

Klasifikasi Penyakit Daun Kopi Arabika Berbasis Gambar Menggunakan Model Convolutional Neural Networks DenseNet121

Muhammad Alwy Solehudin*, Yana Aditia Gerhana, Ichsan Taufik

Fakultas Sains dan Teknologi, Teknik Informatika, UIN Sunan Gunung Djati, Bandung
Jl. A.H. Nasution No.105, Cipadung Wetan, Kec. Cibiru, Kota Bandung, Jawa Barat, Indonesia

E-mail: ^{1,*}alwyal2001@gmail.com, ²yanagerhana@uinsgd.ac.id, ³ichsan@uinsgd.ac.id

Email Penulis Korespondensi: alwyal2001@gmail.com

Submitted: 06/12/2024; Accepted: 28/12/2024; Published: 01/01/2025

Abstrak—Deteksi penyakit daun kopi arabika sangat penting untuk meningkatkan kualitas dan hasil panen kopi. Penelitian ini bertujuan untuk menerapkan model Convolutional Neural Networks DenseNet121 dalam mengidentifikasi tiga jenis penyakit pada daun kopi arabika, yaitu Rust, Phoma, dan Miner. Data yang digunakan terdiri dari gambar daun kopi arabika yang terbagi menjadi data training, validasi, dan uji. Model dilatih menggunakan optimizer Adamax dengan pengaturan hyperparameter, seperti epoch maksimum 30 dan batch size 32. Selama pelatihan, model mencapai akurasi validasi sebesar 98,86% sebelum dihentikan oleh callback early stopping pada epoch ke-28 untuk mencegah overfitting. Evaluasi model yang memanfaatkan confusion matrix menghasilkan akurasi 97% pada data uji, dengan nilai precision, recall, dan F1-score yang sangat baik pada sebagian besar kategori, terutama pada kelas Healthy, Miner, dan Phoma. Kelas Rust menunjukkan recall yang lebih rendah akibat ketidakseimbangan jumlah data pada data uji. Hasil penelitian ini menunjukkan bahwa model DenseNet121 dapat diandalkan untuk mendeteksi penyakit pada daun kopi arabika dengan akurasi yang tinggi dan memberikan kontribusi penting untuk teknologi pemantauan kesehatan tanaman kopi, yang dapat membantu petani dalam deteksi dini dan meningkatkan produktivitas pertanian kopi.

Kata Kunci: Convolutional neural networks; DenseNet121; Daun Kopi; Gambar; Klasifikasi

Abstract—Detection of Arabica coffee leaf diseases is crucial for improving the quality and yield of coffee crops. This study aims to apply the DenseNet121 Convolutional Neural Network model to identify three types of diseases on Arabica coffee leaves, namely Rust, Phoma, and Miner. The data used consists of images of Arabica coffee leaves, which are divided into training, validation, and test sets. The model was trained using the Adamax optimizer with hyperparameters such as a maximum of 30 epochs and a batch size of 32. During training, the model achieved a validation accuracy of 98.86% before being stopped by the early stopping callback at epoch 28 to prevent overfitting. Model evaluation using a confusion matrix resulted in 97% accuracy on the test data, with excellent precision, recall, and F1-score values for most categories, particularly for the Healthy, Miner, and Phoma classes. The Rust class showed lower recall due to data imbalance in the test set. The results of this study demonstrate that the DenseNet121 model is reliable for detecting diseases on Arabica coffee leaves with high accuracy and provides an important contribution to the technology of plant health monitoring, which can assist farmers in early detection and improve coffee crop productivity.

Keywords: Convolutional Neural Networks; DenseNet121; Coffee Leaf; Images; Classification

1. PENDAHULUAN

Kopi arabika adalah salah satu hasil produksi unggulan Indonesia. Pada lima tahun terakhir, Indonesia meraih peringkat keempat sebagai eksportir kopi arabika paling besar di seluruh dunia, berada di bawah Brazil, Kolombia, dan Vietnam. Diluar itu, Indonesia juga menduduki posisi kedua setelah Vietnam sebagai produsen kopi arabika terbesar secara global[1]. Meskipun memiliki potensi yang besar, tanaman kopi arabika kerap menghadapi berbagai masalah yang menghambat produktivitasnya, beberapa penyebabnya adalah gangguan yang ditimbulkan oleh serangan hama maupun kondisi lingkungan yang tidak menguntungkan[2]. Penyakit pada tanaman kopi arabika dapat menyebabkan penurunan hasil produksi dan bahkan meningkatkan angka kematian tanaman. Untuk itu, deteksi dini penyakit pada tanaman kopi arabika menjadi sangat penting agar langkah penanggulangan yang tepat dapat dilakukan[3].

Penyakit pada tanaman kopi arabika sering kali bisa dikenali dari perubahan warna atau bentuk daun[4]. Beberapa jenis penyakit yang menyerang daun kopi arabika di antaranya adalah miner, Phoma dan Rust. Beberapa penyakit dapat ditimbulkan oleh jamur, mikroorganisme atau bakteri, yang sering kali sulit diidentifikasi hanya melalui pengamatan langsung[3]. Oleh karena itu, penerapan teknologi modern sangat dibutuhkan untuk membantu proses identifikasi penyakit dengan kecepatan dan ketepatan yang lebih tinggi.

Teknologi yang dapat membantu mempermudah proses deteksi penyakit dalam daun tanaman kopi arabika. Dengan memanfaatkan dataset berupa gambar dari daun kopi arabika yang sehat ataupun sakit sebagai data pelatihan untuk Machine Learning, teknologi ini memungkinkan petani dapat mendeteksi penyakit tanaman kopi arabika dengan lebih akurat[5]. Salah satu pendekatan yang digunakan untuk klasifikasi penyakit pada daun kopi arabika berbasis gambar adalah Convolutional Neural Network (CNN)[6]. CNN adalah jenis neural network yang paling signifikan di bidang pembelajaran mendalam deep learning[7]. CNN terbagi menjadi dua komponen utama, berupa pemrosesan ekstrak fitur dan pengklasifikasian. Bagian ekstrak fitur melibatkan berbagai macam lapisan convolution dilanjutkan dengan fungsi max-pooling dan aktivasi. CNN telah menunjukkan kinerja yang tinggi dalam klasifikasi gambar[8]. Oleh karena itu diperlukannya pengujian dini pada daun tanaman kopi arabika menggunakan model CNN yang bisa dengan tepat mengidentifikasi dan membedakan penyakit pada daun tanaman

kopi arabika dari gambar digital. Dengan memanfaatkan kemampuan CNN dalam pengenalan pola dan analisis gambar, diharapkan deteksi penyakit dapat dilakukan dengan lebih cepat dan akurat.

Beragam penelitian telah dilakukan untuk mengembangkan deteksi penyakit daun kopi arabika dengan kecerdasan buatan. Metode hybrid feature fusion yang menggabungkan MobileNetV3 dan Swin Transformer mencapai akurasi 84,29% dalam identifikasi penyakit daun kopi arabika[9]. YOLOv7 menekankan kecepatan dan presisi tinggi, menghasilkan F1-score 0,99 pada kelas biner[2]. Sementara itu, KNN dengan fitur GLCM mencapai akurasi 81,3%[10], dan CNN AlexNet menghasilkan akurasi uji hingga 81,6% pada gambar daun kopi arabika[4]. Model ResNet-50 menunjukkan performa baik dengan akurasi 92,68% untuk klasifikasi biner[5].

Pendekatan inovatif seperti federated learning CNN mencapai akurasi hingga 94,85%, menunjukkan potensi dalam sistem deteksi berbasis data terdesentralisasi[11]. Selain itu, CNN ResNet50 berhasil mengidentifikasi kekurangan nutrisi daun kopi arabika dengan akurasi 87,75%[12]. Teknologi segmentasi lanjutan juga diterapkan, dengan Mask R-CNN dan UNet mencapai mean intersection over union 94,25%[13], dan semi-otomatisasi mask generation mencapai akurasi 90%[14]. Terakhir, kombinasi CNN dan Random Forest menghasilkan akurasi 77%, menguatkan potensi diagnosa dini penyakit[15].

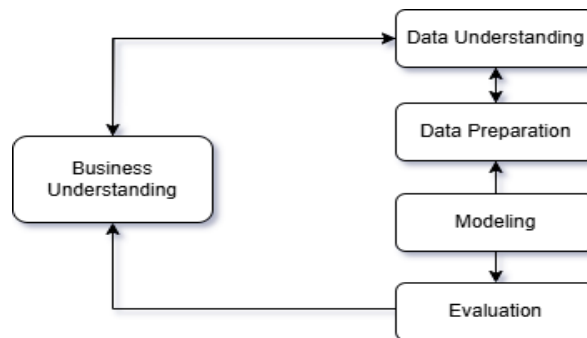
Penelitian ini dilakukan untuk deteksi penyakit daun kopi arabika dengan menggunakan model DenseNet121. Pemilihan model DenseNet121 didasarkan pada keberhasilannya dalam deteksi pada gambar daun, terbukti efektif pada penelitian sebelumnya dengan akurasi 98,23% dan akurasi test mencapai 94,96% [16]. Model DenseNet121 juga menunjukkan performa tinggi dalam berbagai tugas klasifikasi, seperti pada pengujian yang menghasilkan akurasi 0,98, presisi 0,95, recall 0,95, dan F1 Score 0,95[17]. Selain itu, penelitian lain menunjukkan akurasi terbaik sebesar 99,17% dengan loss 0,0355[18], serta keberhasilannya untuk klasifikasi penyakit Alzheimer melalui citra MRI otak dengan tingkat akurasi mencapai 97,83% [19]. Hasil-hasil tersebut menegaskan bahwa DenseNet121 merupakan model yang andal untuk tugas klasifikasi visual. Walaupun telah menunjukkan keefektifan dalam berbagai tugas klasifikasi visual, penerapannya pada deteksi penyakit daun kopi arabika masih belum dilakukan. Dengan menggunakan DenseNet121, diharapkan dapat meningkatkan presisi dan efisiensi deteksi penyakit daun kopi arabika, memberikan solusi yang lebih akurat.

DenseNet121 merupakan salah satu arsitektur CNN yang dirancang untuk menyelesaikan tugas klasifikasi gambar. yaitu kebutuhan komputasi tinggi dan potensi degradasi kinerja seiring dengan bertambahnya kedalaman jaringan[20]. Arsitektur DenseNet (Densely Connected Convolutional Networks) memiliki karakteristik unik, di mana setiap lapisan terhubung langsung ke semua lapisan lainnya[17], memungkinkan jaringan untuk mempelajari fitur-fitur yang lebih kompleks dengan lebih efisien. Selain itu, dengan mengurangi redundansi dan mempercepat aliran gradien, DenseNet121 dapat mencapai akurasi tinggi dengan jumlah parameter informasi yang relatif lebih sedikit dibandingkan model lain dengan kedalaman serupa. Dalam konteks deteksi penyakit daun kopi arabika, DenseNet121 diharapkan dapat mengenali pola dan karakteristik visual yang lebih halus, seperti perubahan warna dan tekstur pada daun yang mungkin mengindikasikan penyakit. Oleh sebab itu, DenseNet121 digunakan untuk memaksimalkan kemampuan model deteksi dalam mengklasifikasikan penyakit secara akurat dan efisien.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan metodologi standar dalam pengembangan proyek data mining yang terdiri dari beberapa tahap penting[21]. Setiap tahap bertujuan untuk mengidentifikasi kebutuhan spesifik dalam pengembangan model secara berurutan yaitu CRISP-DM (Cross-Industry Standard Process for Data Mining)[22].

Dalam penelitian ini, proses pengembangan model deteksi penyakit daun kopi arabika dilakukan hingga tahap evaluasi. Pembatasan ini dilakukan untuk menekankan fokus pada pengembangan dan pengujian akurasi model DenseNet121 dalam mengidentifikasi penyakit daun kopi arabika sebagai bukti konsep (proof of concept). Tahapan metode penelitian dapat dilihat pada Gambar 1 berikut.



Gambar 1. Tahapan metode penelitian

Menurut Gambar 1, penelitian terdiri dari lima tahap utama. Tahap pertama adalah Business Understanding, yang berfokus pada penentuan tujuan penelitian, yaitu mengembangkan solusi berbasis model DenseNet121 untuk mendeteksi penyakit daun kopi arabika secara otomatis. Tahap kedua adalah Data Understanding, yang mencakup



pengumpulan dan analisis dataset, baik data primer berupa gambar daun kopi arabika dari kebun maupun data sekunder dari sumber daring, untuk memahami distribusi kelas dan karakteristik data. Tahap ketiga, Data Preparation, melibatkan preprocessing seperti resizing gambar dan pembagian dataset menjadi latih, validasi, serta uji. Selanjutnya, pada tahap Modeling, model DenseNet121 dirancang dan dilatih menggunakan konfigurasi tertentu untuk menghasilkan performa optimal. Terakhir, tahap Evaluation dilakukan untuk menilai kinerja model dengan metrik seperti akurasi, presisi, recall, dan F1 Score, memastikan hasil yang sesuai dengan tujuan penelitian.

2.1 Business Understanding

Maksud penelitian ini adalah untuk mengembangkan model deteksi penyakit pada daun kopi arabika berbasis gambar dengan penerapan model DenseNet121. Model ini diharapkan mampu memberikan kemudahan bagi petani dalam mengenali penyakit pada daun kopi arabika cepat dan akurat, tanpa bergantung pada keahlian khusus. Identifikasi dini penyakit pada daun kopi arabika sangat penting untuk mencegah kerugian yang semakin besar akibat penyebaran penyakit, sehingga memungkinkan petani untuk mengambil tindakan pencegahan yang lebih cepat.

2.2 Data Understanding

Dataset yang dipakai terbagi menjadi dua yaitu data primer dan data sekunder. Data primer terdiri dari gambar daun kopi arabika yang diambil langsung dari perkebunan kopi arabika di Kp. Longkewang, Desa Gasol, Kec. Cugenang, Kab. Cianjur. Data ini digunakan untuk mengevaluasi model pada gambar yang belum pernah ditemui sebelumnya. Data sekunder diambil dari Kaggle dan digunakan untuk pelatihan dan validasi model. Kedua dataset ini mencakup gambar daun kopi arabika dalam kondisi sehat serta yang terinfeksi penyakit seperti rust, miner, dan phoma.

2.3 Data Preparation

Pada tahap ini, gambar daun kopi arabika dari kedua dataset diproses dan disiapkan untuk digunakan dalam pelatihan dan pengujian model. Langkah-langkah persiapan meliputi resizing gambar menjadi ukuran standar (224x224 piksel), normalisasi nilai piksel, serta pembagian data menjadi training, validation, dan test set. Data sekunder digunakan untuk training dan validation, sementara data primer digunakan untuk test dengan jumlah 114 gambar.

2.4 Modeling

Tahapan ini melibatkan deep learning sebagai metode utama untuk membangun model deteksi penyakit daun kopi arabika. Pemodelan dilakukan dengan memilih arsitektur yang sesuai serta merancang skenario pelatihan untuk mendapatkan hasil terbaik. Model yang dipilih dalam penelitian ini adalah DenseNet121, yang memiliki kemampuan unggul dalam mengekstraksi fitur visual dari gambar daun kopi arabika. Berikut adalah langkah-langkah yang diterapkan dalam pemodelan ini:

1. Berdasarkan karakteristik permasalahan, pendekatan klasifikasi dipilih untuk mengidentifikasi beberapa jenis penyakit daun kopi arabika, seperti rust, miner, dan phoma.
2. Model yang digunakan adalah DenseNet121, sebuah arsitektur CNN yang dirancang untuk pengklasifikasian gambar.
3. Proses pelatihan dilakukan dengan mengoptimalkan hyperparameter model berdasarkan evaluasi akurasi dan loss pada data validation di setiap epoch, guna memastikan model mampu mengenali pola-pola penting pada gambar daun kopi arabika dengan efektif.

2.5 Evaluation

Pada tahapan Evaluation, performa model ini dievaluasi menggunakan test data. Beberapa metrik yang digunakan untuk evaluasi di antaranya akurasi, precision, recall, F1-score, dan confusion matrix. Metrik ini dipakai untuk mengevaluasi seberapa baik model dalam mengidentifikasi penyakit daun kopi arabika dan seberapa akurat prediksi yang diberikan oleh model. Evaluasi ini bertujuan untuk memastikan bahwa model dapat memenuhi tujuan penelitian dan memiliki kinerja yang baik sebelum digunakan lebih lanjut. Masing-masing metrik memiliki rumus dan fungsi sebagai berikut:

1. Akurasi: menghitung proporsi perkiraan yang tepat dari semua perkiraan yang dibuat oleh model. Rumusnya:

$$\text{Akurasi} = \frac{\sum TP}{\sum TP + \sum FP + \sum FN} \quad (1)$$

2. Precision: Pengukuran akurasi model dalam memprediksi setiap kelas secara individual. Precision untuk kelas i dihitung dengan:

$$\text{Precision Kelas } i = \frac{TP_i}{TP_i + \sum FP_{i,j}} \quad (2)$$

3. Recall: Mengukur sensitivitas model dalam mendeteksi sampel yang benar untuk setiap kelas. Recall untuk kelas i adalah:

$$\text{Recall Kelas } i = \frac{TP_i}{TP_i + \sum FN_{j,i}} \tag{3}$$

4. F1-Score: Ini adalah rata-rata precision dan recall yang dihasilkan dari rata-rata harmonik. untuk setiap kelas, memberikan keseimbangan antara kedua metrik tersebut, terutama berguna saat ada ketidakseimbangan data. F1-Score untuk kelas i dihitung dengan:

$$\text{F1-Score Kelas } i = 2 \times \frac{\text{Precision } i \times \text{Recall } i}{\text{Precision } i + \text{Recall } i} \tag{4}$$

3. HASIL DAN PEMBAHASAN

3.1 Business Understanding

Penelitian ini bertujuan untuk mengembangkan model deteksi penyakit daun kopi arabika berbasis gambar menggunakan model DenseNet121. Penyakit seperti rust, miner, dan phoma dapat merusak tanaman kopi arabika jika tidak ditangani dengan cepat, sehingga deteksi dini sangat diperlukan untuk menghindari kerugian lebih lanjut. Model ini dirancang untuk memudahkan petani untuk mengetahui penyakit pada daun kopi arabika secara tepat tanpa memerlukan keahlian khusus.

Dengan model ini memungkinkan deteksi otomatis hanya melalui gambar daun kopi arabika, sehingga mempermudah petani dalam mengambil tindakan pencegahan dengan lebih cepat. DenseNet121 dipilih karena kemampuannya dalam mengekstraksi fitur dari gambar dengan akurasi tinggi, yang diharapkan dapat mengidentifikasi gejala penyakit secara cermat. Tujuan utama dari penelitian ini untuk memberikan konsep yang praktis untuk membantu meningkatkan hasil pertanian dan mengurangi kerugian akibat penyebaran penyakit.

3.2 Data Understanding

Penelitian ini menggunakan dua jenis dataset yang memiliki tujuan spesifik dalam pengembangan model deteksi penyakit daun kopi arabika.




a. Data Primer

Data primer diperoleh dari kebun kopi arabika yang terletak di Kp. Longkewang, Desa Gasol, Kec. Cugenang, Kab. Cianjur. Data ini mencakup gambar-gambar daun kopi arabika yang diperoleh dalam berbagai kondisi, baik daun sehat maupun daun yang menunjukkan tanda-tanda infeksi oleh beberapa jenis penyakit, yaitu Rust, Miner, dan Phoma. Data ini memiliki karakteristik yang lebih alami, mencerminkan kondisi lapangan yang sebenarnya. Data primer difungsikan sebagai data uji (test set), yaitu data yang hanya akan digunakan pada tahap evaluasi model untuk menilai seberapa baik model yang telah dilatih dapat mengenali pola-pola penyakit pada daun kopi arabika dari data lapangan yang sesungguhnya.

b. Data Sekunder

Data sekunder berasal dari dataset terbuka yang tersedia di Kaggle dengan judul "Coffee Leaf Diseases". Data ini terdiri dari gambar-gambar daun kopi arabika dalam dua kondisi utama: daun sehat dan daun yang terinfeksi penyakit. Sama seperti data primer, data sekunder juga mencakup kelas-kelas penyakit yang sama, yaitu Rust, Miner, dan Phoma, yang menyediakan variasi yang cukup untuk proses pelatihan. Namun, data sekunder ini digunakan sebagai data pelatihan (training set) dan validasi (validation set), yang artinya data ini berfungsi sebagai dasar pembelajaran model serta untuk penyesuaian parameter hyperparameter dan pengukuran akurasi selama proses pelatihan.

Tabel 1. Daftar kelas daun kopi arabika

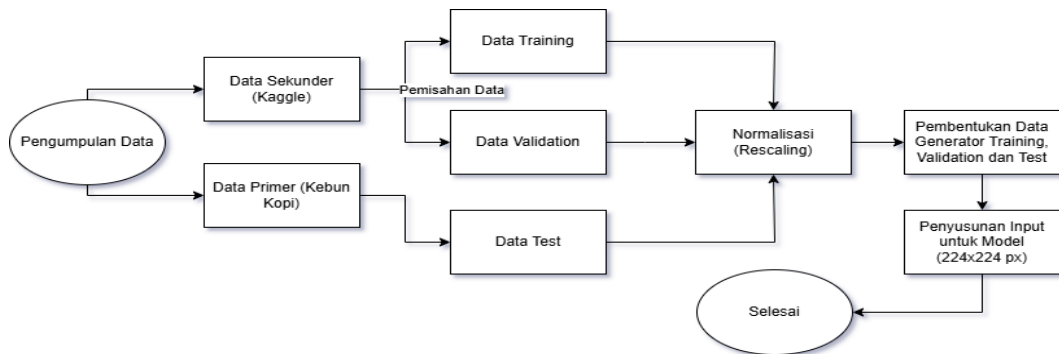
Gambar	Kelas
	Healthy
	Miner
	Phoma

Gambar	Kelas
	Rust

Tabel 1 menunjukkan daftar kelas daun kopi arabika yang digunakan dalam penelitian ini. Dataset diklasifikasikan ke dalam empat kelas utama, yaitu Healthy (daun kopi arabika yang sehat tanpa tanda-tanda penyakit), Miner (daun yang terinfeksi oleh serangan serangga penggerek), Phoma (daun yang menunjukkan penyakit akibat infeksi jamur Phoma), dan Rust (daun yang terinfeksi oleh jamur penyebab karat daun kopi arabika). Keempat kelas ini dipilih berdasarkan jenis-jenis penyakit daun kopi arabika yang umum ditemukan di lapangan, sehingga mencerminkan situasi nyata yang dihadapi petani. Pembagian kelas ini menjadi dasar untuk membangun model klasifikasi guna mendeteksi kondisi daun secara otomatis.

3.3 Data Preparation

Tahap ini bertujuan menyiapkan data menjadi lebih terstruktur dan ideal untuk diproses dalam pelatihan model. Setelah melalui proses Data Understanding, data kemudian diolah lebih lanjut agar siap digunakan dalam pelatihan. Pada tahap ini, dibentuk data generator untuk mempersiapkan data pelatihan, validasi, dan uji. Gambar 2 memberikan ilustrasi mengenai alur dari setiap tahap persiapan data ini.



Gambar 2. Alur Data Preparatorion

Gambar 2 menunjukkan alur Data Preparation penelitian ini. Data diperoleh dari dua sumber: data primer (untuk pengujian) dan data sekunder (untuk pelatihan dan validasi). Data dinormalisasi ke rentang 0–1 dan diubah ukurannya menjadi 224x224 piksel. Setelah itu, data diolah menggunakan generator untuk memastikan siap digunakan dalam pelatihan, validasi, dan pengujian model DenseNet121.

Data pelatihan dan data validasi diambil dari data sekunder yang dibagi dengan perbandingan rasio 70/30, 80/20, dan 90/10. Rasio yang memberikan hasil terbaik akan dipilih untuk digunakan dalam pelatihan model.

Data pelatihan menggunakan objek ImageDataGenerator dengan parameter rescale=1./255, yang bertujuan untuk menormalkan gambar sehingga nilai pikselnya berada dalam rentang [0, 1]. Selanjutnya, data pelatihan dimuat menggunakan metode flow_from_dataframe yang mengambil data dari dataframe train_df. Data frame ini berisi informasi tentang path gambar dan label penyakit yang terkait. Setiap gambar akan diubah ukurannya menjadi 224x224 piksel agar sesuai dengan input yang diperlukan oleh model DenseNet121. Dalam hal ini, label gambar diatur ke dalam format categorical, yang mengindikasikan bahwa tugas model adalah klasifikasi multi-kelas. Ukuran batch ditetapkan sebesar 32 untuk memastikan pelatihan dapat berjalan serta data diacak sebelum diproses untuk menghindari bias.


Data validasi juga diproses menggunakan ImageDataGenerator dengan parameter yang sama, yaitu rescale=1./255, untuk normalisasi. Sama seperti pada data pelatihan, data validasi dimuat menggunakan flow_from_dataframe yang mengambil data dari dataframe valid_df. Data validasi juga diubah ukurannya menjadi 224x224 piksel, dengan label yang sesuai dan diatur dalam format kategori. Ukuran batch juga ditetapkan sebesar 32 dan data validasi diacak setiap kali diproses.

Data uji diambil dari data primer yang disiapkan dengan menggunakan ImageDataGenerator dengan parameter rescale=1./255 untuk normalisasi, untuk menghindari bias dan memastikan bahwa evaluasi model dilakukan dengan gambar yang asli. Data uji dimuat menggunakan flow_from_dataframe dengan mengambil data dari dataframe test_df. Data uji juga diubah ukurannya menjadi 224x224 piksel, sesuai dengan persyaratan input model. Pada bagian ini, gambar-gambar dalam set uji tidak diacak.

3.4 Modelling

Pada penelitian ini, digunakan model DenseNet121 yang dilatih sebagai fitur extractor untuk klasifikasi penyakit daun kopi arabika. DenseNet121 dipilih karena arsitekturnya yang mampu menghubungkan setiap lapisan ke

semua lapisan sebelumnya[16], sehingga memaksimalkan penggunaan fitur tanpa perlu meningkatkan jumlah parameter secara signifikan.



Gambar 3. Arsitektur DenseNet121

Gambar 3 menunjukkan arsitektur DenseNet, yang menekankan koneksi padat antar lapisan. Setiap lapisan terdiri dari batch normalization (BN), ReLU activation, dan convolution (Conv), yang bekerja untuk mengekstraksi fitur dari input. Salah satu fitur utama DenseNet adalah setiap lapisan menerima input dari lapisan sebelumnya, menciptakan hubungan langsung antar fitur dan mengurangi masalah vanishing gradient. Setelah beberapa lapisan konvolusional, Transition Layer digunakan untuk mengurangi dimensi dan mempersiapkan data untuk tahap selanjutnya dalam jaringan.

3.4.1 Pembentukan Model

Model yang digunakan dimulai dari DenseNet121 dengan bobot ImageNet sebagai base model, tetapi lapisan top atau lapisan output aslinya dihilangkan untuk menambahkan lapisan-lapisan kustom sesuai kebutuhan klasifikasi penyakit daun kopi arabika. Input shape yang digunakan adalah 224x224x3.

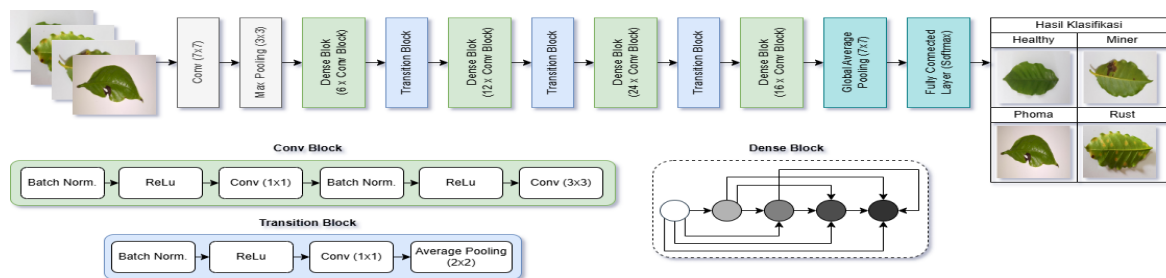
Setelah ekstraksi fitur dari DenseNet121, lapisan tambahan yang ditambahkan:

- 1) Global Average Pooling untuk mengurangi dimensi tanpa kehilangan informasi utama dari fitur-fitur yang diekstraksi.
- 2) Flatten Layer untuk mengubah fitur menjadi vektor satu dimensi.
- 3) Dense Layer dengan 256 neuron dan fungsi aktivasi ReLU, guna menghasilkan fitur-fitur yang lebih spesifik untuk keperluan klasifikasi.
- 4) Dropout Layer sebesar 0,3, yang digunakan untuk mencegah overfitting pada model selama pelatihan.
- 5) Output Layer dengan 4 neuron dan fungsi aktivasi softmax untuk mengkategorikan gambar daun kopi arabika ke dalam empat kategori: Healthy, Miner, Phoma, dan Rust.

Tahapan pertama dimulai dengan lapisan konvolusi berukuran filter 7x7, yang bertugas mengekstrak fitur dasar dari gambar. Setelah itu, hasil ekstraksi fitur ini diproses lebih lanjut melalui lapisan max pooling berukuran 3x3, yang berfungsi untuk mengurangi dimensi fitur, sehingga memperkecil ukuran data yang diproses tanpa kehilangan informasi penting.

Setelah proses awal, data diteruskan ke rangkaian Dense Block dan Transition Block yang merupakan inti dari arsitektur DenseNet. Dalam Dense Block, setiap lapisan konvolusi terhubung langsung ke lapisan-lapisan berikutnya, memungkinkan pemanfaatan kembali fitur yang telah diekstraksi pada tiap lapisan. Setiap blok ini terdiri dari Conv Block yang memiliki beberapa lapisan, termasuk Batch Normalization (untuk normalisasi fitur), ReLU (fungsi aktivasi), dan lapisan konvolusi (Conv) untuk ekstraksi fitur lebih lanjut. Transition Block, yang ditempatkan di antara Dense Block, terdiri dari Batch Normalization, ReLU, konvolusi 1x1, dan average pooling 2x2. Blok transisi ini mengurangi jumlah filter dan ukuran fitur, sehingga menjaga efisiensi komputasi dan mengendalikan jumlah parameter dalam model.

Setelah melalui beberapa Dense Block dan Transition Block, model mengaplikasikan Global Average Pooling (7x7) yang mereduksi fitur ke dalam satu nilai per fitur, tanpa kehilangan informasi penting untuk proses klasifikasi. Kemudian, fitur yang telah diringkas ini dikirim ke lapisan fully connected dengan fungsi aktivasi softmax, untuk memprediksi probabilitas dari keempat kelas penyakit daun kopi arabika yang diteliti. Proses ini memungkinkan model mempelajari karakteristik tiap penyakit dan mengklasifikasikan gambar secara akurat.



Gambar 4. Alur Arsitektur DenseNet121

Hasil Klasifikasi	
Healthy	Miner
Phoma	Rust

Pada Gambar 4, alur arsitektur DenseNet121 untuk penelitian ini digambarkan dari input hingga keluaran prediksi, dengan setiap tahapan dari feature extraction hingga klasifikasi yang disesuaikan untuk penyakit daun kopi arabika. Hasil klasifikasi ini ditampilkan dalam empat kategori, mencerminkan kemampuan model untuk mengidentifikasi jenis penyakit pada daun kopi arabika.


3.5 Training Model

Model dilatih menggunakan optimizer Adamax yang dikenal baik dalam menangani data sparsity, serta memiliki stabilitas dalam pengaturan pembelajaran pada dimensi yang berbeda. Pada tahap pelatihan ini, hyperparameter yang diterapkan meliputi learning rate default dari Adamax, jumlah epoch maksimal 30, dan ukuran batch sebesar 32. Selain itu, callback early stopping diterapkan untuk menghindari overfitting, dengan menghentikan pelatihan saat akurasi validasi mencapai 98% atau lebih. Pada tahap ini akan dilakukan perbandingan berbagai rasio pembagian data antara data pelatihan dan data validasi, yaitu 70/30, 80/20, dan 90/10. Tujuan dari perbandingan ini adalah untuk menentukan rasio yang memberikan hasil terbaik dalam melatih model, sehingga dapat memaksimalkan kinerja dan akurasi deteksi penyakit daun kopi arabika. Rasio yang memberikan performa optimal akan dipilih untuk digunakan dalam proses evaluasi. Selama pelatihan, model menggunakan fungsi loss categorical crossentropy yang sesuai untuk klasifikasi multi-kelas. Akurasi dan loss pada data training dan validasi dipantau di seluruh epoch agar mengevaluasi proses konvergensi model.

Tabel 2. Perbandingan Rasio

Rasio	Akurasi	Akurasi Validasi
70/30	97.14%	98.48%
80/20	98.74%	98.30%
90/10	99.42%	98.86%

Tabel 2 menunjukkan hasil perbandingan kinerja model berdasarkan tiga rasio pembagian data pelatihan dan validasi: 70/30, 80/20, dan 90/10. Pada rasio 70/30, model mencapai akurasi pelatihan sebesar 97.14% dan akurasi validasi 98.48%. Pada rasio 80/20, akurasi pelatihan meningkat menjadi 98.74% dengan akurasi validasi 98.30%. Sementara itu, rasio 90/10 menghasilkan kinerja terbaik dengan akurasi pelatihan 99.42% dan akurasi validasi 98.86%. Rasio 90/10 dipilih karena memberikan akurasi pelatihan dan validasi tertinggi dibandingkan rasio lainnya. Hal ini menunjukkan bahwa dengan lebih banyak data yang digunakan untuk pelatihan, model dapat belajar lebih baik tanpa mengorbankan performa validasi[23]. Dengan demikian, rasio ini dianggap paling optimal untuk mendukung akurasi deteksi penyakit daun kopi arabika.




Gambar 5. Grafik Rasio 90/10

Dari gambar 5 yang menampilkan grafik hasil dari pelatihan model, terlihat bahwa model mencapai akurasi yang tinggi dengan nilai loss yang terus menurun baik pada data training maupun validasi. Hal ini memperlihatkan adanya indikasi bahwa model berhasil mempelajari pola yang ada dalam dataset dengan efektif, menghasilkan performa yang stabil dan memuaskan pada klasifikasi penyakit daun kopi arabika.

3.6 Evaluation

Setelah pelatihan model selesai, langkah berikutnya adalah tahap evaluasi. Pada tahap ini, evaluasi menggunakan confusion matrix untuk menghitung nilai Akurasi, precision, Recall, dan F1 Score. Tahap evaluasi ini mengukur performa model ketika diuji dengan gambar baru yang belum pernah dipelajari oleh model sebelumnya. Dalam proses ini, Confusion Matrix digunakan sebagai alat evaluasi utama.



Gambar 6. Confusion Matrix Daun Kopi Arabika

Confusion matrix pada Gambar 6 menunjukkan hasil klasifikasi model terhadap daun kopi arabika ke dalam empat kelas: Healthy, Miner, Phoma, dan Rust. Nilai pada diagonal utama menunjukkan prediksi yang benar, yaitu 33 untuk Healthy, 34 untuk Miner, 24 untuk Phoma, dan 20 untuk Rust. Beberapa kesalahan terjadi, seperti 1 data Miner salah diprediksi sebagai Healthy, 1 data Healthy salah diprediksi sebagai Phoma, dan 1 data Rust salah diprediksi sebagai Miner. Secara keseluruhan, model menunjukkan performa yang baik dengan sebagian besar prediksi berada pada diagonal utama, menandakan tingkat akurasi yang dengan sedikit kesalahan klasifikasi. Hasil dari keempat metrik tersebut dapat dilihat pada Gambar 7.

	precision	recall	f1-score	support
Healthy	0.97	0.97	0.97	34
Miner	0.97	0.97	0.97	35
Phoma	0.96	1.00	0.98	24
Rust	1.00	0.95	0.98	21
accuracy			0.97	114
macro avg	0.98	0.97	0.97	114
weighted avg	0.97	0.97	0.97	114

Gambar 7. Classification Report Daun Kopi Arabika

Classification report pada Gambar 7 menunjukkan performa model menghasilkan akurasi keseluruhan sebesar 97%, dengan precision, recall, dan F1-score rata-rata masing-masing sebesar 0,97. Kinerja terbaik terlihat pada kelas Rust dengan precision 1,00 dan Phoma dengan recall 1,00, sementara kelas lainnya juga menunjukkan performa yang sangat baik dengan nilai metrik yang konsisten. Secara keseluruhan, model mampu mengklasifikasikan data dengan presisi tinggi dan kesalahan minimal di semua kelas. Berikut untuk menentukan akurasi, recall, precision, dan F1 score dari setiap kelas secara manual

1) Akurasi

Berdasarkan confusion matrix $\sum TP = 33+34+24+20=111$

Jumlah total data test = 114 (ini sama dengan $\sum TP + \sum FP + \sum FN$)

Akurasi dihitung dengan rumus:

$$\begin{aligned} \text{Akurasi} &= \frac{\sum TP}{\sum TP + \sum FP + \sum FN} \\ &= \frac{111}{114} = 0.97 \end{aligned}$$

2) Precision per Kelas

Precision untuk setiap kelas i dihitung dengan rumus:

$$\begin{aligned} \text{Precision Kelas } i &= \frac{TP_i}{TP_i + \sum FP_{i,j}} \\ \text{Healthy} &= \frac{33}{33+1} = 0.97 \\ \text{Miner} &= \frac{34}{34+1} = 0.97 \\ \text{Phoma} &= \frac{24}{24+1} = 0.96 \\ \text{Rust} &= \frac{20}{20+0} = 1.00 \end{aligned}$$

3) Recall per Kelas

Recall untuk setiap kelas i dihitung dengan rumus:

$$\begin{aligned} \text{Recall Kelas } i &= \frac{TP_i}{TP_i + \sum FN_{j,i}} \\ \text{Healthy} &= \frac{33}{33+1} = 0.97 \\ \text{Miner} &= \frac{34}{34+1} = 0.97 \\ \text{Phoma} &= \frac{24}{24+0} = 1.00 \\ \text{Rust} &= \frac{20}{20+1} = 0.95 \end{aligned}$$

4) F1-Score per Kelas

F1-score untuk setiap kelas i dihitung dengan rumus:

$$\begin{aligned} \text{F1-Score Kelas } i &= 2 \times \frac{\text{Precision } i \times \text{Recall } i}{\text{Precision } i + \text{Recall } i} \\ \text{Healthy} &= 2 \times \frac{0.97 \times 0.97}{0.97 + 0.97} = 0.97 \\ \text{Miner} &= 2 \times \frac{0.97 \times 0.97}{0.97 + 0.97} = 0.97 \\ \text{Phoma} &= 2 \times \frac{0.96 \times 1.00}{0.96 + 1.00} = 0.98 \\ \text{Rust} &= 2 \times \frac{1.00 \times 0.95}{1.00 + 0.95} = 0.98 \end{aligned}$$



4. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa model DenseNet121 dapat diterapkan dengan efektif dalam mendeteksi penyakit daun kopi arabika dengan akurasi yang tinggi, yaitu 97% pada data uji. Selama proses pelatihan, model ini mencapai akurasi sebesar 98,86%, yang menunjukkan kemampuannya dalam mempelajari dan mengklasifikasikan gambar daun kopi dengan baik. Dengan menggunakan dataset yang terdiri dari gambar daun kopi sehat dan daun kopi yang terinfeksi penyakit seperti Rust, Phoma, dan Miner, model ini mampu mengklasifikasikan gambar dengan akurasi yang sangat baik pada data uji. Selama tahap evaluasi, model menunjukkan hasil yang menjanjikan berdasarkan pengukuran akurasi dan analisis confusion matrix, yang membuktikan efektivitasnya dalam membedakan kelas-kelas penyakit tersebut. Proses pelatihan model melibatkan penggunaan data primer dan sekunder, serta pengaturan hyperparameter yang optimal, seperti callback early stopping dan penggunaan optimizer Adamax. Hasil dari penelitian ini dapat menjadi dasar untuk penerapan teknologi deep learning dalam sistem pemantauan kesehatan tanaman kopi di lapangan, yang dapat membantu petani kopi dalam mendeteksi penyakit lebih awal dan mengambil tindakan pencegahan yang lebih cepat.

REFERENCES

- [1] S. Harum, "Analisis Produksi Kopi Di Indonesia Tahun 2015-2020 Menggunakan Metode Cobb-Douglass," *Growth: Jurnal Ilmiah Ekonomi Pembangunan*, vol. 4, no. 2, pp. 101–108, 2022.
- [2] N. F. Hasan, "Deteksi dan Klasifikasi Penyakit Pada Daun Kopi Menggunakan Yolov7," *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, vol. 12, no. 1, pp. 30–35, 2023, doi: <https://doi.org/10.32736/sisfokom.v12i1.1545>.
- [3] B. Wahyuningtyas, I. I. Tritoasmoro, and N. Ibrahim, "Identifikasi Penyakit Pada Daun Kopi Menggunakan Metode Local Binary Pattern Dan Random Forest," *eProceedings of Engineering*, vol. 9, no. 6, 2023.
- [4] D. Irfansyah, M. Mustikasari, and A. Suroso, "Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 6, no. 2, pp. 87–92, 2021, doi: <https://doi.org/10.30591/jpit.v6i2.2802>.
- [5] S. Suprihanto, I. Awaludin, M. Fadhil, and M. A. Z. Zulfikor, "Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta," *J. Inform*, vol. 9, no. 2, pp. 116–122, 2022.
- [6] I. Wulandari, H. Yasin, and T. Widiharih, "Klasifikasi citra digital bumbu dan rempah dengan algoritma convolutional neural network (cnn)," *Jurnal Gaussian*, vol. 9, no. 3, pp. 273–282, 2020, doi: <https://doi.org/10.14710/j.gauss.9.3.273-282>.
- [7] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Trans Neural Netw Learn Syst*, vol. 33, no. 12, pp. 6999–7019, Dec. 2022, doi: [10.1109/TNNLS.2021.3084827](https://doi.org/10.1109/TNNLS.2021.3084827).
- [8] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, "Review of image classification algorithms based on convolutional neural networks," *Remote Sens (Basel)*, vol. 13, no. 22, p. 4712, 2021, doi: <https://doi.org/10.3390/rs13224712>.
- [9] M. Faisal, J.-S. Leu, and J. T. Darmawan, "Model Selection of Hybrid Feature Fusion for Coffee Leaf Disease Classification," *IEEE Access*, vol. 11, pp. 62281–62291, 2023, doi: [10.1109/ACCESS.2023.3286935](https://doi.org/10.1109/ACCESS.2023.3286935).
- [10] M. A. N. Yasin and W. F. Al Maki, "Coffee Plant Disease Classification Using K-Nearest Neighbor," in *2022 10th International Conference on Information and Communication Technology (ICoICT)*, IEEE, Aug. 2022, pp. 240–245. doi: [10.1109/ICoICT55009.2022.9914843](https://doi.org/10.1109/ICoICT55009.2022.9914843).
- [11] V. Jindal, V. Kukreja, A. Bhattacharjee, S. Rana, and S. Mehta, "Agricultural Innovation: Unleashing Federated Learning CNNs on Coffee Leaf Disease Severity Analysis," in *2023 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, IEEE, Nov. 2023, pp. 782–787. doi: [10.1109/ICCCIS60361.2023.10425426](https://doi.org/10.1109/ICCCIS60361.2023.10425426).
- [12] V. A. Tuesta-Monteza, H. I. Mejia-Cabrera, and J. Arcila-Diaz, "CoLeaf-DB: Peruvian coffee leaf images dataset for coffee leaf nutritional deficiencies detection and classification," *Data Brief*, vol. 48, p. 109226, Jun. 2023, doi: [10.1016/j.dib.2023.109226](https://doi.org/10.1016/j.dib.2023.109226).
- [13] L. M. Tassis, J. E. Tozzi de Souza, and R. A. Krohling, "A deep learning approach combining instance and semantic segmentation to identify diseases and pests of coffee leaves from in-field images," *Comput Electron Agric*, vol. 186, p. 106191, Jul. 2021, doi: [10.1016/j.compag.2021.106191](https://doi.org/10.1016/j.compag.2021.106191).
- [14] R. I. Hasan, S. M. Yusuf, M. S. Mohd Rahim, and L. Alzubaidi, "Automated masks generation for coffee and apple leaf infected with single or multiple diseases-based color analysis approaches," *Inform Med Unlocked*, vol. 28, p. 100837, 2022, doi: [10.1016/j.imu.2021.100837](https://doi.org/10.1016/j.imu.2021.100837).
- [15] M. Kumari, V. Kukreja, A. Raj, and S. K. Chaudhary, "Coffee Leaf Diseases Classification: A CNN and Random Forest Approach for Precision Diagnosis," in *2024 International Conference on Automation and Computation (AUTOCOM)*, IEEE, Mar. 2024, pp. 210–214. doi: [10.1109/AUTOCOM60220.2024.10486169](https://doi.org/10.1109/AUTOCOM60220.2024.10486169).
- [16] A. S. Vellaichamy, A. Swaminathan, C. Varun, and K. S., "MULTIPLE PLANT LEAF DISEASE CLASSIFICATION USING DENSENET-121 ARCHITECTURE," *INTERNATIONAL JOURNAL OF ELECTRICAL ENGINEERING AND TECHNOLOGY*, vol. 12, no. 5, May 2021, doi: [10.34218/IJEET.12.5.2021.005](https://doi.org/10.34218/IJEET.12.5.2021.005).
- [17] W. W. Kusuma, R. R. Isnanto, and A. Fauzi, "Analisis Perbandingan Model CNN VGG16 dan DenseNet121 Menggunakan Kerangka Kerja TensorFlow untuk Deteksi Jenis Hewan," *Jurnal Teknik Komputer*, vol. 1, no. 4, pp. 141–147, 2023, doi: <https://doi.org/10.14710/jtk.v1i4.37009>.
- [18] A. Agustina, "KLASIFIKASI PENYAKIT TANAMAN PADI MENGGUNAKAN METODE CNN ARSITEKTUR DENSENET121 DAN AUGMENTASI DATA," *KLASIFIKASI PENYAKIT TANAMAN PADI MENGGUNAKAN METODE CNN ARSITEKTUR DENSENET121 DAN AUGMENTASI DATA*, vol. 8, no. 1, 2024.
- [19] M. Y. Ismail, A. Sunyoto, and A. Purwanto, "Klasifikasi Penyakit Alzheimer pada Citra Medis Magnetic Resonance Images dengan Arsitektur DenseNet121," *Jurnal Ilmiah Komputasi*, vol. 23, no. 2, Jun. 2024, doi: [10.32409/jikstik.23.2.3600](https://doi.org/10.32409/jikstik.23.2.3600).



- [20] X. Zhang, X. Chen, W. Sun, and X. He, “Vehicle Re-Identification Model Based on Optimized DenseNet121 with Joint Loss.,” *Computers, Materials & Continua*, vol. 67, no. 3, 2021, doi: 10.32604/cmc.2021.016560.
- [21] C. Schröder, F. Kruse, and J. M. Gómez, “A Systematic Literature Review on Applying CRISP-DM Process Model,” *Procedia Comput Sci*, vol. 181, pp. 526–534, 2021, doi: 10.1016/j.procs.2021.01.199.
- [22] J. S. Saltz, “CRISP-DM for Data Science: Strengths, Weaknesses and Potential Next Steps,” in *2021 IEEE International Conference on Big Data (Big Data)*, IEEE, Dec. 2021, pp. 2337–2344. doi: 10.1109/BigData52589.2021.9671634.
- [23] D. Putri Ayuni, Jasril, M. Irsyad, F. Yanto, and S. Sanjaya, “AUGMENTASI DATA PADA IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK ARSITEKTUR EFFICIENTNET-B3 UNTUK KLASIFIKASI PENYAKIT DAUN PADI,” *ZONAsi: Jurnal Sistem Informasi*, vol. 5, no. 2, pp. 239–249, May 2023, doi: 10.31849/zn.v5i2.13874.