



## Penerapan Jaringan Syaraf Konvolusional Untuk Deteksi Penyakit Tanaman Kopi Berdasarkan Citra Daun

Yusran Panca Putra<sup>1</sup>, Agus Susanto<sup>2</sup>, Willi Novrian<sup>3</sup>

<sup>123</sup>Program Studi Sistem Informasi, Fakultas Teknik, Universitas Bengkulu

[1\\_yusranpanca@unib.ac.id](mailto:1_yusranpanca@unib.ac.id), [2\\_agus.susanto@unib.ac.id](mailto:2_agus.susanto@unib.ac.id), [3\\_willinovrian@unib.ac.id](mailto:3_willinovrian@unib.ac.id)

### Abstract

*The productivity of coffee plants in Indonesia is significantly affected by leaf diseases which often undetected early due to farmers' limited knowledge in identifying disease symptoms. Manual detection methods require specific expertise and time-consuming that cause inefficient for large-scale implementation. Therefore, a technology-based approach is needed to provide faster and more accurate solutions. This study proposes the use of a Convolutional Neural Network (CNN) method with the ResNet-50 architecture to detect coffee plant diseases based on leaf images. The dataset was obtained from a public Kaggle source, consisting of 1,664 leaf images classified into healthy and diseased categories. Model training was conducted on the Google Co-laboratory platform using the Adam optimizer and various data augmentation techniques to enhance generalization. The training results showed that the ResNet-50 model achieved a training accuracy of 96.33% and validation accuracy of 95.31% after 40 epochs. Model evaluation on test data produced a macro average precision of 95.83%, recall of 96.05%, and F1-score of 95.58%. The model demonstrated effectiveness in identifying various types of diseases such as miner, phoma and rust. Although some minor misclassifications were observed. This research highlights the potential of CNN in smart agriculture applications particularly for the automated detection of coffee plant diseases. The findings serve as a foundation for developing user-friendly mobile or web-based diagnostic tools that can assist farmers in disease management, ultimately contributing to increased crop yields and improved agricultural productivity.*

**Keywords:** Plant disease detection, Coffee leaf image, Convolutional Neural Network, ResNet-50, Smart agriculture.

### Abstrak

Produktivitas tanaman kopi di Indonesia sangat dipengaruhi oleh serangan penyakit daun yang sering kali tidak terdeteksi secara dini akibat keterbatasan pengetahuan petani dalam mengenali gejala penyakit. Deteksi penyakit secara manual membutuhkan keahlian khusus dan waktu yang tidak efisien, sehingga dibutuhkan pendekatan berbasis teknologi untuk memberikan solusi yang lebih cepat dan akurat. Penelitian ini mengusulkan pemanfaatan metode *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-50 untuk mendeteksi penyakit tanaman kopi berdasarkan citra daun. Data citra daun diperoleh dari dataset publik Kaggle, yang mencakup total 1664 citra daun kopi dengan klasifikasi sehat maupun terinfeksi penyakit. Proses pelatihan dilakukan pada platform *Google Colaboratory* menggunakan algoritma optimisasi Adam dan teknik augmentasi untuk meningkatkan kemampuan generalisasi model. Hasil pelatihan menunjukkan bahwa model *ResNet-50* mampu mencapai akurasi pelatihan sebesar 96,33% dan akurasi validasi sebesar 95,31% setelah 40 epoch. Evaluasi model terhadap data uji menghasilkan nilai macro average precision sebesar 95,83%, recall 96,05%, dan F1-score 95,58%. Model terbukti efektif dalam mendeteksi berbagai jenis penyakit seperti miner, phoma, dan rust, meskipun masih terdapat kesalahan klasifikasi minor. Penelitian ini menunjukkan potensi besar dari penerapan CNN dalam bidang pertanian cerdas, khususnya dalam deteksi otomatis penyakit tanaman kopi, serta dapat menjadi dasar pengembangan sistem

deteksi berbasis aplikasi yang mudah digunakan oleh petani. Temuan ini berkontribusi pada pengembangan teknologi tepat guna dalam mendukung peningkatan hasil dan kualitas produksi pertanian.

Kata kunci: Deteksi penyakit tanaman, Citra daun kopi, Convolutional Neural Network, ResNet-50, Pertanian cerdas.

© 2025 Author  
Creative Commons Attribution 4.0 International License



## 1. Pendahuluan

Tanaman kopi memiliki peranan yang signifikan dalam industri pertanian Indonesia. Sebagai salah satu tanaman pertanian unggulan, kopi memberikan kontribusi penting dalam meningkatkan perekonomian negara dan pengembangan perkebunan di Indonesia [1]. Kehadiran kopi di Indonesia telah menjadi bagian integral dari sektor pertanian di negara ini [2]. Produktivitas kopi merupakan salah satu fokus utama dalam sistem produksi kopi Indonesia, dimana rendahnya produktivitas menjadi tantangan utama yang perlu diatasi [3].

Salah satu masalah serius yang menyebabkan menurunnya produktivitas dan kualitas kopi adalah penyakit tanaman kopi. Penanganan penyakit pada tanaman kopi seringkali tidak optimal karena kurangnya pemahaman petani terkait penyakit yang menyerang tanaman kopi [4]. Oleh karena itu, pemahaman yang baik mengenai penyakit tanaman kopi menjadi kunci keberhasilan dalam meningkatkan produktivitas kopi, yang dapat didukung melalui kegiatan pelatihan, pendampingan dalam penanganan penyakit dan pemanfaatan teknologi. [5].

Perkembangan teknologi dalam bidang kecerdasan buatan khususnya *machine learning* telah banyak dimanfaatkan dalam berbagai bidang. Penelitian [6] dan [7] telah berhasil menerapkan model-model *machine learning* untuk analisis sentimen. Selain itu, *machine learnig* juga telah banyak digunakan untuk deteksi penyakit tanaman. Salah satu metode yang dapat membantu dalam menyelesaikan masalah deteksi penyakit tanaman adalah Jaringan Syaraf Konvolusional/*Convolutional Neural Network* (CNN). Jaringan saraf konvolusional (CNN) memainkan peran penting dalam deteksi penyakit tanaman. CNN merupakan jenis jaringan saraf tiruan yang menggunakan konvolusi sebagai pengganti perkalian matriks umum di setidaknya salah satu lapisannya [8]. Dalam konteks deteksi penyakit tanaman, CNN telah digunakan dalam berbagai studi untuk mendeteksi hama dan penyakit pada tanaman, seperti deteksi penyakit tomat [8] dan deteksi penyakit pada tanaman jeruk [9]. Selain itu, jaringan saraf konvolusional juga telah diterapkan dalam bidang pertanian untuk mengidentifikasi penyakit tanaman dengan metode deteksi molekuler [10].

Jaringan syaraf konvolusional (CNN) telah terbukti menjadi alat yang efektif dalam deteksi penyakit tanaman kopi. Studi-studi terkait telah menunjukkan keberhasilan penggunaan CNN dalam mengenali penyakit pada tanaman dengan tingkat keberhasilan yang tinggi. Misalnya, sebuah penelitian yang menggunakan model CNN untuk mengenali penyakit pada tanaman tomat mencapai tingkat keberhasilan top-1 sebesar 96.3% dan top-5 sebesar 99.99% [11]. Begitu juga, penelitian lain yang fokus pada klasifikasi penyakit tanaman berdasarkan citra daun mencapai tingkat presisi antara 91% hingga 98%, dengan rata-rata 96.3% [12].

Selain itu, terdapat penelitian yang menggunakan model CNN untuk mengenali penyakit pada tanaman teh dengan hasil yang menjanjikan [13]. Dalam konteks deteksi penyakit tanaman kopi, penggunaan CNN juga telah terbukti berhasil dalam mendeteksi penyakit pada tanaman lain, seperti *flavescence doree* pada tanaman anggur [14]. Model-model CNN yang dikembangkan dalam berbagai penelitian ini telah memberikan hasil yang memuaskan, dengan tingkat akurasi yang tinggi.

Selain itu, terdapat penelitian yang menunjukkan bahwa penggunaan CNN dalam deteksi penyakit tanaman dapat membantu petani meningkatkan kualitas dan kuantitas hasil pertanian mereka [15]. Dengan demikian, penggunaan jaringan syaraf konvolusional dalam deteksi penyakit tanaman kopi dapat memberikan kontribusi yang signifikan dalam upaya pencegahan dan pengendalian penyakit tanaman, serta peningkatan produktivitas pertanian.

Dalam CNN terdapat arsitektur yang dapat digunakan, salah satunya adalah arsitektur ResNet-50. Penelitian yang dilakukan oleh [16], menunjukkan bahwa model ResNet-50 sangat efektif dalam mengenali jenis-jenis sampah, dengan tingkat akurasi pada tahap pelatihan mencapai 78% dan 90%, serta pada tahap validasi mencapai 75% dan 80%. Penelitian [17] mengenai deteksi Kanker Kolorektal menemukan bahwa ResNet-50 menunjukkan kinerja yang sangat baik, dengan tingkat akurasi klasifikasi di atas 80%. Selanjutnya penelitian [18] mengenai klasifikasi penyakit pada strawberry menggunakan ResNet-50 mencapai tingkat akurasi yang sangat tinggi, mencapai 100% untuk kasus pada pucuk, daun, dan buah, serta 98% untuk jamur abu-abu dan 98% untuk jamur tepung.

Penerapan CNN, khususnya arsitektur ResNet-50 yang terbukti andal dalam klasifikasi citra dengan akurasi tinggi, menjadi solusi potensial untuk mendeteksi penyakit pada daun kopi secara otomatis dan akurat guna mendukung peningkatan hasil pertanian.

## 2. Metode Penelitian

Identifikasi penyakit tanaman kopi dilakukan melalui beberapa tahapan, yaitu studi literatur, pengumpulan data, perancangan, implementasi, pengujian, dan analisis hasil. Proses tersebut digambarkan pada Gambar 1.



Gambar 1. Metode Penelitian

### 2.1. Studi Literatur

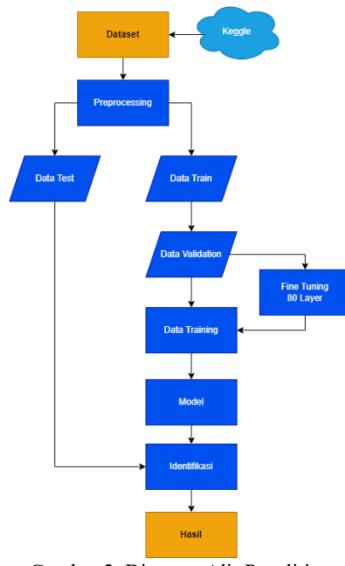
Tahap awal penelitian dilakukan melalui studi literatur dari buku dan jurnal terkait identifikasi penyakit tanaman kopi berbasis citra daun menggunakan metode CNN dan arsitektur ResNet-50. Tanaman kopi, sebagai komoditas penting, membutuhkan penanganan penyakit yang tepat untuk menjaga produktivitasnya. CNN sebagai bagian dari *deep learning*, terdiri dari *convolutional layer*, *pooling layer*, dan *fully connected layer*, digunakan untuk mengolah data citra dua dimensi secara efektif. *Convolution layer* berfungsi mengekstraksi fitur dari citra, *pooling layer* mereduksi dimensi untuk mempercepat komputasi dan mencegah *overfitting*, sementara *fully connected layer* menggabungkan fitur untuk klasifikasi. Teknik augmentasi seperti *flip* dan *random rotation* digunakan untuk memperbanyak variasi data secara tidak langsung. ResNet-50 dipilih karena memiliki *shortcut connection* yang mampu menjaga informasi selama pelatihan. Proses pelatihan model menggunakan *optimizer Adam* yang membantu mempercepat konvergensi dengan meminimalkan loss dan memaksimalkan akurasi.

### 2.2. Pengumpulan Data

Pada tahap ini, data dikumpulkan dari dataset *Coffee Leaf Diseases* yang bersifat publik dan diakses melalui Kaggle. Dataset terdiri dari 1264 citra daun untuk pelatihan dan 400 citra untuk pengujian, masing-masing berukuran 2048 x 1024 piksel, disertai *file label* yang mengklasifikasikan daun sehat dan yang terindikasi penyakit.

### 2.3. Perancangan

Pada penelitian ini diperlukan sebuah rancangan yang digunakan untuk penelitian yaitu metode CNN dan arsitektur ResNet-50. Perancangan tersebut dapat dilihat di gambar 2.



Gambar 2. Diagram Alir Penelitian

Proses dimulai dengan pengumpulan dataset, lalu dilakukan *preprocessing* dengan mengubah ukuran citra dari 2048×1024 menjadi 224×224 piksel, serta memisahkan daun berpenyakit dan sehat berdasarkan *file label*. Proses ini ditampilkan pada Gambar 3.



Gambar 3. Preprocessing Citra Daun Kopi

Langkah selanjutnya adalah augmentasi data menggunakan berbagai parameter seperti *shear*, *rotation*, *zoom*, *brightness*, *shift*, dan *flip*, serta *validation split* pada data latih. Model dilatih selama 20 *epoch* dengan semua *layer* dibekukan, lalu dilanjutkan *fine tuning* selama 40 epoch dengan hanya 80 *layer* awal yang dibekukan. Model menggunakan dua *hidden layer* (32 dan 16 neuron) dengan aktivasi ReLU, *dropout* 0.4, serta dua output layer dengan aktivasi *softmax*. Model yang telah dilatih disimpan dalam format .h5 dan digunakan untuk mengidentifikasi data uji.

#### 2.4. Implementasi

Pada tahapan ini dilakukan mengimplementasi algoritma untuk penelitian yang telah dirancang agar sistem dapat membedakan *health* dan *infected* menggunakan data yang ada sebelumnya dan melakukan operasi perhitungan dalam bentuk kode program untuk menghitung akurasi dan *confusion matrix* pada ResNet-50.

#### 2.5. Pengujian

Ditahap ini dilakukan pengujian terhadap *data test* dengan program yang sudah dibuat, sistem tersebut mengumpulkan data yang diperoleh dan menerapkan hasil dari identifikasi untuk mendapatkan *accuracy*, *precision*, *recall*, dan *F1-Score*.

#### 2.6. Analisis Hasil Pengujian

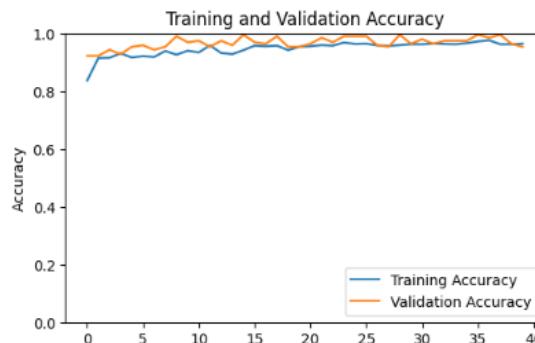
Pada tahap ini dilakukan analisis dan menghitung hasil yang telah di uji untuk mendapatkan tingkat keberhasilan dari metode yang digunakan dengan *Confusion Matrix* untuk menghitung nilai *precision*, *recall*, dan *F1-Score*. *Precision* adalah jumlah total dari sampel positif terkласifikasikan sebagai benar dibagi dengan jumlah total sampel positif yang diprediksi. *Recall* didefinisikan sebagai rasio jumlah total positif yang terkласifikasikan bernilai benar dibagi dengan jumlah total positif. *Accuracy* adalah jumlah prediksi yang benar dengan jumlah total prediksi. *F1-Score* didefinisikan sebagai rata-rata harmonic antara presisi dan *Recall*.

### 3. Hasil dan Pembahasan

Bab ini membahas hasil pelatihan, evaluasi performa ResNet50 dalam mengidentifikasi penyakit tanaman kopi berdasarkan citra daun.

#### 3.1. Pelatihan Model

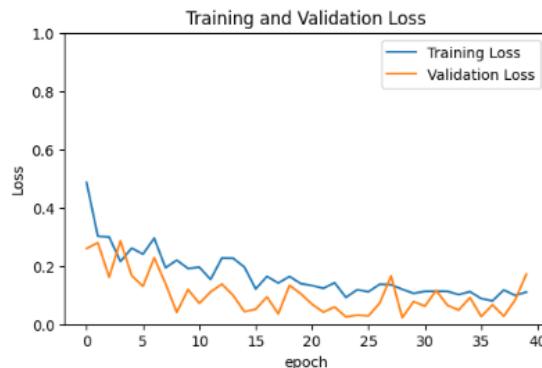
Hasil pelatihan model Resnet50 pada data citra daun tanaman kopi yang dilakukan sebanyak 40 divisualisasikan menggunakan grafik berdasarkan hasil nilai akurasi training dan validasi pada Gambar 4.

Gambar 4. Grafik pelatihan model ResNet50 berdasarkan nilai akurasi *train* dan validasi

Ukuran halaman adalah A4 (210 mm x 297 mm). Margin halaman adalah 25 mm atas-bawah, kiri dan kanan.

Gambar 4 menunjukkan peningkatan akurasi *train* dan validasi yang konsisten hingga *epoch* ke-40, dengan hasil masing-masing 96,33% dan 95,31%, menandakan model mampu mempelajari pola citra daun dan menggeneralisasi jenis penyakit secara akurat.

Hasil pelatihan model Resnet50 pada data citra daun tanaman kopi juga divisualisasikan menggunakan grafik berdasarkan hasil nilai *loss training* dan validasi pada Gambar 5.



Gambar 5. Grafik pelatihan model ResNet50 berdasarkan nilai *loss train* dan validasi

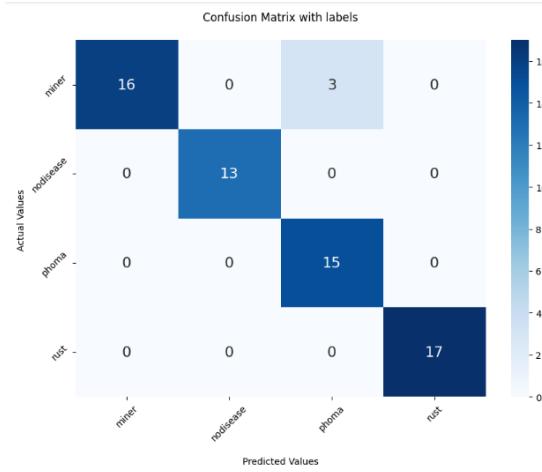
Gambar 5 menunjukkan penurunan *loss train* dan validasi yang konsisten hingga *epoch* ke-40, dengan nilai masing-masing sebesar 0,1094 dan 0,1719. Nilai *loss* yang rendah ini menandakan bahwa model memiliki kemampuan prediksi yang baik. Hasil pelatihan dirangkum pada Tabel 5.1, yang mengilustrasikan performa tinggi model dalam mempelajari pola data dan menggeneralisasi pada data validasi.

Tabel 1. Hasil Pelatihan Model ResNet50 pada *Epoch* ke-40

| Epoch | Akurasi <i>Train</i> (%) | Akurasi <i>Validasi</i> (%) | Loss <i>Train</i> | Loss <i>Validasi</i> |
|-------|--------------------------|-----------------------------|-------------------|----------------------|
| 40    | 96.33                    | 95.31                       | 0.1094            | 0.1719               |

### 3.2. Evaluasi Model

Evaluasi dilakukan untuk mengukur performa model ResNet50 dalam mengidentifikasi penyakit kopi berdasarkan 64 data uji. Hasilnya divisualisasikan melalui *confusion matrix* (Gambar 3.3) dan *classification report* (Gambar 3.4), yang mencakup nilai *precision*, *recall*, dan *f1-score* untuk tiap kelas.



Gambar 6. Evaluasi *confusion matrix* model ResNet50 tanaman kopi

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| miner        | 1.0000    | 0.8421 | 0.9143   | 19      |
| nodisease    | 1.0000    | 1.0000 | 1.0000   | 13      |
| phoma        | 0.8333    | 1.0000 | 0.9091   | 15      |
| rust         | 1.0000    | 1.0000 | 1.0000   | 17      |
| accuracy     |           |        | 0.9531   | 64      |
| macro avg    | 0.9583    | 0.9605 | 0.9558   | 64      |
| weighted avg | 0.9609    | 0.9531 | 0.9532   | 64      |

Gambar 7. Nilai evaluasi *classification report* model ResNet50 tanaman kopi

Gambar 3.3 dan 3.4 menunjukkan evaluasi model ResNet50 dalam mengidentifikasi penyakit kopi. Kelas *miner* memiliki *precision* 100% dan *recall* 84,21%, dengan *F1-score* 91,43% karena terdapat 3 prediksi salah. Kelas *non-disease* dan *rust* menunjukkan performa sempurna (*precision*, *recall*, dan *F1-score* 100%). Pada kelas *phoma*, *recall* mencapai 100% namun *precision* hanya 83,33% akibat kesalahan prediksi dari kelas *miner*. Secara keseluruhan, nilai *macro average* mencapai *precision* 95,83%, *recall* 96,05%, dan *F1-score* 95,58%.

Hasil evaluasi model ResNet50 ditampilkan berdasarkan metrik *precision*, *recall*, dan *F1-score* untuk masing-masing kelas penyakit, yaitu *miner*, *phoma*, *rust*, dan *non-disease*. Tabel berikut merangkum performa tiap kelas serta nilai rata-rata (*macro average*) dari ketiga metrik tersebut.

Tabel 2. Evaluasi Model ResNet50 untuk Identifikasi Penyakit Tanaman Kopi

| Kelas Penyakit       | TP | FP | FN | Precision (%) | Recall (%)   | F1-Score (%) |
|----------------------|----|----|----|---------------|--------------|--------------|
| <i>Miner</i>         | 16 | 0  | 3  | 100           | 84.21        | 91.43        |
| <i>Non Disease</i>   | -  | 0  | 0  | 100           | 100          | 100          |
| <i>Phoma</i>         | -  | 1  | 0  | 83.33         | 100          | -            |
| <i>Rust</i>          | -  | 0  | 0  | 100           | 100          | 100          |
| <i>Macro Average</i> |    |    |    | <b>95.83</b>  | <b>96.05</b> | <b>95.58</b> |

Keterangan evaluasi metrik pada tabel mencakup beberapa istilah penting. *True Positive* (TP) adalah jumlah data yang berhasil diprediksi dengan benar oleh model. *False Positive* (FP) merupakan jumlah data yang salah diprediksi sebagai kelas tertentu, padahal sebenarnya bukan. *False Negative* (FN) adalah jumlah data dari suatu kelas yang salah diprediksi sebagai kelas lain. *Precision* mengukur ketepatan prediksi model terhadap data yang sebenarnya, sedangkan *Recall* menunjukkan sejauh mana model mampu mendeteksi seluruh data yang benar dari suatu kelas. *F1-Score* merupakan nilai harmonis dari *precision* dan *recall*, yang memberikan gambaran keseimbangan antara keduanya.

#### 4. Kesimpulan

Kesimpulan dari hasil dan pembahasan pelatihan dan evaluasi model ResNet50 dalam mendeteksi penyakit tanaman kopi berdasarkan citra daun menunjukkan bahwa model ini memiliki performa yang sangat baik. Model ResNet50 yang telah dilatih selama 40 *epoch* mencapai akurasi *train* sebesar 96.33% dan akurasi validasi 95.31%, serta menunjukkan penurunan *loss* yang konsisten. Evaluasi performa model menggunakan *data testing* menghasilkan nilai *macro average* yang tinggi, yaitu *precision* sebesar 95.83%, *recall* sebesar 96.05%, dan *f1-score* sebesar 95.58%. Pada beberapa kelas penyakit, seperti *miner*, *phoma*, dan *rust*, model mampu memberikan hasil yang hampir sempurna, meskipun ada beberapa kasus prediksi salah, terutama pada kelas *miner* yang terprediksi sebagai *phoma*. Secara keseluruhan, model ResNet50 ini mampu menggeneralisasi data dengan baik dan menunjukkan kinerja yang solid dalam mengidentifikasi berbagai jenis penyakit pada tanaman kopi.

#### Ucapan Terimakasih

Ucapan terima kasih disampaikan kepada Fakultas Teknik Universitas Bengkulu atas dukungan pendanaan melalui skema PNBP (Penerimaan Negara Bukan Pajak) yang telah memungkinkan terlaksananya penelitian ini. Dukungan tersebut sangat berperan penting dalam penyelesaian kegiatan penelitian, mulai dari perencanaan, pelaksanaan, hingga pelaporan hasil, serta menjadi pendorong dalam pengembangan riset berbasis teknologi yang aplikatif dan relevan bagi sektor pertanian.

#### Daftar Rujukan

- [1] N. Risdawati and S. Soemarno, "Pengaruh Aplikasi Kompos Kulit Buah Kopi Terhadap Kandungan Bahan Organik Dan Fosfor Pada Inceptisol Kebun Kopi Desa Bangelan, Malang," *Jurnal Tanah Dan Sumberdaya Lahan*, 2021, doi: 10.21776/ub.jtsl.2021.008.2.17.
- [2] I. D. K. T. A. Laksanti, "Variasi Nama-Nama Kopi Di Indonesia," *Kelasa*, 2021, doi: 10.26499/kelasa.v16i1.163.
- [3] Y. Sarvina, T. June, E. Surmaini, R. Nurmalina, and S. S. Hadi, "Strategi Peningkatan Produktivitas Kopi Serta Adaptasi Terhadap Variabilitas Dan Perubahan Iklim Melalui Kalender Budidaya," *Jurnal Sumberdaya Lahan*, 2020, doi: 10.21082/jsdl.v14n2.2020.65-78.
- [4] E. Sudaryanto, A. Suryanto, and T. Watiningsih, "Sistem Pakar Penyakit Pada Tanaman Kopi Berbasis Android Menggunakan Metode Forward Chaining," *Teodolita Media Komunikasi Ilmiah Di Bidang Teknik*, 2022, doi: 10.53810/jt.v22i2.422.
- [5] R. Lantarsih, N. C. Kresnanto, R. Raharti, and W. H. Putri, "Pemberdayaan Kelompok Tani Kopi Desa Balerante Kabupaten Klaten," *Jurnal Pengabdian Undikma*, 2022, doi: 10.33394/jpu.v3i2.5598.

- [6] V. Renedominick and S. Barus, "Analisis Sentimen pada Trailer Deadpool vs Wolverine Menggunakan Model Machine Learning," *Jurnal Pustaka AI (Pusat Akses Kajian Teknologi Artificial Intelligence)*, vol. 5, no. 1, pp. 01–06, Apr. 2025, doi: 10.55382/jurnalpustakaai.v5i1.892.
- [7] N. Abel Laia and S. P. Barus, "Analisis Sentimen YouTube: 'Di Balik Ambisi Jokowi dalam IKN,'" *Jurnal Pustaka AI (Pusat Akses Kajian Teknologi Artificial Intelligence)*, vol. 5, no. 1, pp. 07–12, Apr. 2025, doi: 10.55382/jurnalpustakaai.v5i1.891.
- [8] R. C. Sigitta, R. H. Saputra, and F. Fathulloh, "Deteksi Penyakit Tomat Melalui Citra Daun Menggunakan Metode Convolutional Neural Network," *Avitec*, 2023, doi: 10.28989/avitec.v5i1.1404.
- [9] M. Megawati and R. M. Candra, "Diagnosa Hama Dan Penyakit Pada Tanaman Jeruk Dengan Menerapkan Jaringan Syaraf Tiruan Learning Vector Quantization (Studi Kasus : Badan Penyuluhan Pertanian Kuok)," *Jurnal Coreit Jurnal Hasil Penelitian Ilmu Komputer Dan Teknologi Informasi*, 2018, doi: 10.24014/coreit.v3i2.4399.
- [10] E. Aulia, M. Sutrawati, and T. Pamekas, "Deteksi Molekuler Dan Analisis Genetik Begomovirus Pada Tanaman Cabai Di Desa Pematang Donok," *Jurnal Ilmu-Ilmu Pertanian Indonesia*, 2022, doi: 10.31186/jipi.24.2.69-74.
- [11] A. Fuentes, S. Yoon, S. C. Kim, and D. S. Park, "A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition," *Sensors*, 2017, doi: 10.3390/s17092022.
- [12] S. Sladojević, M. Arsenović, A. Anderla, D. Ćulibrk, and D. Stefanović, "Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification," *Comput Intell Neurosci*, 2016, doi: 10.1155/2016/3289801.
- [13] J. Chen, Q. Liu, and L. Gao, "Visual Tea Leaf Disease Recognition Using a Convolutional Neural Network Model," *Symmetry (Basel)*, 2019, doi: 10.3390/sym11030343.
- [14] M. A. Musci, C. Persello, and A. M. Lingua, "Uav Images and Deep-Learning Algorithms for Detecting Flavescence Doree Disease in Grapevine Orchards," *The International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences*, 2020, doi: 10.5194/isprs-archives-xliii-b3-2020-1483-2020.
- [15] B. P. Zen, I. K. A, and D. C. Fransisca, "Applications for Detecting Plant Diseases Based on Artificial Intelligence," *Sinkron*, 2022, doi: 10.33395/sinkron.v7i4.11833.
- [16] Stephen, Raymond, and H. Santoso, "Aplikasi Convolution Neural Network Untuk Mendeteksi Jenis-Jenis Sampah," Bandar Lampung, Oct. 2019. Accessed: Jul. 16, 2025. [Online]. Available: <https://download.garuda.kemdikbud.go.id/article.php?article=1299516&val=6024&title=APLIKASI%20CONVOLUTION%20NEU> RAL%20NETWORK%20UNTUK%20MENDETEKSI%20JENIS-JENIS%20SAMPAH
- [17] D. Sarwinda, R. H. Paradisa, A. Bustamam, and P. Anggia, "Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer," in *Procedia Computer Science*, Elsevier B.V., 2021, pp. 423–431. doi: 10.1016/j.procs.2021.01.025.
- [18] J.-R. Xiao, P.-C. Chung, H. Wu, Q.-H. Phan, J. A. Yeh, and M. T. Hou, "Detection of Strawberry Diseases Using a Convolutional Neural Network," *Plants*, vol. 10, no. 1, p. 31, 2020, doi: 10.3390/plants10010031.