

IMPLEMENTASI TRANSFER LEARNING RESNET-50 DALAM KLASIFIKASI PENYAKIT DAUN TOMAT BERBASIS CNN

Christin S. Dengen*¹⁾, Alva H. Muhammad²⁾

1. Magister Informatika, Universitas Amikom Yogyakarta, Indonesia
2. Magister Informatika, Universitas Amikom Yogyakarta, Indonesia

Article Info

Kata Kunci: Resnet-50; Transfer Learning; Klasifikasi Gambar; Penyakit Daun Tomat

Keywords: Resnet-50; Transfer Learning; Image Classification; Tomato Leaf Disease

Article history:

Received 29 December 2024

Revised 4 January 2025

Accepted 9 January 2025

Available online 1 December 2025

DOI :

<https://doi.org/10.29100/jipi.v10i4.7191>

* Christin Soyan Dengen.

E-mail address:

csoyandengen@students.amikom.ac.id

ABSTRAK

Tomat merupakan produk pertanian penting di banyak negara, termasuk Indonesia. Namun, penyakit daun tomat dapat berdampak signifikan pada hasil panen dan kualitas tanaman. Oleh karena itu, deteksi dini penyakit sangat penting untuk meningkatkan hasil panen. Dalam penelitian ini, kami menerapkan *transfer learning* menggunakan arsitektur ResNet-50 untuk klasifikasi penyakit daun tomat berbasis *Convolutional Neural Network* (CNN). Dataset pelatihan yang digunakan berisi 2902 gambar daun tomat yang mencakup 10 kategori termasuk daun sehat dan sembilan jenis penyakit. Proses penelitian meliputi akuisisi data, preprocessing citra dengan augmentasi untuk meningkatkan keragaman dataset, dan pengembangan model menggunakan ResNet-50 untuk ekstraksi fitur. Hasil evaluasi model menunjukkan akurasi keseluruhan sebesar 99%, dengan rata-rata presisi dan perolehan lebih besar dari 0,97 untuk sebagian besar kategori penyakit. Kategori *Two-Spotted Spider Mite* menunjukkan performa terbaik dengan nilai presisi, recall, dan skor F1 sebesar 1,00. Meskipun terdapat sedikit kesalahan klasifikasi pada beberapa kategori seperti *Tomato Yellow Leaf Curl Virus*, model tersebut tetap menunjukkan kinerja yang baik dalam mendeteksi keriting daun tomat. Penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan sistem deteksi penyakit tanaman berbasis teknologi pengolahan citra yang lebih efisien dan akurat.

ABSTRACT

Tomatoes are a significant agricultural product in numerous countries, including Indonesia. However, tomato leaf diseases can substantially impact crop yields and plant quality. Therefore, early disease detection is essential for improving harvest outcomes. In this study, we employed transfer learning utilizing the ResNet-50 architecture to classify tomato leaf diseases based on Convolutional Neural Networks (CNN). The dataset comprised 2,902 images of tomato leaves, encompassing 10 categories, including healthy leaves and nine disease types. The research methodology involved data acquisition, image preprocessing with augmentation to enhance dataset diversity, and model development using ResNet-50 for feature extraction. Model evaluation results demonstrated an overall accuracy of 99%, with average precision and recall exceeding 0.97 for most disease categories. The Two-Spotted Spider Mite category performed best, achieving precision, recall, and F1 scores of 1.00. Although there were minor classification errors in some categories, such as Tomato Yellow Leaf Curl Virus, the model still showed robust performance in detecting tomato leaf curls. This study is expected to contribute to advancing plant disease detection systems based on more efficient and accurate image processing technologies.

I. PENDAHULUAN

Di banyak negara, termasuk Indonesia, tomat merupakan produk pertanian yang penting dan tanaman yang dibudidayakan secara luas [1]. Tomat memiliki nilai ekonomi yang tinggi karena digunakan sebagai bahan makanan dan industri pangan, serta didukung oleh hasil panen yang tinggi, perpanjangan musim, dan

peningkatan produktivitas melalui teknik produksi seperti terowongan dan pencangkakan [2]. Namun, berbagai jenis penyakit mempengaruhi produksi tomat [3]. Penyakit pada daun tomat, seperti bercak bakteri, bercak target, dan keriting daun kuning tomat dapat menyebabkan penurunan hasil panen yang signifikan, bahkan dapat menyebabkan kegagalan total apabila tidak ditangani dengan baik [4].

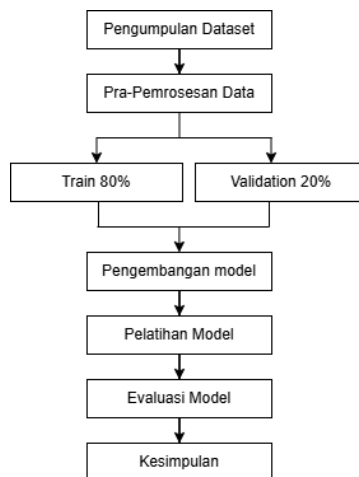
Dalam beberapa tahun terakhir, perkembangan teknologi pengolahan citra telah menunjukkan potensi besar dalam mendukung deteksi dan diagnosis penyakit tanaman. Teknologi ini memberikan solusi praktis bagi petani, terutama dalam bidang AI dan IoT, sehingga para petani dapat memantau kesehatan tanaman dan mengelola penyakit daun tomat menggunakan perangkat yang mudah diakses [5]. Hal ini dapat meningkatkan efisiensi dalam pengambilan keputusan dan mengurangi kerugian akibat keterlambatan penanganan penyakit [6]. Salah satu metode yang paling menonjol adalah Convolutional Neural Network (CNN) yang menawarkan alat yang tangguh dengan hasil yang sangat akurat untuk deteksi penyakit tanaman [7]. CNN mampu secara otomatis mengekstraksi pola dan struktur penting dari data visual, yang sangat berguna dalam pelacakan visual dan klasifikasi gambar [8], [9]. Dibandingkan dengan metode konvensional seperti inspeksi manual atau pendekatan berbasis SVM dan KNN, pendekatan berbasis CNN menawarkan keunggulan signifikan dalam akurasi, efisiensi, dan fleksibilitas. Inspeksi manual sangat bergantung pada tenaga ahli dan memakan waktu, sementara metode berbasis SVM atau k-NN memerlukan preprocessing fitur yang kompleks dan kurang efektif dalam menangani variasi kondisi seperti pencahayaan [10], [11]. Sebaliknya, CNN mampu secara otomatis mengekstraksi fitur penting dan menangkap pola spasial kompleks, memungkinkan akurasi yang lebih tinggi dan generalisasi lebih baik pada dataset beragam [12]. Namun, CNN memerlukan dataset yang besar dan beragam untuk mencapai performa yang baik [13], serta ekstraksi fitur menggunakan model CNN yang sangat dalam memerlukan perangkat keras berkinerja tinggi karena kompleksitas komputasinya yang besar, yang dapat membatasi penggunaannya dalam aplikasi waktu nyata [14]. Untuk mengatasi hal ini, penggunaan teknik transfer learning dan optimalisasi arsitektur CNN telah terbukti dapat meningkatkan akurasi model deteksi penyakit tanaman berbasis citra [15], [16].

Transfer learning adalah pendekatan yang efektif untuk klasifikasi penyakit tanaman, memungkinkan penggunaan model yang telah dilatih sebelumnya untuk meningkatkan akurasi dan efisiensi [17]. Ini sangat berguna dalam situasi di mana data pelatihan terbatas, dan dapat mengurangi waktu serta sumber daya yang dibutuhkan untuk melatih model dari awal. Salah satu model pralatih yang banyak digunakan adalah ResNet-50, yang memiliki keunggulan dalam menangani permasalahan pelatihan jaringan yang sangat dalam melalui mekanisme residual learning [18]. Arsitektur ini memungkinkan model untuk mempertahankan akurasi yang tinggi meskipun terdiri dari banyak lapisan jaringan [19].

Penelitian ini bertujuan untuk mengimplementasikan transfer learning dengan menggunakan arsitektur ResNet-50 dalam klasifikasi penyakit daun tomat. Metode ini diharapkan dapat menjadi langkah inovatif yang mendukung pengembangan teknologi pertanian berbasis kecerdasan buatan, yang tidak hanya meningkatkan produktivitas tetapi juga memastikan keberlanjutan industri pertanian. Metode ini juga diharapkan dapat meningkatkan akurasi klasifikasi dengan memanfaatkan kemampuan generalisasi dari model pralatih. Selain itu, penelitian ini juga mengevaluasi performa model menggunakan berbagai metrik evaluasi seperti akurasi, presisi, recall, dan F1-score, guna memberikan penilaian yang komprehensif terhadap kinerja model. Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam pengembangan sistem deteksi penyakit tanaman berbasis teknologi pengolahan citra yang lebih akurat dan efisien. Hasil penelitian ini diharapkan menjadi landasan bagi inovasi teknologi pertanian cerdas yang mendukung keberlanjutan produksi pangan secara global.

II. METODE PENELITIAN


Gambar tersebut menjelaskan alur pengembangan model pembelajaran mesin, dimulai dari pengumpulan dataset dan pra-pemrosesan data untuk memastikan kualitas data. Dataset kemudian dibagi menjadi data pelatihan (80%) dan validasi (20%) untuk melatih dan menguji model. Model dikembangkan dan dilatih menggunakan data pelatihan, kemudian dievaluasi dengan data validasi untuk mengukur performa dan mencegah overfitting. Hasil evaluasi menentukan apakah model sudah optimal atau membutuhkan perbaikan. Langkah terakhir adalah kesimpulan, yang merangkum performa model dan langkah selanjutnya. Pada sub-bab berikut akan menjabarkan uraian yang lebih jelas dari setiap tahapan alur penelitian.



Gambar 1. Metode Penelitian

A. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini berasal dari sumber publikasi ilmiah yaitu Huang, Mei-Ling dan Chang, Ya-Han (2020) dengan judul “*Tomato Leaf Dataset*” dan Mendeley Data Available from (V1, DOI:10.17632/ngdgg79rzb). Dataset ini khusus dikembangkan untuk keperluan penelitian klasifikasi penyakit daun tomat. Data tersebut diklasifikasikan ke dalam 10 kelas: bercak bakteri, penyakit busuk daun awal, sehat, penyakit busuk daun, jamur daun, bercak daun septoria, bercak sasaran, virus mosaik tomat, virus keriting daun kuning tomat, dan tungau laba-laba berbintik dua. Gambar 2 berisi gambar daun beserta penyakitnya. Setiap gambar diberi label berdasarkan jenis penyakit atau kondisi kesehatan, sehingga sangat cocok untuk melatih model klasifikasi berbasis pembelajaran mesin. Saat kumpulan data diunduh, proses verifikasi kualitas data dilakukan untuk memastikan bahwa hanya gambar dengan resolusi yang sesuai yang disimpan. Organisasi data dilakukan dalam direktori terstruktur yang memisahkan gambar ke dalam kelas. Analisis distribusi jumlah gambar per kelas juga dilakukan untuk memastikan keseimbangan data, yang penting untuk performa model klasifikasi yang optimal.



Gambar 2. Kategori Penyakit Daun Tomat

B. Pra-Pemrosesan Data

Pra-pemrosesan data merupakan tahap penting dalam penelitian ini untuk memastikan kualitas dataset yang optimal sebelum digunakan dalam pelatihan model klasifikasi. Langkah pertama dalam pra-pemrosesan adalah augmentasi data, yang bertujuan untuk meningkatkan variasi dataset sehingga model mampu menangkap pola-pola yang lebih beragam dan mengurangi risiko *overfitting*. Teknik augmentasi yang diterapkan meliputi rotasi gambar hingga sudut maksimum 15 derajat, perbesaran hingga 15% dari ukuran asli, serta perpindahan gambar secara horizontal dan vertikal hingga 15%. Selain itu, perubahan kecerahan dilakukan dengan kisaran 0.5 hingga 1.2 untuk mensimulasikan berbagai kondisi pencahayaan, dan flipping horizontal diterapkan untuk menangkap simetri alami daun tomat.

Langkah berikutnya adalah standarisasi gambar menggunakan fungsi `preprocess_input` dari model *ResNet50*. Fungsi ini mengubah nilai piksel gambar ke rentang $[-1, 1]$, sesuai dengan skala dan format yang diharapkan oleh model pretrained. Proses ini bertujuan untuk menyelaraskan distribusi data dan mengurangi ketidaksesuaian nilai piksel yang dapat memengaruhi performa model.

Dataset kemudian dibagi menjadi dua subset utama: data pelatihan yang mencakup 80% dari total data dan data validasi sebesar 20%. Pembagian ini dilakukan dengan memanfaatkan parameter `validation_split` pada

objek ImageDataGenerator. Data pelatihan digunakan untuk membangun model, sementara data validasi digunakan untuk mengevaluasi performa model selama proses pelatihan. Sebagai langkah tambahan, eksplorasi visual dataset dilakukan dengan menampilkan sampel gambar dari setiap kelas penyakit untuk memastikan keberagaman data, termasuk setelah augmentasi. Tahapan-tahapan ini memastikan bahwa dataset yang digunakan memiliki kualitas tinggi untuk mendukung pelatihan model secara optimal.

C. Pengembangan Model

Pengembangan model dalam penelitian ini dilakukan dengan menggunakan pendekatan pembelajaran transfer menggunakan arsitektur ResNet50, jaringan saraf konvolusional yang telah dilatih sebelumnya pada kumpulan data ImageNet yang besar. ResNet50 dipilih karena kemampuan representasi fiturnya yang sangat baik untuk berbagai jenis gambar, termasuk gambar penyakit daun. Proses pengembangan model dimulai dengan menggunakan model ResNet50 terlatih yang diimpor dengan bobot yang dilatih pada kumpulan data ImageNet, tetapi bagian atas model (lapisan klasifikasi ImageNet yang terhubung sepenuhnya) tidak disertakan. Perlunya klasifikasi penyakit daun tomat. Model dasar ini hanya digunakan untuk mengekstrak fitur dari gambar masukan berukuran 224x224 piksel. Selanjutnya, lapisan klasifikasi baru ditambahkan. Ini termasuk lapisan perataan yang meratakan keluaran dari lapisan konvolusional terakhir, lapisan padat dengan 128 neuron yang menggunakan fungsi aktivasi ReLU, dan lapisan lunak yang menghitung jumlah kelas dalam kumpulan data (10 kelas) dan Hasilkan probabilitas kelas menggunakan fungsi aktivasi maksimal.

Selama tahap pelatihan awal, semua lapisan model dasar ResNet50 dibekukan sehingga bobot yang telah dilatih sebelumnya tidak berubah, sehingga pelatihan dilakukan hanya pada lapisan tambahan yang baru ditambahkan. Model disusun menggunakan fungsi kerugian entropi silang kategoris dan optimasi Adam dengan kecepatan pembelajaran awal $1e-4$. Pelatihan dilakukan menggunakan augmentasi data dengan generator data (ImageDataGenerator) untuk meningkatkan keragaman data pelatihan. Setelah pelatihan awal selesai, fase penyesuaian dilakukan yang membongkar semua lapisan model dasar ResNet50 dan memungkinkan pembaruan bobot seluruh model. Pada fase ini, kecepatan pembelajaran dikurangi menjadi $1e-5$ untuk menghindari pembaruan besar yang dapat merusak bobot yang telah dilatih sebelumnya. Strategi penyempurnaan ini memudahkan model untuk beradaptasi dengan fitur-fitur kumpulan data penyakit daun tomat sekaligus memanfaatkan representasi fitur kuat yang dipelajari dari ImageNet. Proses optimasi dan evaluasi dilakukan dengan pelatihan ulang dengan pendekatan penyesuaian selama beberapa periode, menggunakan callback seperti EarlyStopping untuk mencegah overfitting. Evaluasi model dilakukan pada set validasi menggunakan metrik akurasi dan laporan klasifikasi sebagai tolok ukur kinerja. Pendekatan pembelajaran transfer ini memungkinkan model untuk memanfaatkan pengetahuan yang diperoleh dari kumpulan data yang besar dan diadaptasi secara optimal untuk klasifikasi penyakit daun tomat, sehingga sangat efisien bahkan dengan kumpulan data pelatihan yang terbatas.

D. Pelatihan Model

Pelatihan model dilakukan dalam dua tahap. Pada tahap pertama, lapisan ResNet50 dibekukan, sehingga hanya lapisan kustom yang dilatih selama 100 *epoch*. Optimizer Adam digunakan dengan fungsi kehilangan *categorical_crossentropy*. Selain itu, mekanisme *early stopping* diterapkan dengan *patience* lima *epoch* untuk mencegah *overfitting*. Pada tahap kedua, seluruh lapisan ResNet50 dibuka untuk melatih jaringan secara menyeluruh (*fine-tuning*). Selama tahap ini, laju pembelajaran diturunkan menjadi 1×10^{-5} untuk memastikan perubahan bobot dilakukan secara bertahap tanpa mengganggu bobot yang telah terlatih.

E. Evaluasi Model

Evaluasi model dilakukan dengan menggunakan data validasi yang telah dipisahkan sebelumnya. Kinerja model diukur berdasarkan metrik akurasi, precision, recall, dan F1-score. Precision (P) mengukur proporsi prediksi benar terhadap semua prediksi positif, sementara recall (R) mengukur kemampuan model untuk mendeteksi semua sampel positif. Formula untuk precision, recall, dan F1-score adalah:

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

$$F1 = \frac{2 \times \text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (3)$$

Dimana TP adalah *True Positives*, FP adalah *False Positives*, dan FN adalah *False Negatives*. Matriks kebingungan divisualisasikan untuk memberikan gambaran detail performa model dalam mengklasifikasi setiap kategori penyakit. Grafik akurasi dan loss juga dihasilkan untuk memvisualisasikan dinamika performa model selama pelatihan. Akurasi (A) dihitung sebagai:

$$A = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

Proses evaluasi memberikan hasil numerik yang rinci, memungkinkan analisis yang lebih mendalam terhadap kekuatan dan kelemahan klasifikasi yang dilakukan.

F. Kesimpulan

Penelitian ini bertujuan untuk mengembangkan model deteksi penyakit daun tomat dengan memanfaatkan pendekatan transfer learning menggunakan arsitektur ResNet50. Hasil evaluasi model menunjukkan performa yang sangat baik, yang diukur menggunakan precision, recall, f1-score, dan akurasi keseluruhan. Selain itu, analisis dilakukan menggunakan *conclusion matrix* dan visualisasi kehilangan (*loss*) selama pelatihan untuk memastikan kualitas model yang dibangun.

III. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mengembangkan model deteksi penyakit daun tomat dengan memanfaatkan pendekatan transfer learning menggunakan arsitektur ResNet50. Hasil evaluasi model menunjukkan performa yang sangat baik, yang diukur menggunakan precision, recall, f1-score, dan akurasi keseluruhan. Selain itu, analisis dilakukan menggunakan *conclusion matrix* dan visualisasi kehilangan (*loss*) selama pelatihan untuk memastikan kualitas model yang dibangun.

A. Evaluasi Kinerja Model

Hasil evaluasi model menunjukkan bahwa model mencapai akurasi keseluruhan sebesar **99%** pada dataset uji. Precision, recall, dan f1-score rata-rata makro masing-masing sebesar 0.98, sedangkan rata-rata berbobot mencapai 0.99. Secara rinci, hasil evaluasi kinerja untuk masing-masing kategori ditampilkan pada Tabel 1.

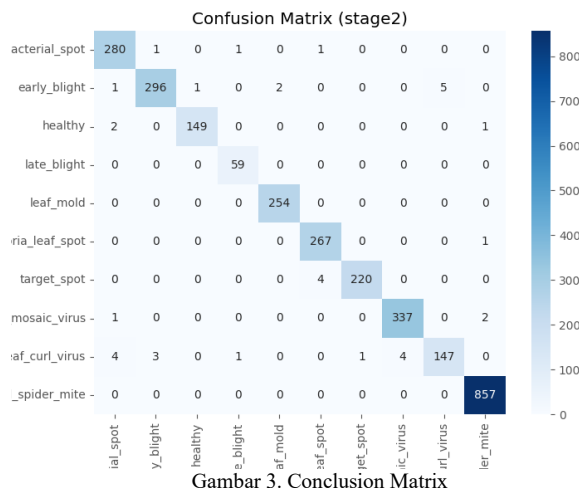
TABEL I.
EVALUASI KINERJA MODEL

Penyakit	Presisi	Recall	F1-Score	Support
Bacterial_Spot	0.97	0.99	0.98	238
Early_Blight	0.99	0.97	0.98	305
Healthy	0.99	0.98	0.99	152
Late_Blight	0.97	1.00	0.98	59
Leaf_Mold	0.99	1.00	1.00	254
Septoria_Leaf_Spot	0.98	1.00	0.99	268
Target_Spot	1.00	0.98	0.99	244
Tomato_Mosaic_Virus	0.99	0.99	0.99	340
Tomato_Yellow_Leaf_Curl_Virus	0.97	0.92	0.94	160
Two Spotted Spider Mite	1.00	1.00	1.00	879
Accuracy			0.99	2902
Macro avg	0.98	0.98	0.98	2902
Weighted avg	0.99	0.99	0.99	2902

Performa terbaik dicapai pada kelas *Two-Spotted Spider Mite*, dengan precision, recall, dan f1-score mencapai **1.00**. Hal ini menunjukkan bahwa model dapat mengenali fitur-fitur gejala yang sangat khas dari penyakit ini. Sebaliknya, performa terendah terjadi pada kelas *Tomato Yellow Leaf Curl Virus* dengan f1-score sebesar **0.94**. Kesalahan ini kemungkinan besar disebabkan oleh kemiripan fitur visual dengan kelas penyakit lain seperti *Bacterial Spot* dan *Early Blight*. Langkah konkret yang dapat diambil untuk meningkatkan akurasi pada kategori ini mencakup augmentasi data tambahan, seperti pencahayaan yang bervariasi, perubahan warna daun, atau rotasi citra. Selain itu, modifikasi arsitektur model untuk menekankan perbedaan kecil antara kelas yang serupa juga perlu dipertimbangkan dalam penelitian mendatang.

B. Analisis Conclusion Matrix

Untuk mengevaluasi distribusi prediksi, *Conclusion Matrix* digunakan sebagai alat analisis tambahan. matriks ini divisualisasikan pada Gambar 3.

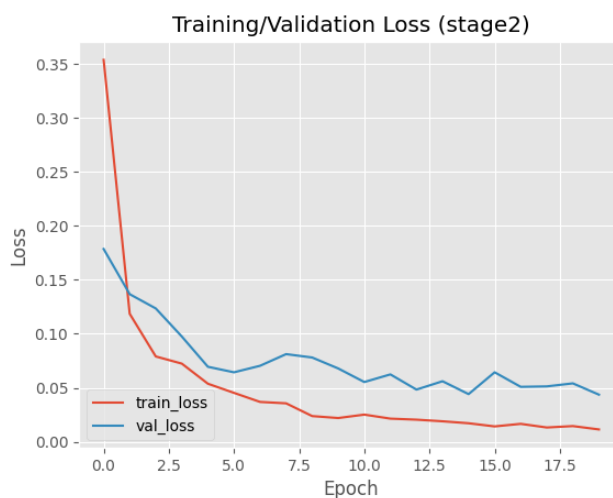


Gambar 3. Conclusion Matrix

Berdasarkan *conclusion matrix*, sebagian besar prediksi model benar, yang terlihat dari dominasi nilai pada diagonal utama matriks. Hal ini menunjukkan bahwa model mampu memetakan fitur dari dataset dengan akurasi tinggi untuk sebagian besar kategori penyakit. Namun, terdapat beberapa kesalahan klasifikasi yang signifikan, terutama pada kategori *Tomato Yellow Leaf Curl Virus*, di mana 4 sampel diklasifikasikan sebagai *Bacterial Spot* dan 4 sampel lainnya sebagai *Early Blight*. Kesalahan klasifikasi ini kemungkinan besar disebabkan oleh tumpang tindih gejala visual yang menyerupai penyakit lain, seperti perubahan warna dan bercak pada daun. Untuk mengatasi masalah ini, pengayaan dataset menggunakan teknik augmentasi berbasis domain dan koleksi data lapangan tambahan perlu dilakukan. Hal ini dapat membantu meningkatkan kemampuan model dalam mengenali pola unik dari kategori ini.

C. Proses Pelatihan Model

Proses implementasi arsitektur ResNet50 dilakukan dengan memanfaatkan framework TensorFlow dan Keras. Model awal ResNet50 yang telah dilatih pada dataset ImageNet dimuat ulang dan lapisan atasnya diadaptasi untuk klasifikasi 10 kategori penyakit daun tomat. Proses ini melibatkan penggantian lapisan dense terakhir dengan lapisan baru yang sesuai dengan jumlah kelas, serta penggunaan fungsi aktivasi softmax. Seluruh model dilatih menggunakan optimasi Adam dengan learning rate awal 0.001, yang kemudian disesuaikan secara dinamis selama pelatihan. Proses pelatihan model dievaluasi menggunakan grafik kehilangan (loss) selama pelatihan, yang ditampilkan pada Gambar 4.



Gambar 4. Garfik Loss

Grafik menunjukkan bahwa nilai kehilangan untuk data pelatihan dan validasi menurun secara signifikan selama 10 epoch pertama. Penurunan yang cepat pada fase awal ini menunjukkan bahwa model dengan cepat belajar pola dasar dari dataset. Setelah epoch ke-10, nilai kehilangan mulai stabil, menandakan bahwa model telah

mencapai konvergensi. Nilai kehilangan pelatihan mendekati **0.1** pada akhir proses pelatihan, sedangkan nilai kehilangan validasi tetap rendah, menunjukkan bahwa model tidak mengalami overfitting. Secara keseluruhan, proses pelatihan menunjukkan bahwa arsitektur ResNet50 yang digunakan mampu menangkap pola dengan efisien dan menjaga keseimbangan antara data pelatihan dan validasi. Hal ini mengindikasikan bahwa strategi pra-pemrosesan, termasuk augmentasi data, berhasil meningkatkan performa model.

Penelitian ini dilakukan untuk mengatasi beberapa kelemahan pada penelitian sebelumnya. Pendekatan metaheuristik untuk mengoptimalkan CNN yang digunakan memerlukan waktu komputasi yang signifikan, sehingga kurang cocok untuk aplikasi real-time pada perangkat berbasis edge [20]. Penelitian ini menggunakan ResNet50 dengan transfer learning, yang lebih efisien dari segi pelatihan dan inferensi, sehingga memungkinkan penerapan praktis dalam sistem berbasis IoT. Sementara itu pada penelitian yang lain menggunakan dataset yang terbatas, yang berpotensi menyebabkan overfitting dan keterbatasan generalisasi[3]. Penelitian ini mengatasi masalah tersebut dengan menggunakan dataset yang lebih besar dan beragam, serta menerapkan augmentasi data untuk meningkatkan variasi dalam pelatihan. Selain itu, penelitian ini menambahkan analisis mendalam melalui confusion matrix untuk mengidentifikasi dan memahami kesalahan prediksi, terutama pada kategori dengan gejala visual yang serupa.

Hasil yang diperoleh menunjukkan potensi besar penggunaan transfer learning dengan arsitektur ResNet50 untuk klasifikasi penyakit daun tomat. Dengan akurasi keseluruhan sebesar **99%**, model ini memiliki tingkat keandalan yang sangat tinggi dalam aplikasi praktis. Namun, beberapa temuan penting yang dapat menjadi dasar diskusi lebih lanjut.

Penggunaan transfer learning terbukti sangat efektif untuk mendeteksi penyakit daun tomat. Dengan arsitektur ResNet50, proses pelatihan model menjadi lebih efisien karena model dapat memanfaatkan fitur visual yang telah dilatih sebelumnya pada dataset ImageNet. Hal ini memungkinkan pengenalan pola gejala pada dataset target dengan lebih cepat tanpa memerlukan pelatihan dari awal. Namun demikian, tantangan utama yang dihadapi adalah kinerja pada kelas-kelas yang memiliki gejala mirip, seperti *Tomato Yellow Leaf Curl Virus*, yang masih memerlukan peningkatan melalui variasi data. Penambahan data dari kondisi lapangan yang lebih luas, termasuk kondisi pencahayaan dan varietas tomat yang berbeda, dapat membantu meningkatkan akurasi pada kategori ini.

Selain itu, untuk mengatasi kesalahan minor pada kategori lain, eksplorasi strategi augmentasi data lebih lanjut dapat dilakukan, termasuk augmentasi berbasis geometri seperti rotasi, flipping, atau pemanfaatan teknik augmentasi berbasis domain seperti *Style Transfer*. Untuk aplikasi praktis, model ini dapat diintegrasikan ke dalam perangkat berbasis edge computing seperti Raspberry Pi untuk mendukung deteksi real-time. Dengan demikian, implementasi sistem ini dapat membantu petani mengenali penyakit lebih dini dan mengambil tindakan pencegahan secara efektif. Dalam pengembangan selanjutnya, eksplorasi terhadap metode ensemble model atau arsitektur lain seperti visi transformer dapat dilakukan untuk meningkatkan stabilitas dan akurasi prediksi.

IV. KESIMPULAN

Berdasarkan hasil pelatihan menggunakan 2902 data gambar daun tomat dan penerapan metode transfer learning pada arsitektur ResNet-50, model menunjukkan performa yang sangat baik dengan akurasi 99%. Nilai presisi, recall, dan skor F1 yang diperoleh setiap kategori penyakit juga sangat baik, dengan rata-rata presisi dan recall $>0,97$ untuk sebagian besar kelas. Kategori *Two-Spotted Spider* memiliki performa terbaik dengan nilai presisi, recall, dan skor F1 sebesar 1,00, sedangkan kategori *Tomato Yellow Leaf Curl Virus* memiliki nilai skor F1 terendah, kemungkinan karena kemiripannya dengan gejala lain yang mencapai 0,94. penyakit. Meskipun terdapat kesalahan klasifikasi yang kecil, namun hasil yang diperoleh menunjukkan bahwa model ini sangat efektif dalam mengklasifikasikan penyakit daun tomat. Secara keseluruhan, model ini dapat diandalkan untuk aplikasi praktis deteksi penyakit daun tomat berbasis gambar.

DAFTAR PUSTAKA

- [1] E. R. Lubis, *Bercocok Tanam Tomat Untung Melimpah*. Bhuana Ilmu Populer, 2020. [Online]. Available: <https://books.google.co.id/books?id=sfHuDwAAQBAJ>
- [2] J. D. Arthur, T. Li, G. T. Lalk, and G. Bi, "High tunnel production of containerized hybrid and heirloom tomatoes using grafted plants with two types of rootstocks," *Horticulturae*, vol. 7, no. 9, 2021, doi: 10.3390/horticulturae7090319.
- [3] N. K. Trivedi *et al.*, "Early detection and classification of tomato leaf disease using high-performance deep neural network," *Sensors*, vol. 21, no. 23, 2021, doi: 10.3390/s21237987.
- [4] J. Abdulridha, Y. Ampatzidis, J. Qureshi, and P. Roberts, "Laboratory and UAV-based identification and classification of tomato yellow leaf curl, bacterial spot, and target spot diseases in tomato utilizing hyperspectral imaging and machine learning," *Remote Sens.*, vol. 12, no. 17, 2020, doi: 10.3390/RS12172732.
- [5] K. Roy *et al.*, "Detection of Tomato Leaf Diseases for Agro-Based Industries Using Novel PCA DeepNet," *IEEE Access*, vol. 11, pp. 14983–15001, 2023, doi: 10.1109/ACCESS.2023.3244499.
- [6] A. Debnath *et al.*, "A Smartphone-Based Detection System for Tomato Leaf Disease Using EfficientNetV2B2 and Its Explainability with Artificial Intelligence (AI)," *Sensors (Basel)*, vol. 23, no. 21, 2023, doi: 10.3390/s23218685.
- [7] A. Abade, P. Ferreira, and F. Vidal, "Plant Diseases recognition on images using Convolutional Neural Networks: A Systematic Review,"

- Comput. Electron. Agric.*, vol. 185, p. 106125, 2020, doi: 10.1016/j.compag.2021.106125.
- [8] D. Varughese and S. Sridevi, "DFPT-CNN: A Dual Feature Extraction and Pretrained CNN Synergy for Minimal Computational Overhead and Enhanced Accuracy in Multi-Class Medical Image Classification," *IEEE Access*, vol. 12, pp. 58573–58585, 2024, doi: 10.1109/ACCESS.2024.3386634.
- [9] S. Marvasti-Zadeh, H. Ghanei-Yakhdan, and S. Kasaei, "Adaptive exploitation of pre-trained deep convolutional neural networks for robust visual tracking," *Multimed. Tools Appl.*, vol. 80, pp. 2207–22076, 2020, doi: 10.1007/s11042-020-10382-x.
- [10] L. Chen, X. Cui, and W. Li, "Meta-Learning for Few-Shot Plant Disease Detection," pp. 1–14, 2021.
- [11] W. Shafik, A. Tufail, A. Namoun, L. C. De Silva, and R. A. A. H. M. Apong, "A Systematic Literature Review on Plant Disease Detection: Motivations, Classification Techniques, Datasets, Challenges, and Future Trends," *IEEE Access*, vol. 11, no. May, pp. 59174–59203, 2023, doi: 10.1109/ACCESS.2023.3284760.
- [12] S. Parez, N. Dilshad, N. S. Alghamdi, T. M. Alanazi, and J. W. Lee, "Visual Intelligence in Precision Agriculture: Exploring Plant Disease Detection via Efficient Vision Transformers," *Sensors*, vol. 23, no. 15, pp. 1–14, 2023, doi: 10.3390/s23156949.
- [13] A. Salehi *et al.*, "A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope," *Sustainability*, 2023, doi: 10.3390/su15075930.
- [14] J. Wang, P. Yin, Y. Wang, and W. Yang, "CMAT: Integrating Convolution Mixer and Self-Attention for Visual Tracking," *IEEE Trans. Multimed.*, vol. 26, pp. 326–338, 2024, doi: 10.1109/TMM.2023.3264851.
- [15] Y. Zhang, C. Song, and D. Zhang, "Deep Learning-Based Object Detection Improvement for Tomato Disease," *IEEE Access*, vol. 8, pp. 56607–56614, 2020, doi: 10.1109/ACCESS.2020.2982456.
- [16] E. Cengil and A. Cinar, "Hybrid convolutional neural network based classification of bacterial, viral, and fungal diseases on tomato leaf images," *Concurr. Comput. Pract. Exp.*, vol. 34, 2021, doi: 10.1002/cpe.6617.
- [17] J. Chen, J. Chen, D. Zhang, Y. Sun, and Y. Nanehkaran, "Using deep transfer learning for image-based plant disease identification," *Comput. Electron. Agric.*, vol. 173, p. 105393, 2020, doi: 10.1016/j.compag.2020.105393.
- [18] V. S. Desanamukula, T. D. Teja, and P. Rajitha, "An In-Depth Exploration of ResNet-50 and Transfer Learning in Plant Disease Diagnosis," *2024 Int. Conf. Inven. Comput. Technol.*, pp. 614–621, 2024, doi: 10.1109/ICICT60155.2024.10544802.
- [19] D. Hindarto, "Use of RESNET-50 Neural Network in Diagnosing Diseases Mango Leaves," *J. Comput. Networks, Archit. High Perform. Comput.*, 2024, doi: 10.47709/cnahpc.v6i1.3308.
- [20] S. Nandhini and K. Ashokkumar, "Improved crossover based monarch butterfly optimization for tomato leaf disease classification using convolutional neural network," *Multimed. Tools Appl.*, vol. 80, no. 12, pp. 18583–18610, 2021, doi: 10.1007/s11042-021-10599-4.