas *transfer learning* dalam meningkatkan kemampuan generalisasi dan stabilitas model terhadap variasi visual pada citra daun. Secara praktis, keberhasilan model

ini memperkuat potensi penerapan teknologi AI untuk diagnosis dini penyakit tanaman yang dapat membantu petani dalam pengambilan keputusan cepat, menekan kehilangan hasil panen, dan mendukung ketahanan pangan berkelanjutan sebagai kontribusi nyata terhadap pencapaian SDG 2 (*Zero Hunger*).

## DAFTAR PUSTAKA

1. Zein N. Pengembangan Varietas Unggul Jagung Hibrida Untuk Ketahanan Pangan Nasional. *Lit Notes*. 2024;2(1).
2. Gookyi Dan, Wulnye Fa, Arthur Eae, Ahiadormey Rk, Agyemang Jo, Agyekum Kobo, Et Al. Tinyml For Smart Agriculture: Comparative Analysis Of Tinyml Platforms And Practical Deployment For Maize Leaf Disease Identification. *Smart Agric Technol*. 2024;8:100490.
3. Simanjuntak Jm, Others. Application Of Mobilenetv2 Architecture With Simam For Automatic Detection Of Diseases On Mango Leaves. Universitas Medan Area; 2025.
4. Agustiani S, Aryanti R, Wildah Sk, Arifin Yt, Marlina S, Misriati T. Optimisasi Model Deep Learning Untuk Deteksi Penyakit Daun Tebu Dengan Fine-Tuning Mobilenetv2. *J Informatics Manag Inf Technol*. 2024;4(4):150–7.
5. Amin M, Bindas A. Pengklasifikasi Bibit Kelapa Menggunakan Algoritma Deep Learning Convolutional Neural Network. *J Perangkat Lunak*. 2024;6(3):405–13.
6. Inaya An, Rahma Au, Jannah M, Arafah Lrk, Ishak Ll, Edy Mr. Klasifikasi Citra Dengan Pendekatan Transfer Learning Pada Gambar Fauna Terbang. *J Mediat*. 2024;85–9.

7. Setya Hadi H. Penerapan Iot Pada Smart Farming. Yayasan Putra Adi Dharma; 2025.
8. Alaydrus Aza. Mekanisasi Pertanian Untuk Tanaman Pangan. Mek Pertan. 2025;34.
9. Sujatha R, Krishnan S, Chatterjee Jm, Gandomi Ah. Advancing Plant Leaf Disease Detection Integrating Machine Learning And Deep Learning. Sci Rep. 2025;15(1):11552.
10. Kaya Y, Gürsoy E. Retracted Article: A Mobilenet-Based Cnn Model With A Novel Fine-Tuning Mechanism For Covid-19 Infection Detection. Soft Comput. 2023;27(9):5521.
11. Upadhyay A, Chandel Ns, Singh Kp, Chakraborty Sk, Nandede Bm, Kumar M, Et Al. Deep Learning And Computer Vision In Plant Disease Detection: A Comprehensive Review Of Techniques, Models, And Trends In Precision Agriculture. Artif Intell Rev. 2025;58(3):92.
12. Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking The Inception Architecture For Computer Vision. In: Proceedings Of The Ieee Conference On Computer Vision And Pattern Recognition. 2016. P. 2818–26.
13. Chollet F, Chollet F. Deep Learning With Python. Simon And Schuster; 2021.
14. Mahlein Ak, Arnal Barbedo Jg, Chiang Ks, Del Ponte Em, Bock Ch. From Detection To Protection: The Role Of Optical Sensors, Robots, And Artificial Intelligence In Modern Plant Disease Management. Phytopathology®. 2024;114(8):1733–41.
15. Sandler M, Howard A, Zhu M, Zhmoginov A, Chen Lc. Mobilenetv2: Inverted Residuals And Linear Bottlenecks. In: Proceedings Of The Ieee Conference On Computer Vision And Pattern Recognition. 2018. P. 4510–20.
16. Firmansyah Fd. Deteksi Penyakit Daun Bawang Merah Menggunakan Transfer Learning Dengan Mobilenetv2 Berbasis Citra.