e-ISSN: 3025-8189 ; p-ISSN: 3025-8197

LANCAH JURNAL INOVASI DAN TREN

doi.org/10.35870/ljit.v4i2.9104

Vol. 4, No. 2, Tahun 2026

Hal. 1777-1790

Homepage http://www.journal.lembagakita.com/ljit

Optimasi Performa Klasifikasi Penyakit Daun Mangga Menggunakan *ResNet50* melalui Pendekatan *Domain Adaptation*

Riyan Farismana[1], Naila Fathirani Zain[2], A Lubis Ghozali[3], Sahid Triambudhi[4]

Jurusan Teknik Informatika, Politeknik Negeri Indramayu, Kabupaten Indramayu, Indonesia[1,2,3,4]

Email Korespondensi: riyanfarismana@polindra.ac.id

INFO ARTIKEL

Sejarah Artikel:

Diterima *28-10-2026*
Disetujui *04-11-2026*
Diterbitkan *23-11-2026*

ABSTRACT

Mango is an important agricultural commodity that is highly susceptible to pathogens, particularly those affecting its leaves. Because leaves are the primary site where early disease symptoms appear, accurate image-based classification of mango leaf diseases can help reduce yield losses. This study evaluates a ResNet50 convolutional neural network (CNN) with transfer learning and domain adaptation to classify six mango leaf conditions: anthracnose, die back, gall midge, powdery mildew, sooty mould, and healthy leaves. The methodology comprises image pre-processing, ResNet50 modeling with an added classification layer, initial evaluation, domain adaptation, and final evaluation. The model was trained on a primary dataset of 1,178 images collected in Indramayu, Indonesia, and tested on an external public dataset of 300 images. On the internal test set (177 images), the model achieved an accuracy of 100%. However, on the external dataset it achieved only 44.33% accuracy, revealing a domain gap between the two data sources. After domain adaptation, in which part of the external data was added to retraining of the classification layer, accuracy on the held-out external test set (60 images) increased to 100%. Because these test images come from the same source as the external images used for adaptation, the result demonstrates successful adaptation to that specific external distribution rather than generalization to entirely new data sources. Further validation on independent datasets is needed.

Keywords*: Domain Adaption, CNN, Mango Leaf Disease Classification, ResNet50, Transfer Learning.*

ABSTRAK

Mangga merupakan komoditas pertanian penting yang sangat rentan terhadap patogen, terutama yang menyerang bagian daunnya. Karena daun menjadi lokasi utama munculnya gejala awal penyakit, klasifikasi penyakit daun mangga berbasis citra secara akurat dapat membantu mengurangi kehilangan hasil panen. Penelitian ini mengevaluasi arsitektur Convolutional Neural Network (CNN) ResNet50 dengan transfer learning dan domain adaptation untuk mengklasifikasikan enam kondisi daun mangga, yaitu antraknosa, die back, gall midge, powdery mildew, sooty mould, dan daun sehat. Tahapan penelitian meliputi pra-pemrosesan citra, pemodelan ResNet50 dengan tambahan lapisan klasifikasi, evaluasi awal, adaptasi domain, dan evaluasi akhir. Model dilatih menggunakan dataset primer sebanyak 1.178 citra yang dikumpulkan di Indramayu dan diuji pada dataset publik eksternal sebanyak 300 citra. Pada data uji internal (177 citra), model mencapai akurasi 100%. Namun, pada dataset eksternal akurasinya hanya 44,33%, yang menunjukkan adanya kesenjangan domain antara kedua sumber data. Setelah adaptasi domain, yaitu penambahan sebagian data eksternal pada pelatihan ulang lapisan klasifikasi, akurasi pada data uji eksternal (60 citra) meningkat menjadi 100%. Karena citra uji tersebut berasal dari sumber yang sama dengan citra eksternal yang digunakan untuk

Copyright @ 2026. Published by Lembaga Komunitas Informasi Teknologi Aceh (KITA), Indonesia. This work is licensed under a Creative Commons Attribution 4.0 International License (CC BY 4.0). Based on a work at http://journal.lembagakita.com/ljit

Abstract & Indexing CC BY-NC 4.0 OPEN ACCESS

adaptasi, hasil ini menunjukkan keberhasilan adaptasi terhadap distribusi data eksternal tertentu, bukan generalisasi terhadap sumber data yang sepenuhnya baru. Validasi lebih lanjut pada dataset independen masih diperlukan.

Katakunci: Domain Adaption, CNN, Klasifikasi Penyakit Daun Mangga, ResNet50, Transfer Learning.

Bagaimana Cara Sitasi Artikel ini:

Farismana, R., Fathirani Zain, N., Ghozali, A. L., & Triambudhi, S. (2026). Optimasi Performa Klasifikasi Penyakit Daun Mangga Menggunakan ResNet50 melalui Pendekatan Domain Adaptation. LANCAH: Jurnal Inovasi Dan Tren, 4(2), 1777-1790. https://journal.lembagakita.com/ljit/article/view/9104

PENDAHULUAN

Tanaman mangga (*Mangifera indica* L.) merupakan salah satu produk pertanian unggulan domestik yang memiliki kontribusi cukup tinggi terhadap perekonomian sektor pertanian Indonesia (Ariningsih et al., 2021). Dalam budidaya mangga, keadaan daun memegang peran penting sebagai faktor utama yang menentukan hasil panen dan kualitas buah yang dihasilkan. Daun berfungsi sebagai organ utama untuk melakukan fotosintesis serta sebagai bagian yang tetap ada dalam tanaman (Isnansyah et al., 2024). Keragaman morfologi mangga menunjukkan keragaman genetik yang luas. Perbedaan karakteristik morfologi pada setiap jenis tumbuhan membuat daun menjadi dasar dalam mengklasifikasikan setiap jenis tersebut (Fajar Ramadhan et al., 2024). Gangguan pada jaringan daun yang disebabkan oleh infeksi patogen, seperti antraknosa, bercak daun, dan *powdery mildew*, menyebabkan penurunan luas daun yang dapat melakukan fotosintesis. Penurunan kapasitas metabolisme ini berdampak fatal pada tingkat hasil panen; jika tidak segera dideteksi, hal ini dapat menyebabkan kerugian bukan hanya bagi para petani, tetapi juga mengurangi kapasitas hasil panen mangga.

Meskipun deteksi awal penyakit pada daun sangat penting dilakukan sebagai upaya pencegahan kegagalan panen, praktik pengamatan di lapangan saat ini masih terbatas dan bergantung pada prosedur identifikasi konvensional. Identifikasi penyakit daun mangga secara umum masih mengandalkan pengamatan indera penglihatan langsung secara kasatmata di area perkebunan. Metode ini memerlukan peran aktif ahli patologi tanaman atau petani yang telah memiliki pengalaman panjang dalam mengidentifikasi ciri visual penyakit daun. Akan tetapi, jumlah ahli patologi tanaman sangat minim jika dibandingkan dengan luas area perkebunan mangga di Indramayu, sementara itu pengalaman para petani bervariasi secara signifikan dan tanpa rujukan yang jelas. Pengamatan visual yang bergantung pada indera manusia ini sangat rentan terhadap subjektivitas, memakan banyak waktu, dan memiliki kemungkinan tinggi untuk menimbulkan kesalahan diagnosis karena gejala dari berbagai penyakit sering kali mirip pada tahap awal (Saputra et al., 2025).

Untuk mengatasi keterbatasan dalam diagnosis visual oleh manusia serta batasan yang dimiliki oleh para ahli tanaman, penggunaan teknologi *deep learning* muncul sebagai solusi yang sangat menjanjikan untuk mengotomatisasi pengklasifikasian penyakit pada daun dengan akurasi tinggi (Satia et al., 2022). Pendekatan *deep learning* yang memiliki keandalan dalam melakukan klasifikasi, terutama berbasis citra, adalah *Convolutional Neural Networks* (CNN). Pendekatan CNN terbukti menjadi model pembelajaran yang sangat baik dalam mengekstraksi fitur-fitur spasial secara otomatis dari citra digital tanpa memerlukan pengolahan fitur secara manual (Wirabowo & Susilawati, 2025). Penelitian ini memanfaatkan keunggulan CNN yang dikenal akan kemampuannya dalam mengkategorikan dan memberikan hasil yang signifikan dalam identifikasi objek pada data gambar (Adzkia & Arifin, 2025) sebagai solusi dalam deteksi penyakit pada daun mangga. Studi terbaru pada daun mangga membandingkan berbagai arsitektur berbasis pembelajaran transfer, termasuk ResNet50 dan model berbasis transformer, serta memanfaatkan Grad-CAM dan LIME untuk menjelaskan area citra yang memengaruhi keputusan model (Prabhu et al., 2025).

Dalam penelitian ini, model ResNet50, yaitu arsitektur jaringan residual yang diperkenalkan oleh He et al. (2016), diterapkan menggunakan metode pembelajaran transfer yang dikenal sebagai ekstraksi fitur, di mana pengetahuan dari tugas sumber dimanfaatkan untuk tugas target (Pan & Yang, 2010). Seluruh lapisan dasar ResNet50 yang sebelumnya telah dilatih pada dataset ImageNet dibekukan dan berfungsi sebagai pengekstrak fitur (Muzhaffar & Suharjo, 2025), sedangkan proses pelatihan dilaksanakan pada lapisan klasifikasi yang ditambahkan di akhir model. Cara ini memungkinkan penerapan dataset yang lebih

kecil untuk melatih model secara lebih efisien. Desain ini ditujukan untuk mengatasi masalah penurunan akurasi dan *vanishing gradient* yang sering muncul pada jaringan saraf dengan kedalaman sangat tinggi (Hakim et al., 2024). Metode ini membuat jaringan dapat mempelajari fungsi residual sehingga pelatihan menjadi lebih stabil dan akurasi model dapat meningkat meskipun terdapat banyak lapisan. Pendekatan ini memungkinkan penggunaan dataset yang lebih kecil dalam melatih model, sehingga dapat menghemat waktu dan sumber daya yang biasanya dibutuhkan untuk melatih model dari awal.

Kinerja dan keberhasilan model pembelajaran mesin, seperti CNN dan ResNet50, sangat bergantung pada ketersediaan dataset primer yang dikumpulkan langsung dari lingkungan nyata, dalam hal ini perkebunan mangga di Indramayu. Kumpulan data ini menyajikan informasi visual autentik mengenai fenotipe penyakit, varietas tanaman lokal, serta kondisi fisik daun. Karena data primer ini diperoleh secara langsung, data tersebut mencakup karakteristik spasial dan tekstural yang spesifik sehingga menjadi landasan ideal untuk melatih model yang disesuaikan dengan lokasi penelitian (Romaili Siagian et al., 2025). Pemanfaatan kumpulan data primer merupakan prasyarat mendasar untuk memastikan bahwa model yang dihasilkan memiliki tingkat keandalan yang tinggi saat diterapkan dalam kondisi lapangan yang sesungguhnya.

Meskipun demikian, model klasifikasi ini pada akhirnya ditujukan untuk diterapkan dalam skenario dunia nyata yang sangat dinamis, yang cakupannya jauh melampaui lingkungan pengumpulan data awal. Dalam kondisi lapangan yang sesungguhnya, sistem akan menghadapi berbagai variasi lingkungan yang tidak ada selama fase pengumpulan data awal, seperti fluktuasi intensitas cahaya matahari, perbedaan perangkat keras kamera, keragaman kondisi latar belakang, serta sudut pandang pengambilan gambar yang tidak konsisten. Kesenjangan dalam distribusi statistik antara kumpulan data utama dan kondisi lapangan yang nyata dapat memengaruhi kinerja serta akurasi generalisasi model secara berarti, bahkan terkadang secara drastis (Al-Fahrezi, 2025). Untuk memastikan model tetap andal di berbagai lingkungan operasional, penyertaan kumpulan data dari sumber publik atau eksternal menjadi langkah strategis guna meningkatkan keragaman sampel dan memperluas kapasitas generalisasi model tersebut.

Penggabungan kumpulan data dari berbagai sumber sering kali memicu pergeseran domain data (*data domain shifts*). Oleh karena itu, penerapan strategi adaptasi domain melalui proses *fine-tuning* pada arsitektur CNN dan ResNet menjadi bagian penting dalam penelitian ini untuk menjamin kinerja model dalam kondisi dunia nyata. Perbedaan dalam distribusi statistik antara kumpulan data utama dan dataset eksternal kerap menyebabkan pergeseran domain yang menurunkan efisiensi klasifikasi (Dwi Baginda et al., 2026). Teknik domain adaptation memungkinkan jaringan saraf untuk mempelajari fitur yang tetap informatif bagi tugas klasifikasi sekaligus tidak bergantung pada asal domain data (Ganin et al., 2016). Pada klasifikasi penyakit tanaman, pendekatan ini telah dikembangkan, misalnya melalui penyelarasan multi-sumber untuk penyakit kentang pada lingkungan lapangan (Gao et al., 2024) dan kerangka adaptasi domain berbasis jarak Wasserstein (Tunio et al., 2024). Dengan menerapkan pelatihan berbasis adaptasi domain, model klasifikasi penyakit daun mangga tidak hanya mencapai akurasi optimal pada kumpulan data lokal, tetapi juga menunjukkan ketangguhan dan kemampuan generalisasi yang tinggi saat diterapkan dalam lingkungan operasional dunia nyata yang dinamis.

Untuk mengatasi kesenjangan tersebut, penelitian ini bertujuan mengembangkan sistem klasifikasi yang tangguh untuk penyakit pada daun mangga berbasis arsitektur ResNet50 dengan mengintegrasikan dataset primer dan eksternal melalui metode adaptasi domain. Pendekatan ini dirancang untuk memitigasi masalah pergeseran domain yang muncul akibat tingginya variabilitas kondisi lingkungan di dunia nyata.

Keunggulan utama dari pendekatan yang diusulkan terletak pada skema pemetaan fitur lintas domain yang menjamin kemampuan generalisasi model tanpa mengorbankan akurasi diagnostik untuk varietas daun mangga lokal di Indramayu. Melalui kontribusi ini, penelitian ini diharapkan dapat menyediakan solusi berbasis kecerdasan buatan yang andal, yang dapat diadopsi oleh para petani dan praktisi pertanian untuk memantau kesehatan daun mangga secara dini dan akurat, sehingga mendukung keberagaman serta stabilitas produksi dalam sektor hortikultura.

METODE

Penelitian ini menggunakan pendekatan eksperimental kuantitatif untuk menilai dampak sistematis dari pengoptimalan model ResNet50 dalam klasifikasi penyakit pada daun mangga. Pendekatan kuantitatif ini diterapkan untuk memproses data numerik yang mencerminkan kinerja model, yang kemudian dianalisis menggunakan metode statistik dan objektif. Eksperimen ini memanfaatkan arsitektur ResNet50 berbasis *transfer learning*, yang mencakup penyesuaian parameter tertentu serta pra-pemrosesan citra daun mangga. Tujuannya adalah untuk mengevaluasi secara terukur bagaimana intervensi tersebut memengaruhi kemampuan model dalam mengenali dan mengklasifikasikan enam jenis penyakit pada daun mangga pada dataset primer, yang kemudian dievaluasi dan diintegrasikan dengan dataset eksternal dari publik. Hal ini bertujuan agar model dapat belajar mengatasi perbedaan situasi pada kondisi nyata di lapangan.

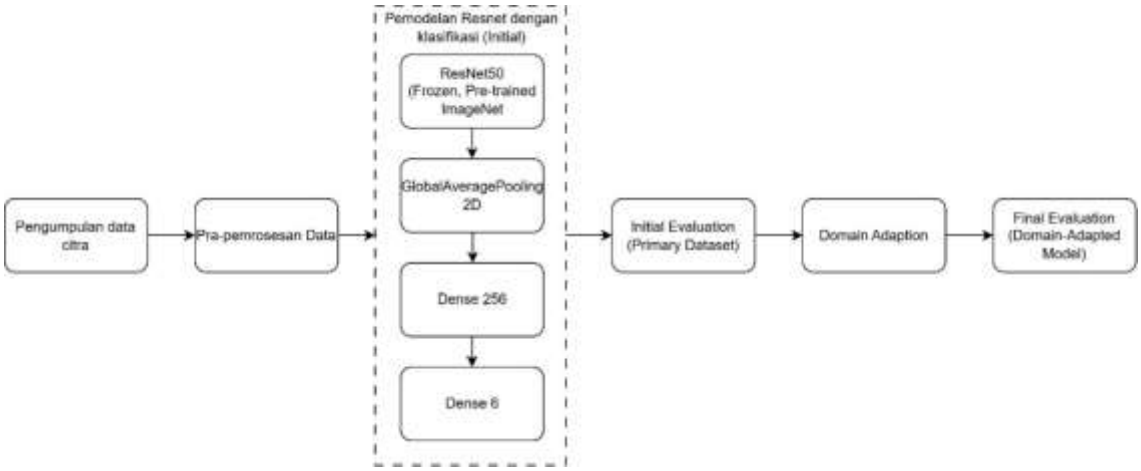

Gambar 1. Tahapan Penelitian
(Sumber: Penulis, 2026)

Penelitian ini diawali dengan pengumpulan data yang dilakukan menggunakan dua cara. Pertama, data primer melalui observasi lapangan dan pendokumentasian langsung citra daun mangga pada Unit Pelaksana Teknis Daerah (UPTD) Balai Pembenihan dan Pembibitan Hortikultura di bawah naungan Dinas Pertanian Kabupaten Indramayu. Citra yang diperoleh melalui proses pengumpulan langsung ini divalidasi oleh Dinas Ketahanan Pangan dan Pertanian untuk memastikan akurasi serta kebenaran klasifikasi penyakitnya. Kedua, data citra didapatkan dari dataset publik melalui platform Kaggle melalui tautan https://www.kaggle.com/datasets/warcoder/mango-leaf-disease-dataset. Dataset tersebut diselaraskan

dengan kelas penyakit pada dataset internal, kemudian disimpan dalam repositori peneliti yang nantinya akan digunakan sebagai *domain adaptation*.

Tahap kedua dilakukan melalui beberapa langkah, di antaranya pra-pemrosesan citra, yaitu penyesuaian ukuran citra dengan mengubah ukuran gambar daun menjadi 224 × 224 piksel sehingga sesuai dengan ukuran *input* yang diperlukan oleh model ResNet50. Proses ini bertujuan untuk memastikan semua gambar memiliki ukuran yang seragam sehingga dapat diproses secara efisien oleh model jaringan saraf tiruan berarsitektur konvolusi (CNN), baik saat model tersebut dilatih maupun diuji. Setelah *resizing*, selanjutnya dilakukan tahapan normalisasi citra hasil *resizing* untuk melakukan pengurangan nilai rata-rata pada setiap saluran warna BGR berdasarkan statistik dari dataset ImageNet. Terakhir, dilakukan augmentasi data untuk menciptakan dan menghasilkan data latihan tambahan yang beragam secara buatan tanpa perlu mengumpulkan data baru dari sumber lain. Tujuan utamanya adalah mencegah *overfitting* (Rahmawati et al., 2026) sehingga model dapat tetap mengenali objek secara akurat meskipun gambar yang diberikan memiliki perbedaan dalam posisi, sudut, atau ukuran di dunia nyata.

Setelah data diproses, tahapan selanjutnya adalah perancangan ResNet dengan tambahan klasifikasi. Dalam penelitian ini, digunakan model yang telah dilatih sebelumnya (*pre-trained model*) menggunakan dataset ImageNet. Hal ini memungkinkan sistem untuk memanfaatkan fitur-fitur dasar yang telah dipelajari selama pelatihan awal, seperti bentuk, tekstur, dan pola citra. Pada tahap pengembangan model, lapisan klasifikasi akhir dari arsitektur ResNet50 disesuaikan agar selaras dengan jumlah kelas penyakit daun mangga yang tercakup dalam penelitian ini. Fungsi aktivasi *Softmax* diterapkan untuk menentukan probabilitas bagi setiap kelas penyakit. Selanjutnya, dilakukan evaluasi kinerja model awal hanya pada dataset primer untuk menetapkan metrik kinerja dasar seperti Akurasi, Presisi, *Recall*, dan *F1-Score* (Helmiyah & Pramestiawan, 2025). Hal ini menunjukkan bagaimana model berkinerja pada data lokal tanpa melalui proses penyesuaian. Model dikompilasi menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,0001, fungsi *loss categorical crossentropy*, serta metrik evaluasi berupa *accuracy*.

Tahapan *domain adaptation* merupakan langkah kunci yang membedakan penelitian ini, yaitu penggunaan metode adaptasi domain untuk menyelaraskan distribusi fitur antara dataset eksternal dan dataset utama. Adaptasi domain diterapkan dengan memasukkan sebagian data eksternal yang dibagi sebelumnya menggunakan metode *stratified split* ke dalam skema pelatihan ulang model untuk menjembatani kesenjangan domain. Hal ini memungkinkan model untuk beradaptasi dari kondisi yang terdapat dalam dataset eksternal ke kondisi yang ada pada dataset lokal. Terakhir, dilakukan penilaian terhadap kinerja model yang sudah disesuaikan dengan domain pada gambar uji yang mencakup berbagai kondisi nyata, seperti perubahan kecerahan, sudut pandang, dan latar belakang, serta menghitung metrik kinerja final.

HASIL DAN PEMBAHASAN

Hasil Pelatihan Dataset Internal

1) Pengumpulan dan Pembersihan Dataset Citra

Langkah pertama dalam penelitian ini adalah mengumpulkan dataset awal yang terdiri dari 1.200 gambar daun mangga. Data tersebut diperoleh melalui data primer yang dikumpulkan langsung di Unit Pelaksana Teknis Daerah (UPTD) Balai Pembenihan dan Pembibitan Hortikultura. Sebelum digunakan dalam pelatihan model, terlebih dahulu dilakukan pemeriksaan duplikat dengan metode *hash* untuk

mengenali gambar yang sama atau sangat mirip.

Tabel 1. Distribusi Dataset yang Telah Dibersihkan

Jenis Penyakit	Jumlah Data
Anthracnose	200
Die Back	200
Gall Midge	200
Powdery Mildew	200
Sooty Mould	178
Daun Sehat	200
Total	1178

(Sumber: UPTD Balai Pembenihan dan Pembibitan Hortikultura, diolah penulis, 2026)

Kelas Sooty Mould memiliki jumlah sampel paling sedikit (178) karena banyak gambar duplikat atau mirip yang dihapus pada kelas tersebut

2) pra-Pemrosesan Data

Tahapan ini diawali dengan melakukan *resizing* untuk penyeragaman ukuran citra menjadi 224 × 224 piksel agar citra dapat diolah untuk pelatihan model. Data citra yang sudah seragam kemudian dinormalisasi untuk menyamakan pola distribusi nilai piksel dari dataset daun mangga dengan distribusi data yang dipakai saat melatih ResNet50 pada ImageNet, sehingga bobot yang sudah dilatih dapat berfungsi dengan sebaik-baiknya.



Gambar 2. Normalisasi Citra Penyakit Daun Mangga
(Sumber: Penulis, 2026)

Augmentasi data diterapkan secara eksklusif pada data pelatihan, sementara dataset validasi dan pengujian dibiarkan tanpa augmentasi untuk memastikan bahwa evaluasi model tetap autentik. Untuk meningkatkan keragaman dalam data pelatihan serta mencegah *overfitting*, augmentasi data dilakukan

dengan menggunakan teknik-teknik augmentasi citra berbasis posisi.

3) Distribusi Dataset

Dalam penelitian ini, dataset gambar daun mangga dibagi menjadi tiga bagian, yaitu 70% untuk data latih (*training data*), 15% untuk data validasi (*validation data*), dan 15% untuk data uji.

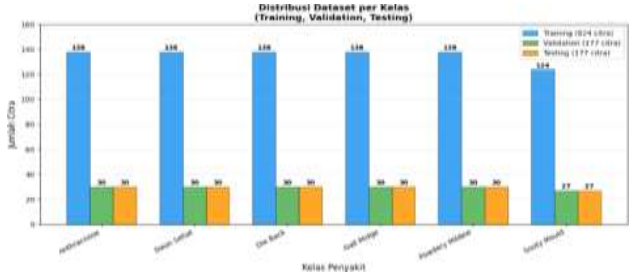

Gambar 3. Pembagian Dataset berdasarkan kelas
(Sumber: Penulis, 2026)

4) Pemodelan Resnet50 dengan Klasifikasi (Initial)

Model yang dikembangkan berdasarkan arsitektur ResNet50 dengan metode *transfer learning* berupa ekstraksi fitur. Lapisan klasifikasi yang ditambahkan di bagian akhir model terdiri dari *GlobalAveragePooling2D* yang dilengkapi dengan lapisan *Dense* 256 menggunakan fungsi aktivasi ReLU dan regulasi L2, *Dropout* 0,5, serta *Dense* 6 dengan *Softmax*.

Tabel 2. Uraian Model ResNet50

Parameter	Nilai
Arsitektur *Base*	ResNet50 (*pre-trained ImageNet*)
Input Shape	224 × 224 × 3
Total Params	24.113.798
Trainable Params	526.086
Nontrainable Params	23.587.712

(Sumber: penulis, 2026)

Perbedaan yang jelas antara parameter yang dilatih dan yang tidak dilatih menunjukkan bahwa hanya sebagian kecil parameter, khususnya lapisan klasifikasi yang ditambahkan, yang dilatih, sementara sebagian besar parameter ResNet50 tetap mempertahankan bobot yang telah dilatih sebelumnya. Proses pelatihan dilakukan selama 25 *epoch* dengan memanfaatkan *callback EarlyStopping* yang memiliki parameter *patience* sebesar 7, serta *ModelCheckpoint* yang memantau nilai *validation loss* terendah.

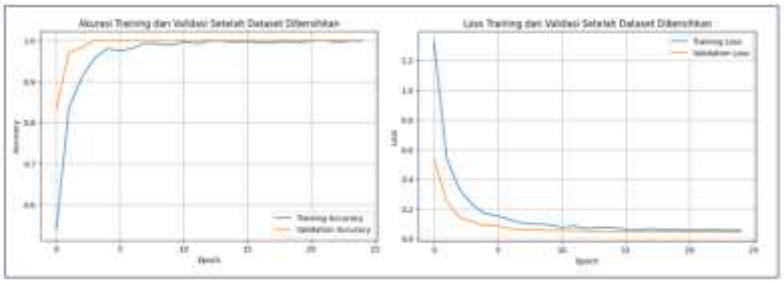

Gambar 4. Grafik Tren Akurasi dan Loss Training Hasil Pelatihan Model

(Sumber: Penulis, 2026)

Akurasi model meningkat secara signifikan, dimulai dari sekitar 54% pada *epoch* pertama, naik hingga hampir 95% pada *epoch* ketiga, dan kemudian tetap stabil di kisaran 98% hingga 100% hingga *epoch* ke-24. Terkait kestabilan model, nilai *loss* selama fase pelatihan menurun secara substansial dari sekitar 1,33 menjadi 0,05 pada *epoch* ke-24, sementara *loss* pada tahap validasi juga mengalami penurunan dari 0,54 menjadi nilai rata-rata 0,05.

5) Initial Evaluation (Dataset Primer)

Evaluasi model dilakukan menggunakan dataset uji yang berisi 177 citra, yang mencakup 15% dari total dataset yang telah dibersihkan. Data uji tersebut tidak digunakan selama proses pelatihan maupun validasi. Evaluasi ini mencakup *confusion matrix* dan *classification report*.

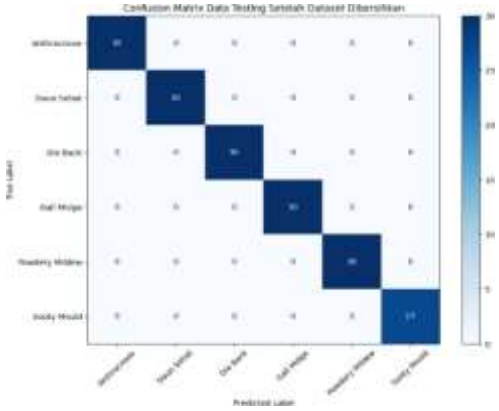

Gambar 5. Confusion Matrix Pengujian Model (Initial)
(Sumber: Penulis, 2026)

Berdasarkan *confusion matrix*, model berhasil memprediksi seluruh 177 data uji secara tepat tanpa kesalahan dalam klasifikasi, di mana semua nilai berada secara sempurna di sepanjang diagonal utama. Setiap kelas, yaitu Anthracnose, Daun Sehat, Die Back, Gall Midge, dan Powdery Mildew, berhasil diprediksi dengan benar sebanyak 30 gambar, sedangkan kelas Sooty Mould berhasil diprediksi dengan benar sebanyak 27 gambar sesuai dengan jumlah data uji yang tersedia.

	precision	recall	f1-score	support	accuracy_per_kelas
Anthracnose	100.0	100.0	100.0	30.0	100.0
Daun Sehat	100.0	100.0	100.0	30.0	100.0
Die Back	100.0	100.0	100.0	30.0	100.0
Gall Midge	100.0	100.0	100.0	30.0	100.0
Powdery Mildew	100.0	100.0	100.0	30.0	100.0
Sooty Mould	100.0	100.0	100.0	27.0	100.0

Gambar 6. Classification Report (Initial)
(Sumber: Penulis, 2026)

Pada *classification report* hasil dataset primer, seluruh kelas berhasil mencapai nilai *precision*, *recall*, *F1-score*, dan akurasi sempurna sebesar 100%. Kelas Anthracnose, Daun Sehat, Die Back, Gall Midge, dan Powdery Mildew masing-masing memiliki *support* 30 citra, sementara kelas Sooty Mould berjumlah 27 citra. Meskipun *support* untuk Sooty Mould lebih sedikit, model tetap mampu memprediksi seluruh citra

pada tiap kelas tanpa kesalahan.

Pembahasan Domain Adaption

1) Domain Adaption

Pada tahap penelitian ini, pertama-tama dilakukan pengujian pada hasil pelatihan sebelum dan sesudah penambahan *domain adaptation* pada model yang telah dibuat. Hal ini dilakukan untuk mengetahui seberapa penting proses *domain adaptation* dalam klasifikasi penyakit daun mangga saat beradaptasi dengan dataset eksternal.

a. Evaluasi Sebelum Domain Adaption

Untuk mengevaluasi kemampuan model dalam melakukan generalisasi terhadap data dari sumber yang berbeda, pengujian dilakukan menggunakan dataset eksternal yang terdiri dari 300 citra (50 citra per kelas). Dataset ini diperoleh dari sumber yang berbeda dengan dataset utama yang digunakan untuk pelatihan. Pengujian tersebut menggunakan model yang sama tanpa pelatihan tambahan apa pun.

CLASSIFICATION REPORT DATASET EKSTERNAL

	precision	recall	f1-score	support
Anthracnose	0.23	0.58	0.33	50
Daun Sehat	0.67	0.96	0.79	50
Die Back	0.83	0.98	0.90	50
Gall Midge	0.36	0.08	0.13	50
Powdery Mildew	0.00	0.00	0.00	50
Sooty Mould	0.11	0.06	0.08	50
accuracy			0.44	300
macro avg	0.37	0.44	0.37	300
weighted avg	0.37	0.44	0.37	300

Gambar 7. Classification Report Dataset Eksternal Sebelum Domain Adaption
(Sumber: Penulis, 2026)

Hasil pengujian menunjukkan penurunan performa yang signifikan. Penurunan ini jauh berbeda dari akurasi pada data uji internal, mengindikasikan adanya *domain gap* yang nyata antara dataset pelatihan dan dataset eksternal, yang kemungkinan disebabkan oleh perbedaan kondisi pencahayaan, sudut pengambilan gambar, latar belakang, atau karakteristik kamera. Temuan ini sejalan dengan laporan bahwa model yang dilatih pada dataset terkontrol umumnya menurun kinerjanya ketika diuji pada citra lapangan (Tunio et al., 2024), dan bahwa variasi pencahayaan merupakan salah satu penyebab utama pergeseran domain pada lingkungan lapangan (Gao et al., 2024).

b. Proses Domain Adaption

Untuk menjembatani kesenjangan domain, dilakukan adaptasi domain dengan mengintegrasikan sebagian data eksternal ke dalam proses pelatihan ulang model. Kumpulan data eksternal yang terdiri dari 300 citra dibagi menggunakan metode pembagian *stratified split*, di mana 180 citra (60%) digunakan sebagai data pelatihan tambahan, 60 citra (20%) sebagai data validasi tambahan, dan 60 citra (20%) disisihkan sebagai set pengujian eksternal akhir. Data latih dan validasi tambahan digabungkan dengan data dari dataset utama, menghasilkan total 1.004 citra untuk pelatihan gabungan dan 237 citra untuk validasi gabungan. Model yang telah dilatih dimuat kembali dengan seluruh lapisan. ResNet50 tetap dibekukan, kemudian dilakukan pelatihan ulang (*re-training*) terhadap lapisan klasifikasi menggunakan data gabungan selama 20 *epoch* dengan *class weight* untuk menyeimbangkan kontribusi tiap kelas.

.

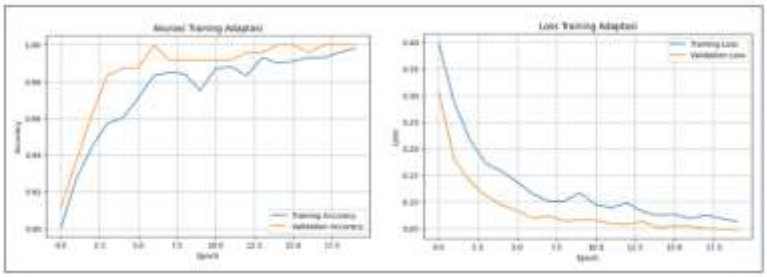

Gambar 8. Grafik Tren Akurasi dan Loss Training Domain Adaption
(Sumber: Penulis, 2026)

Hasil ini perlu dibaca secara hati-hati bila dibandingkan dengan studi sebelumnya. Tunio et al. (2024) melaporkan akurasi 70,0% pada dataset lapangan PlantDoc menggunakan adaptasi domain tanpa pengawasan, sedangkan Gao et al. (2024) melaporkan akurasi rata-rata 92,11% hingga 93,02% dengan adaptasi multi-sumber untuk penyakit kentang. Berbeda dengan kedua studi tersebut, adaptasi pada penelitian ini memanfaatkan sebagian data eksternal berlabel dalam pelatihan ulang, dan citra ujinya berasal dari sumber yang sama. Karena itu, akurasi 100% pada penelitian ini tidak dapat dibandingkan secara langsung dan lebih tepat dipahami sebagai keberhasilan penyesuaian terhadap distribusi data eksternal tertentu.

2) Evaluasi Eksternal Setelah Domain Adaption

Model hasil adaptasi domain diuji dengan menggunakan 60 citra (15%) uji akhir eksternal sesuai pembagian *stratified split* yang tidak pernah diterapkan dalam proses pelatihan ataupun validasi adaptasi. Hasilnya menunjukkan adanya kenaikan akurasi sebelum dan setelah dilakukan *domain adaptation*. Meskipun 60 citra uji akhir ini tidak digunakan langsung dalam proses pelatihan, gambar-gambar tersebut berasal dari sumber dan distribusi yang serupa dengan 240 gambar eksternal lainnya yang telah dimanfaatkan untuk melatih model. Pencapaian akurasi pada tahap ini lebih menyoroti keberhasilan dalam *domain adaptation* dengan distribusi data eksternal yang spesifik, bukan generalisasi terhadap sumber data yang sepenuhnya baru.

Tabel 3. Ringkasan Sebelum dan Sesudah Domian Adaption

Skema Evaluasi	Jumlah Data	*Accuracy*	*Precision*	*Recall*	*F1-Score*
Internal (Data Uji)	177 citra	100,00%	100,00%	100,00%	100,00%
Eksternal Sebelum Adaptasi	300 citra	44,33%	36,60%	44,33%	37,03%
Eksternal Setelah Adaptasi	60 citra	100,00%	100,00%	100,00%	100,00%

(Sumber: penulis, 2026)

KESIMPULAN

Penerapan *domain adaptation* berbasis *transfer learning* menggunakan arsitektur ResNet50 berhasil meningkatkan kemampuan model untuk bergeneralisasi ke domain baru, terlihat dari peningkatan akurasi uji pada data eksternal dari 44,33% menjadi 100%. Pendekatan ini berhasil mempertahankan kestabilan prediksi dan tingkat akurasi yang tinggi pada dataset tanpa mengalami *overfitting*. Namun, meskipun akurasi mencapai tingkat sempurna, hasil tersebut tidak menunjukkan kemampuan generalisasi yang penuh, melainkan hanya terbatas pada karakteristik dari dataset evaluasi yang digunakan, bukan generalisasi

terhadap sumber data yang sepenuhnya baru. Secara keseluruhan, pendekatan *domain adaptation* tidak hanya mempercepat proses konvergensi dan menghemat penggunaan sumber daya komputasi, tetapi juga membantu menjaga stabilitas kemampuan generalisasi model, sehingga akhirnya mencapai tingkat akurasi validasi yang baik.

KONTRIBUSI PENULIS

Riyan Farismana (Penulis 1): Bertugas merancang konsep penelitian, mengumpulkan dataset, mengembangkan model CNN ResNet50 dengan metode *transfer learning*, melaksanakan skenario *domain adaptation* menggunakan dataset internal dan eksternal, serta menulis naskah utama penelitian.
Naila Fathirani Zain (Penulis 2): Bertugas dalam pengumpulan data lapangan/citra, pengumpulan dan pengujian data daun mangga, prosedur pembersihan dataset, desain augmentasi, serta mengembangkan model CNN ResNet50 dengan metode *transfer learning*.
A. Lubis Ghozali (Penulis 3): Bertugas mengolah matriks evaluasi untuk pelatihan dan validasi serta menganalisis perbandingan kinerja sebelum dan setelah adaptasi domain.
Sahid Triambudhi (Penulis 4): Bertugas memastikan eksperimen tetap valid, meninjau kembali naskah ilmiah, serta menjamin kualitas penelitian.

KONFLIK KEPENTINGAN

Para penulis menyatakan bahwa tidak terdapat konflik kepentingan, baik secara finansial maupun nonfinansial, yang dapat memengaruhi pelaksanaan penelitian, analisis data, penyusunan, maupun publikasi artikel ini.

PERNYATAAN PENGGUNAAN KECERDASAN ARTIFISIAL (AI)

Dalam penyusunan artikel ini, penulis menggunakan teknologi kecerdasan artifisial (AI) hanya sebagai alat bantu dalam proses penyuntingan bahasa, pemeriksaan tata bahasa, dan penyempurnaan struktur penulisan. AI tidak digunakan untuk menghasilkan, memanipulasi, atau menganalisis data penelitian. Seluruh isi artikel, interpretasi hasil, serta tanggung jawab atas keakuratan dan integritas naskah tetap berada pada penulis.

UCAPAN TERIMAKASIH

Ucapan Terimakasih ditujukan kepada Politeknik Negeri Indramayu atas dukungan dan fasilitas yang diberikan dalam penelitian ini.

DAFTAR PUSTAKA

Adzkia, S. A., & Arifin, T. (2025). Perbandingan arsitektur CNN berbasis transfer learning untuk klasifikasi pada BreastMNIST. *Jurnal Nasional Teknologi dan Sistem Informasi, 11*(2), 192–200. https://doi.org/10.25077/teknosi.v11i2.2025.192-200

Al-Fahrezi, M. A. (2025). Pengaruh augmentasi data terhadap akurasi pelatihan model CNN untuk klasifikasi jenis ikan. *JITSI: Jurnal Ilmiah Teknologi Sistem Informasi, 6*(2), 177–185. https://doi.org/10.62527/jitsi.6.2.471

Ariningsih, E., Ashari, N., Saliem, H. P., Maulana, M., & Septanti, K. S. (2021). Kinerja agribisnis mangga gedong gincu dan potensinya sebagai produk ekspor pertanian unggulan. *Forum Penelitian Agro Ekonomi, 39*(1), 49–71. https://doi.org/10.21082/fae.v39n1.2021.49-71

Dwi Baginda, A., Fajriani, A., & Shalihah, R. (2026). Deteksi penyakit daun mangga menggunakan threshold dengan metode CNN arsitektur ResNet50. *Sistemasi: Jurnal Sistem Informasi, 15*(2), 745–757. https://doi.org/10.32520/stmsi.v15i2.6123

Emmanuel, R. D., & Santoso, K. I. (2026). Analisis komparatif arsitektur CNN untuk klasifikasi kelayakan buah mangga: ResNet50 dan MobileNetV2. *Go Infotech: Jurnal Ilmiah STMIK AUB, 32*(1), 23–34. https://doi.org/10.36309/goi.v32i1.446

Fajar Ramadhan, M. M. R., Hastin, M. R., & Supriatna, A. (2024). Identifikasi karakter morfologi mangga (*Mangifera indica* L.) di Kecamatan Panyileukan, Jawa Barat, Indonesia. *Botani: Publikasi Ilmu Tanaman dan Agribisnis, 1*(3), 27–37. https://doi.org/10.62951/botani.v1i3.79

Ganin, Y., Ustinova, E., Ajakan, H., Germain, P., Larochelle, H., Laviolette, F., March, M., & Lempitsky, V. (2016). Domain-adversarial training of neural networks. *Journal of Machine Learning Research, 17*(59), 1–35.

Gao, X., Feng, Q., Wang, S., Zhang, J., & Yang, S. (2024). A multi-source domain feature adaptation network for potato disease recognition in field environment. *Frontiers in Plant Science, 15*, Article 1471085. https://doi.org/10.3389/fpls.2024.1471085

Hakim, S. A., Ubaidillah, M., Ramadhan, A. R., Zulvia, R., Hawari, A., Rizky, A. B., Lutfi, R., Tsania, P., Hermanto, M., & Yudistira, N. (2024). Klasifikasi citra generasi artificial intelligence menggunakan metode fine tuning pada residual network [AI generated image classification using fine tuning on residual network]. *Jurnal Teknologi Informasi dan Ilmu Komputer, 11*(3), 655–666. https://doi.org/10.25126/jtiik.938118

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770–778).

Helmiyah, S., & Pramestiawan, R. (2025). Analisis komparatif algoritma machine learning dengan metrik akurasi, presisi, recall, dan F1-Score pada dataset kacang kering. *Jurnal Ilmu Komputer dan Teknologi, 6*(3), 152–159. https://doi.org/10.35960/ikomti.v6i3.2031

Isnansyah, G., Ngii, K. A., & Adi Saputra, R. (2024). Klasifikasi citra daun mangga menggunakan algoritma Support Vector Machine. *Kopertip: Jurnal Ilmiah Manajemen Informatika dan Komputer, 7*(3), 80–83. https://doi.org/10.32485/kopertip.v7i3.346

Muzhaffar, R., & Suharjo, I. (2025). Penerapan CNN berbasis arsitektur ResNet-50 untuk klasifikasi citra beras organik dan anorganik. *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, dan Arsitektur Komputer), 5*(2), 351–358. https://doi.org/10.55382/jurnalpustakadata.v5i2.1117

Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering, 22*(10), 1345–1359. https://doi.org/10.1109/TKDE.2009.191

Prabhu, O., T, M., & Shetty, S. (2025). An investigation on advances in transfer learning and explainable AI for mango leaf disease detection. *Smart Agricultural Technology, 12*, Article 101348. https://doi.org/10.1016/j.atech.2025.101348

Rahmawati, R., Arifin, N., & Firgiawan, W. (2026). Perbandingan SVM dan CNN MobileNetV2 untuk klasifikasi residu insektisida pada citra buah kakao. *Jambura Journal of Informatics, 8*(1), 77–91. https://doi.org/10.37905/jji.v8i1.37972

Rizal, M., Saputra, V. J., Maulana, D. I., Budiman, F., & Sugiarto, E. (2025). Deteksi awal penyakit tanaman berbasis citra daun: Studi perbandingan algoritme SVM dan CNN. *IRCS: Integrative Research in Computer Science, 1*(1), 61–76.

Romaulti Siagian, T., Taufik, I., Indra, Z., & Wiliam Iskandar, J. (2025). Klasifikasi penyakit dan hama pada daun mangga menggunakan metode Convolutional Neural Network. *Jurnal Mahasiswa Teknik Informatika, 9*(6), 10370–10376. https://doi.org/10.36040/jati.v9i6.16477

Satia, G. A. W., Firmansyah, E., & Umami, A. (2022). Perancangan sistem identifikasi penyakit pada daun kelapa sawit (*Elaeis guineensis* Jacq.) dengan algoritma deep learning convolutional neural networks. *Jurnal Ilmiah Pertanian, 19*(1), 1–10. https://doi.org/10.31849/jip.v19i1.9556

Tunio, M. H., Li, J. P., Zeng, X., Ahmed, A., Shah, S. A., Shaikh, H.-U., Mallah, G. A., & Yahya, I. A. (2024). Advancing plant disease classification: A robust and generalized approach with transformer-fused convolution and Wasserstein domain adaptation. *Computers and Electronics in Agriculture, 227*, Article 109574. https://doi.org/10.1016/j.compag.2024.109574

Wirabowo, I., & Susilawati, I. (2025). Implementasi Convolution Neural Network (CNN) untuk deteksi penyakit pada daun jagung berbasis citra digital. *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, dan Arsitektur Komputer), 5*(1), 233–241. https://doi.org/10.55382/jurnalpustakadata.v5i1.1046