

Klasifikasi Penyakit Tanaman Mangga Menggunakan Citra Daun Dengan Pendekatan Transfer Learning Efficientnet-B0

Muhammad Raihan*, Cindi Wulandari, Rusdiyanto, Rudi Kurniawan

Fakultas Ilmu Teknik, Program Studi Informatika, Universitas Bina Insan, Lubuklinggau, Indonesia

Email: ¹*raihansty@gmail.com, ²cindi_wulandari@univbinainsan.ac.id, ³rusdiyanto@univbinainsan.ac.id,

⁴rudi.kurniawan@univbinainsan.ac.id

Email Penulis Korespondensi: raihansty@gmail.com

Abstrak—Penyakit pada tanaman mangga merupakan salah satu faktor yang dapat menurunkan kualitas dan produktivitas hasil panen. Identifikasi penyakit daun mangga secara manual masih bergantung pada pengamatan visual sehingga berpotensi memerlukan waktu yang lama dan menghasilkan diagnosis yang kurang konsisten. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit tanaman mangga berbasis citra daun menggunakan pendekatan *transfer learning* dengan arsitektur EfficientNet-B0. Dataset yang digunakan terdiri dari delapan kelas, yaitu tujuh jenis penyakit daun mangga dan satu kelas daun sehat. EfficientNet-B0 dimanfaatkan sebagai *feature extractor* dengan bobot pralatih dari ImageNet, kemudian ditambahkan lapisan kustom berupa Batch Normalization, Dense, dan Dropout untuk menyesuaikan kebutuhan klasifikasi. Proses pelatihan dilakukan selama 10 epoch dengan pembagian data ke dalam data latih, validasi, dan uji. Hasil pengujian menunjukkan bahwa model mencapai performa maksimal pada dataset yang digunakan, ditunjukkan oleh nilai akurasi, precision, recall, dan f1-score yang sangat tinggi pada seluruh kelas. Visualisasi prediksi citra individu juga menunjukkan tingkat keyakinan prediksi sebesar 0,91 pada salah satu kelas penyakit. Meskipun hasil tersebut menunjukkan potensi EfficientNet-B0 dalam klasifikasi penyakit daun mangga, capaian performa yang sangat tinggi dalam jumlah epoch yang terbatas mengindikasikan perlunya evaluasi lebih lanjut terhadap kemampuan generalisasi model.

Kata Kunci: Deep Learning; EfficientNet-B0; Klasifikasi Penyakit; Daun Mangga; Confusion Matrix

Abstract—Mango plant disease is one of the factors that can reduce the quality and productivity of the harvest. Manual identification of mango leaf diseases still relies on visual observation, potentially requiring a long time and producing inconsistent diagnoses. This study aims to develop a mango plant disease classification system based on leaf images using a transfer learning approach with the EfficientNet-B0 architecture. The dataset used consists of eight classes, namely seven types of mango leaf diseases and one class of healthy leaves. EfficientNet-B0 is used as a feature extractor with pre-trained weights from ImageNet, then custom layers are added in the form of Batch Normalization, Dense, and Dropout to adjust to classification needs. The training process was carried out for 10 epochs by dividing the data into training, validation, and test data. The test results show that the model achieves maximum performance on the dataset used, indicated by very high accuracy, precision, recall, and f1-score values across all classes. Visualization of individual image predictions also shows a prediction confidence level of 0.91 for one of the disease classes. While these results demonstrate the potential of EfficientNet-B0 in mango leaf disease classification, the very high performance achieved in a limited number of epochs indicates the need for further evaluation of the model's generalization capabilities.

Keywords: Deep Learning; EfficientNet-B0; Disease Classification; Mango Leaves; Confusion Matrix

1. PENDAHULUAN

Dalam perkembangan pesat era digital saat ini, penerapan kecerdasan buatan telah menjadi bagian integral di berbagai bidang kehidupan. Kemajuan teknologi komputasi dan ketersediaan data dalam jumlah besar telah mendorong pemanfaatan kecerdasan buatan untuk menyelesaikan berbagai permasalahan kompleks, termasuk di bidang pertanian [1]. Salah satu cabang penting dari *Artificial Intelligence* yang menunjukkan perkembangan signifikan adalah *Deep Learning*. Metode *Deep Learning* telah banyak dimanfaatkan, khususnya dalam pengolahan citra, karena kemampuannya dalam mengekstraksi fitur-fitur kompleks dari data visual dengan sangat efektif [2]. Dengan kemampuan ini, teknologi deep learning dapat mengenali pola, tekstur, dan karakteristik visual yang sulit diinterpretasikan secara manual oleh manusia [3].

Di Indonesia, mangga termasuk salah satu komoditas buah unggulan yang menempati posisi ketiga dalam kontribusi terhadap total produksi buah nasional setelah pisang dan jeruk, dengan jumlah produksi mencapai 1.627.997 ton atau sekitar 10,07%. Pada rentang waktu 2003–2005, Indonesia berada di peringkat kelima dari sepuluh negara penghasil mangga terbesar di dunia. Secara global, India menjadi produsen mangga terbesar dengan kontribusi sebesar 38,58%, disusul oleh China sebesar 12,90%, Thailand sebesar 6,20%, Meksiko sebesar 5,50%, dan Indonesia dengan kontribusi sekitar 5,29% dari total produksi mangga dunia [4]. Untuk menjaga produktivitas tanaman mangga, kualitas dan kesehatan komponennya harus dipelihara dengan baik. Namun, serangan hama dan penyakit pada daun mangga masih menjadi permasalahan utama yang menyebabkan penurunan hasil panen serta kualitas buah, sehingga berdampak pada nilai jual dan pendapatan petani.

Identifikasi penyakit yang masih dilakukan secara manual membuat petani kesulitan dalam melakukan diagnosis yang tepat [5]. Gejala penyakit yang memiliki kemiripan visual sering menimbulkan kesalahan dalam penanganan, sementara keterbatasan pengetahuan dan akses teknologi ikut memperparah kondisi tersebut. Keterlambatan dalam mendeteksi penyakit berpotensi meningkatkan tingkat kerusakan tanaman dan menimbulkan kerugian yang signifikan secara ekonomi.

Beberapa penelitian sebelumnya telah mengembangkan sistem klasifikasi penyakit daun mangga menggunakan berbagai metode, seperti Convolutional Neural Networks (*VGG16*, *InceptionV3*) yang berhasil mencapai akurasi tinggi

pada dataset penyakit daun mangga 4000 citra, namun memiliki jumlah parameter yang besar dan kebutuhan komputasi tinggi yang kurang ideal untuk perangkat dengan sumber daya terbatas[5]. Selain itu, pendekatan lain menggunakan arsitektur ringan seperti *MobileNetV2* menunjukkan hasil yang baik yaitu akurasi sebesar 90%, tetapi masih memerlukan optimasi lebih lanjut untuk mendukung aplikasi real-time di lapangan[6]. Oleh karena itu, penelitian ini memilih *EfficientNet-B0* untuk menyeimbangkan efisiensi komputasi dan performa klasifikasi yang tinggi, sehingga lebih sesuai untuk implementasi praktis di perangkat *mobile* yang akan digunakan oleh petani.

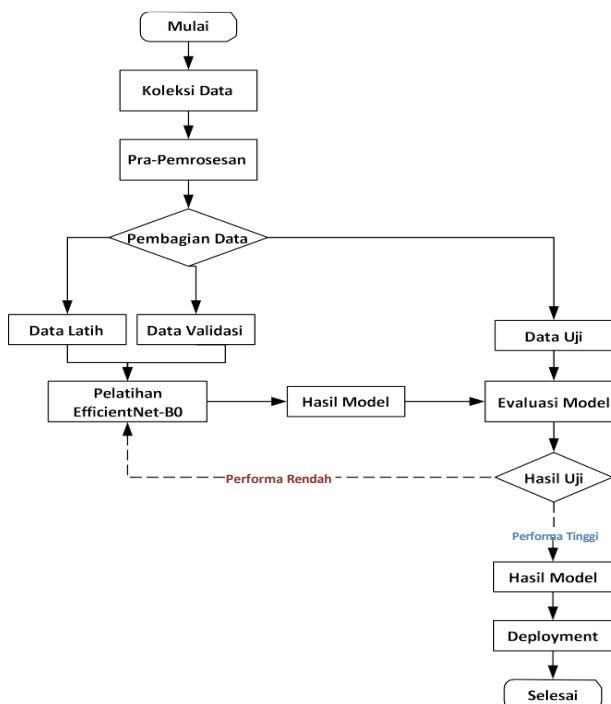
Sebagai solusi, teknologi berbasis kecerdasan buatan dapat digunakan untuk membantu deteksi penyakit daun mangga secara cepat dan akurat [7]. Penelitian ini menerapkan pendekatan *transfer learning* dengan arsitektur *EfficientNet-B0*, yang dikenal memiliki efisiensi komputasi dan akurasi yang baik dalam klasifikasi citra [8]. Sehingga memungkinkan klasifikasi penyakit dan penanganan yang lebih tepat waktu.

Beberapa penelitian terkini mendukung pendekatan ini. Misalnya, dalam tinjauan sistematis pada deteksi penyakit daun secara otomatis menggunakan deep learning, terbukti bahwa model CNN dan transfer learning menawarkan deteksi penyakit tanaman dengan akurasi tinggi dan potensi penerapan nyata dalam pertanian presisi [9]. Penelitian lain pada tanaman mangga membuktikan bahwa pendekatan CNN dengan citra daun mampu mengidentifikasi penyakit secara efektif dengan akurasi yang signifikan [10]. Selain itu, penerapan deep learning pada tanaman lain seperti kentang, padi, dan tanaman hias juga menunjukkan hasil yang menjanjikan [11]. Meskipun demikian, keberhasilan sistem sangat dipengaruhi oleh keberagaman dataset, teknik *preprocessing*, dan kemampuan generalisasi model terhadap kondisi lapangan[12]. Oleh karena itu, penggunaan *EfficientNet-B0* dengan *transfer learning* diharapkan mampu menjawab tantangan tersebut.

Dengan demikian, penelitian ini berupaya menerapkan pendekatan modern deep learning untuk klasifikasi penyakit daun mangga secara otomatis. Harapannya, sistem ini dapat menjadi alat bantu yang efektif bagi petani dalam pengelolaan tanaman, meningkatkan produktivitas, dan mendukung praktik pertanian yang lebih efisien dan berkelanjutan.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode klasifikasi citra berbasis pembelajaran mendalam (*deep learning*). Pendekatan ini dipilih karena tujuan penelitian adalah untuk melakukan klasifikasi penyakit tanaman mangga berdasarkan citra daun menggunakan metode *transfer learning* dengan arsitektur *EfficientNet-B0*. Model dikembangkan untuk mengklasifikasikan citra daun mangga ke dalam beberapa kelas penyakit secara otomatis berdasarkan pola visual yang terdapat pada gambar. Gambar 1 merupakan langkah-langkah penelitian meliputi:



Gambar 1. Alur Penelitian

2.1 Data Collection

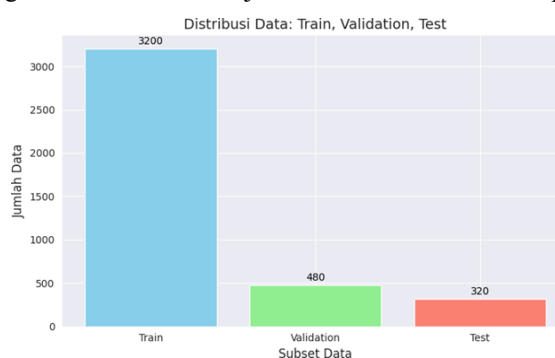
Dataset diambil pada *website* penyedia dataset publik yaitu *Kaggle* dengan nama *Mango Leaf Disease Dataset*. *Dataset* tersebut berjumlah 4000 data. Jumlah kelas sebanyak 8 (delapan) antara lain: *Anthracoese*, *Bacterial Canker*, *Cutting Weevil*, *Die Back*, *Gall Midge*, *Healthy*, *Powdery Mildew*, dan *Sooty Mould*.

2.2 Preprocessing data

Preprocessing data merupakan tahapan awal yang sangat penting dalam proses pengolahan citra digital sebelum data digunakan untuk pelatihan model deep learning[13]. Perbedaan ukuran dan kualitas citra perlu disesuaikan agar data lebih mudah diproses oleh model[14]. Pada penelitian ini, seluruh citra diubah ukurannya menjadi 224×224 piksel menggunakan parameter *target_size* pada ImageDataGenerator dan dilakukan normalisasi dengan membagi nilai piksel dengan 255 sehingga berada pada rentang $[0,1]$ untuk mempercepat konvergensi pelatihan. Namun, *ImageDataGenerator* belum dimanfaatkan untuk menerapkan teknik *data augmentation*, sehingga variasi data pelatihan masih berasal dari dataset asli tanpa transformasi tambahan.

2.3 Split Data

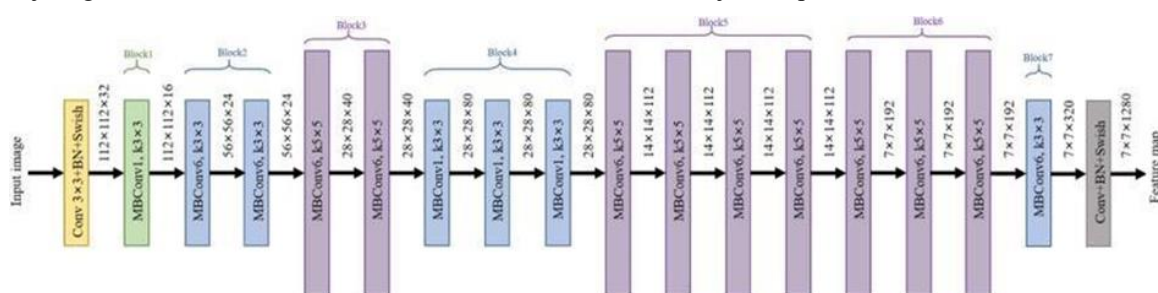
Dataset umumnya dibagi ke dalam *training set*, *validation set*, dan *test set* untuk memastikan proses pelatihan dan evaluasi model deep learning dilakukan secara objektif serta menghindari kebocoran data[15]. Pembagian ini bertujuan agar performa model dapat dievaluasi menggunakan data yang tidak terlibat dalam proses pembelajaran[16]. Pada penelitian ini, dataset berjumlah 4.000 citra dibagi ke dalam tiga subset, yaitu data latih sebanyak 3.200 sampel 80%, data validasi sebanyak 480 sampel 12%, dan data uji sebanyak 320 sampel 8%. Pembagian ini memberikan proporsi data yang cukup untuk pelatihan sekaligus memungkinkan evaluasi kinerja model selama dan setelah proses pelatihan.



Gambar 2. Split Data

2.4 Arsitektur EfficientNet-B0

Arsitektur EfficientNet-B0 merupakan model *deep learning* berbasis *Convolutional Neural Network* (CNN) yang dirancang untuk menghasilkan performa tinggi dengan jumlah parameter yang relatif kecil[17]. Metode CNN terbukti unggul dalam tugas klasifikasi citra karena kemampuannya mengekstraksi fitur visual secara hierarkis dari data gambar [17]. EfficientNet menerapkan pendekatan *compound scaling* sehingga mampu menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara efisien. Ilustrasi arsitektur EfficientNet-B0 ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur EfficientNet-B0

Dalam penelitian ini, EfficientNet-B0 digunakan sebagai *base model* melalui pendekatan *transfer learning* dengan memanfaatkan bobot pralatih dari dataset ImageNet. Lapisan klasifikasi bawaan dihapus agar model berfungsi sebagai *feature extractor*, kemudian ditambahkan lapisan kustom untuk menyesuaikan kebutuhan klasifikasi penyakit tanaman mangga. Deskripsi arsitektur model beserta jumlah parameter pada setiap lapisan disajikan pada Tabel 1, sedangkan konfigurasi pelatihan model ditampilkan pada Tabel 2.

Tabel 1. Deskripsi Model EfficientNet-B0

Layer	Output Shape	Parameters
efficientnetb0 (Functional)	(None, 1280)	4,049,571
Batch_normalization (BatchNormalization)	(None, 1280)	5,120
dense (Dense)	(None, 256)	327,936
dropout (Dropout)	(None, 256)	0
Dense 1 (Dense)	(None, 8)	2,056

Tabel 2. Konfigurasi Pelatihan Model

Komponen	Konfigurasi
Optimizer	Adamax
Learning Rate	0,001
Loss Function	Categorical Crossentropy
Metrics	Accuracy
Jumlah Epochs	10
Batch Size	16

a. EfficientNetB0 Functional

Model *EfficientNetB0* digunakan sebagai fitur ekstraktor, yang telah dilatih sebelumnya (*pre-trained*) pada dataset besar seperti *ImageNet*. Lapisan ini mengekstrak fitur penting dari gambar daun mangga, seperti pola bercak, perubahan warna, atau tekstur yang menjadi indikator penyakit. *Output* fitur berdimensi (1280) mencakup representasi mendalam dari karakteristik daun.

b. BatchNormalization

Lapisan normalisasi memastikan distribusi data fitur yang stabil, membantu model mempelajari pola penyakit seperti *Anthracoze*, *Bacterial Canker*, *Powdery Mildew*, dan lainnya dengan lebih efektif.

c. Dense Layer (256 neurons)

Lapisan padat pertama mereduksi dimensi fitur dan memungkinkan model mempelajari kombinasi fitur yang lebih spesifik untuk membedakan antara jenis penyakit pada daun mangga.

d. Dropout

Teknik dropout diterapkan untuk mencegah overfitting, terutama karena variasi gambar daun bisa signifikan, seperti perbedaan pencahayaan, posisi, atau ukuran daun.

e. Dense Layer (8 neurons)

Lapisan terakhir memiliki 8 neuron, yang sesuai dengan jumlah kelas penyakit daun mangga, termasuk *Healthy* (sehat). *Output* ini merepresentasikan probabilitas bahwa gambar daun termasuk dalam salah satu dari delapan kelas, seperti *Anthracoze*, *Bacterial Canker*, *Cutting Weevil*, *Die Back*, *Gall Midge*, *Powdery Mildew*, *Sooty Mould*, atau daun sehat.

Dengan memanfaatkan arsitektur ini, diharapkan model mampu mengklasifikasikan penyakit daun mangga secara akurat berdasarkan pola visual yang ditangkap oleh *EfficientNetB0*.

2.5 Evaluasi

Dalam penelitian ini, performa model dievaluasi dengan menggunakan *Confussion Matrix*. *Confusion matrix* adalah salah satu metode pengukuran keputusan yang paling banyak digunakan dalam supervised machine learning [18]. *Confusion matrix* memvisualisasikan nilai tingkat kebingungan dari algoritma pada setiap kelas yang berbeda dan tidak tergantung pada algoritma klasifikasi. Evaluasi dengan *confusion matrix* menghasilkan nilai akurasi, presisi dan *recall* [19]. Nilai akurasi adalah persentase ketepatan *record* data yang diklasifikasikan secara benar setelah dilakukan pengujian pada hasil klasifikasi. Presisi atau *confidence* merupakan proporsi kasus yang diprediksi positif yang juga hasilnya positif benar pada data yang sebenarnya. *Recall* atau *sensitivity* adalah proporsi kasus positif yang sebenarnya yang diprediksi positif secara benar [20]. Secara berurutan perhitungan akurasi, presisi, recall dan f-1 score dapat dilihat pada persamaan (1), (2), (3) dan (4).

a. Akurasi, rasio dari prediksi benar terhadap keseluruhan data

$$Akurasi = \frac{(TP + TN)}{TP + TN + FP + FN} \times 100\% \quad (1)$$

b. Presisi, rasio benar positif terhadap keseluruhan prediksi positif

$$Presisi = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

c. Recall, rasio benar positif terhadap keseluruhan data yang benar positif

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

d. F-1 Score, perbandingan rata-rata presisi dan recall yang telah dibobotkan

$$F - 1 \text{ Score} = \frac{2 \times recall \times presisi}{Recall + Presisi} \quad (4)$$

3. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini diperoleh dari situs penyedia dataset publik Kaggle dengan nama Mango Leaf Disease Dataset. Dataset ini terdiri dari 4.000 citra daun mangga yang terbagi ke dalam 8 (delapan) kelas, yaitu *Anthracoze*, *Bacterial Canker*, *Cutting Weevil*, *Die Back*, *Gall Midge*, *Healthy*, *Powdery Mildew*, dan *Sooty Mould*.

Seluruh citra merepresentasikan kondisi daun mangga dengan variasi gejala penyakit yang berbeda dan digunakan sebagai dasar dalam proses pelatihan dan pengujian model klasifikasi.

Pada eksperimen ini, proses melatih model pembelajaran mendalam menggunakan dataset penyakit tanaman mangga selama 10 *epoch*. Tujuan dari pelatihan ini adalah untuk meningkatkan akurasi model dalam mengklasifikasikan data dengan benar, sambil meminimalkan nilai *loss*, yang mengindikasikan seberapa baik model menyesuaikan diri terhadap data pelatihan. Hasil pelatihan dapat dilihat pada Gambar 4.

```

batch_size = 16
epochs = 10

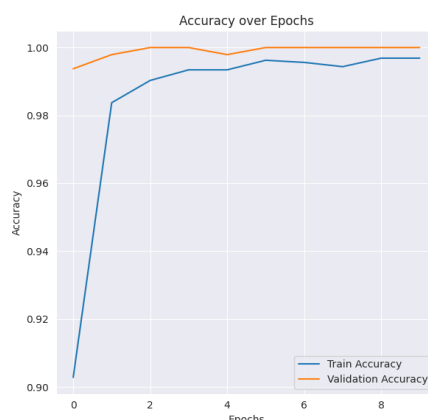
history = model.fit(x= train_gen, epochs= epochs, verbose= 1, validation_data= valid_gen,
                    validation_steps= None, shuffle= False)

Epoch 1/10
200/200 — 1508s 7s/step - accuracy: 0.7826 - loss: 0.6784 - val_accuracy: 0.9937 - val_loss: 0.0204
Epoch 2/10
200/200 — 18s 92ms/step - accuracy: 0.9796 - loss: 0.0592 - val_accuracy: 0.9979 - val_loss: 0.0026
Epoch 3/10
200/200 — 19s 95ms/step - accuracy: 0.9914 - loss: 0.0268 - val_accuracy: 1.0000 - val_loss: 0.0017
Epoch 4/10
200/200 — 19s 89ms/step - accuracy: 0.9903 - loss: 0.0298 - val_accuracy: 1.0000 - val_loss: 1.6383e-04
Epoch 5/10
200/200 — 19s 93ms/step - accuracy: 0.9911 - loss: 0.0220 - val_accuracy: 0.9979 - val_loss: 0.0023
Epoch 6/10
200/200 — 19s 95ms/step - accuracy: 0.9963 - loss: 0.0112 - val_accuracy: 1.0000 - val_loss: 4.6681e-04
Epoch 7/10
200/200 — 18s 90ms/step - accuracy: 0.9963 - loss: 0.0123 - val_accuracy: 1.0000 - val_loss: 5.9685e-04
Epoch 8/10
200/200 — 18s 89ms/step - accuracy: 0.9954 - loss: 0.0147 - val_accuracy: 1.0000 - val_loss: 3.1325e-04
Epoch 9/10
200/200 — 18s 90ms/step - accuracy: 0.9942 - loss: 0.0107 - val_accuracy: 1.0000 - val_loss: 4.0718e-05
Epoch 10/10
200/200 — 19s 95ms/step - accuracy: 0.9977 - loss: 0.0064 - val_accuracy: 1.0000 - val_loss: 2.8040e-05

```

Gambar 4. Hasil Pelatihan Model EfficientNet-B0

Berdasarkan hasil pelatihan selama 10 *epoch*, model menunjukkan performa yang sangat tinggi dan stabil, khususnya pada lima *epoch* terakhir. Akurasi validasi mencapai nilai 100% secara konsisten, yang menunjukkan bahwa model mampu mengenali seluruh sampel pada data validasi dengan benar. Capaian ini mengindikasikan efektivitas arsitektur EfficientNet-B0 dalam mengekstraksi fitur citra daun mangga. Namun demikian, nilai akurasi yang sangat tinggi ini juga mengindikasikan potensi *overfitting*, mengingat variasi data yang digunakan masih terbatas dan belum diterapkan teknik *data augmentation*. Akurasi pelatihan berada pada rentang 99,42% hingga 99,77%, yang menunjukkan bahwa model mampu mengklasifikasikan sebagian besar data pelatihan dengan sangat baik. Fluktuasi kecil pada akurasi pelatihan, khususnya penurunan pada *epoch* keempat, menunjukkan adanya penyesuaian bobot selama proses konvergensi, namun tidak berdampak signifikan terhadap stabilitas model secara keseluruhan. Dari sisi nilai *loss*, *training loss* berada pada rentang 0,0064 hingga 0,0147, sedangkan *validation loss* memiliki nilai yang sangat kecil, yaitu antara $4,6681e-04$ hingga $2,8040e-05$, dengan tren yang terus menurun. Nilai *loss* yang rendah menunjukkan bahwa kesalahan prediksi model sangat minimal baik pada data pelatihan maupun validasi. Meskipun demikian, nilai *validation loss* yang sangat kecil juga mengindikasikan bahwa model berpotensi mempelajari pola yang terlalu spesifik terhadap dataset yang digunakan. Secara keseluruhan, hasil pelatihan menunjukkan bahwa model EfficientNet-B0 memiliki kemampuan yang sangat baik dalam mempelajari pola citra daun mangga pada dataset penelitian ini. Grafik akurasi pelatihan dan validasi ditampilkan pada Gambar 5.

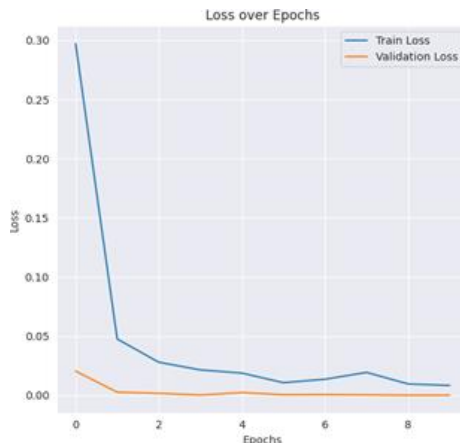


Gambar 5. Hasil Akurasi Pelatihan

Dari analisis kurva, terlihat bahwa model mengalami peningkatan akurasi pelatihan yang sangat cepat pada awal pelatihan, dimulai dari sekitar 90% pada *epoch* pertama, kemudian meningkat pesat hingga mencapai 98% pada *epoch* kedua, dan terus mengalami peningkatan bertahap hingga mendekati 99.7% pada *epoch* terakhir. Hal ini menunjukkan bahwa pendekatan *transfer learning* memungkinkan model untuk belajar secara efektif dalam jumlah *epoch* yang relatif singkat.

Akurasi validasi sejak awal pelatihan juga berada pada nilai yang tinggi dan mencapai 100% dalam beberapa *epoch* awal, kemudian stabil hingga akhir pelatihan. Perbedaan yang sangat kecil antara akurasi pelatihan dan validasi

menunjukkan bahwa model mampu menyesuaikan bobot dengan baik terhadap data yang diberikan, meskipun hal ini juga dapat dipengaruhi oleh keterbatasan variasi data. Untuk grafik loss dari pelatihan dapat dilihat pada gambar 6.



Gambar 6. Hasil Kesalahan Pelatihan


Berdasarkan Gambar 6, terlihat bahwa *loss* pelatihan mengalami penurunan yang signifikan pada epoch awal, dari sekitar 0,30 pada epoch pertama menjadi kurang dari 0,05 pada epoch kedua. Selanjutnya, *loss* terus menurun secara bertahap hingga mendekati nol pada epoch terakhir. Pola ini menunjukkan bahwa model dengan cepat mempelajari representasi fitur yang relevan dan mampu meminimalkan kesalahan prediksi.

Setelah melakukan proses pelatihan atau *training*, model ini akan diujikan dengan data *testing* dengan *classification report* seperti terlihat pada gambar 7.

	precision	recall	f1-score	support
Anthracnose	1.00	1.00	1.00	37
Bacterial Canker	1.00	1.00	1.00	36
Cutting Weevil	1.00	1.00	1.00	30
Die Back	1.00	1.00	1.00	43
Gall Midge	1.00	0.98	0.99	46
Healthy	1.00	1.00	1.00	43
Powdery Mildew	1.00	1.00	1.00	42
Sooty Mould	0.98	1.00	0.99	43
accuracy			1.00	320
macro avg	1.00	1.00	1.00	320
weighted avg	1.00	1.00	1.00	320

Gambar 7. Hasil Classification Report

Berdasarkan metrik evaluasi utama yaitu precision, recall, dan f1-score, model menunjukkan hasil yang sangat baik, dengan sebagian besar nilai mencapai 1.00, menandakan bahwa model mampu mengklasifikasikan semua kategori dengan tingkat kesalahan yang sangat rendah. Selain itu, hasil *confusion matrix* yang ditampilkan pada Gambar 8 menunjukkan bahwa sebagian besar prediksi berada pada diagonal utama, yang mengindikasikan kesesuaian yang tinggi antara label prediksi dan label sebenarnya.



Gambar 8. Hasil Confusion Matrix

Untuk melengkapi evaluasi kuantitatif tersebut, penelitian ini juga menampilkan contoh hasil prediksi model dalam bentuk visual citra daun mangga. Setiap citra uji ditampilkan bersama dengan label kelas hasil prediksi serta nilai *confidence score* yang merepresentasikan tingkat keyakinan model terhadap prediksi yang dihasilkan. Sebagai contoh dapat dilihat pada Gambar 9.

Powdery Mildew (Confidence: 0.91)



Gambar 9. Visualisasi hasil prediksi model EfficientNet-B0

Model memprediksi salah satu citra daun sebagai kelas *Powdery Mildew* dengan nilai *confidence* sebesar 0,91 yang menunjukkan bahwa model memiliki tingkat keyakinan yang tinggi dalam mengklasifikasikan citra tersebut. Visualisasi hasil prediksi ini memberikan gambaran intuitif mengenai kemampuan model dalam mengenali pola visual pada citra daun dan memperkuat hasil evaluasi yang diperoleh dari metrik kuantitatif.

Hasil ini menunjukkan bahwa arsitektur EfficientNet-B0 sangat efektif dalam menangkap pola visual pada citra daun mangga. Namun demikian, mengingat belum diterapkannya teknik *data augmentation* dan terbatasnya jumlah epoch pelatihan, penelitian ini masih memiliki keterbatasan dalam menguji kemampuan generalisasi model terhadap variasi data yang lebih kompleks. Oleh karena itu, penerapan *data augmentation* dan evaluasi pada dataset yang lebih beragam direkomendasikan untuk penelitian selanjutnya.

4. KESIMPULAN

Penelitian ini mengembangkan sistem klasifikasi penyakit tanaman mangga berbasis citra daun menggunakan pendekatan *transfer learning* dengan arsitektur EfficientNet-B0 dan menunjukkan kinerja yang sangat tinggi pada dataset yang digunakan. Evaluasi melalui grafik akurasi dan *loss*, *classification report*, serta *confusion matrix* menunjukkan bahwa model mampu mempelajari pola visual penyakit daun mangga secara efektif pada ruang data penelitian ini, dengan tingkat kesalahan klasifikasi yang sangat rendah. Namun demikian, capaian performa maksimal yang diperoleh pada data pelatihan dan pengujian secara bersamaan berpotensi mengindikasikan adanya kemiripan karakteristik antara data latih dan data uji, sehingga kemampuan generalisasi model terhadap data di luar distribusi penelitian masih perlu diuji lebih lanjut. Visualisasi hasil prediksi juga menunjukkan bahwa model mampu memberikan prediksi kelas penyakit dengan tingkat keyakinan yang tinggi, ditunjukkan oleh nilai *confidence score* sebesar 0,91 pada salah satu contoh citra uji. Oleh karena itu, meskipun EfficientNet-B0 menunjukkan potensi yang baik sebagai pendekatan awal dalam klasifikasi penyakit tanaman mangga berbasis kecerdasan buatan, penelitian lanjutan disarankan untuk menggunakan dataset yang lebih besar dan bervariasi, menerapkan teknik *data augmentation*, serta melakukan pengujian pada kondisi dunia nyata guna meningkatkan keandalan dan kemampuan generalisasi sistem.

REFERENCES

- [1] E. A. Apriadi *et al.*, *KECERDASAN BUATAN Teori, Implementasi, dan Aplikasi di Era Digital*. Eko Aziz Apriadi, 2025.
- [2] M. Munadi, "Penerapan Algoritma Deep Learning untuk Deteksi Dini Penyakit dari Citra Medis," *Journal of Computer Science and Information Technology*, vol. 1, no. 2, pp. 53–59, 2025, doi: 10.70716/jocsit.v1i2.259.
- [3] H. Listiani, S. N. Asia, S. Sepriano, and L. Judijanto, *Deep Learning: Konsep, Arsitektur, dan Implementasi*. PT. Sonpedia Publishing Indonesia, 2025.
- [4] R. M. Ardiyanti, N. Maryana, and P. Pudjianto, "Keanekaragaman lalat buah (Diptera: Tephritidae) dan parasitoidnya di Taman Buah Mekarsari, Cileungsi, Bogor," *J. Entomol. Indones.*, vol. 16, no. 2, p. 65, 2019, doi: 10.5994/jei.16.2.65.
- [5] R. C. Simangunsong and M. Muhathir, "MobileNetV2 Analysis in Disease Classification on Mango Leaves," *Journal of Informatics and Telecommunication Engineering*, vol. 8, no. 3, pp. 73–80, 2025, doi: 10.31289/jite.v8i3Spc.14430.
- [6] P. D. Rinanda, D. N. Aini, T. A. Pertiwi, S. Suryani, and A. J. Prakash, "Implementation of Convolutional Neural Network (CNN) for Image Classification of Leaf Disease In Mango Plants Using Deep Learning Approach," *Public Research Journal of Engineering, Data Technology and Computer Science*, vol. 1, no. 2, pp. 56–61, Feb. 2024, doi: 10.57152/predatecs.v1i2.872.

- [7] M. Rizal, V. J. Saputra, D. I. Maulana, F. Budiman, and E. Sugiarto, "Deteksi awal penyakit tanaman berbasis citra daun: studi perbandingan algoritme SVM dan CNN," *IRCS: Integrative Research in Computer Science*, vol. 1, no. 1, pp. 61–76, 2025, [Online]. Available: <https://ritecs.org/journal/index.php/IRCS/article/view/7>
- [8] W. M. Ardana and K. Kusriani, "Optimasi Algoritma Convolutional Neural Network dengan Arsitektur Efficientnet-B0 dan Resnet-50 untuk Klasifikasi Jenis Sampah," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. October, pp. 1274–1286, 2025, doi: 10.57152/malcom.v5i4.2030.
- [9] I. Pacal *et al.*, "A systematic review of deep learning techniques for plant diseases," *Artif. Intell. Rev.*, vol. 57, no. 11, p. 304, 2024, doi: 10.1007/s10462-024-10944-7.
- [10] V. R. Saragih, N. Azizi, A. Atalarais, R. A. Hatmi, and H. Syahputra, "Detection of mango leaf disease using the convolution neural network method," *TEKNOSAINS: Jurnal Sains, Teknologi dan Informatika*, vol. 11, no. 1, Jan. 2024, doi: 10.37373/tekno.v11i1.639.
- [11] A. B. Faqih and D. Avianto, "Identifikasi Penyakit Daun Pada Tanaman Solanaceae Dan Rosaceae Menggunakan Deep Learning," *Jurnal Teknologi Terpadu*, vol. 10, no. 2, pp. 105–116, 2024, doi: 10.54914/jtt.v10i2.1440.
- [12] N. Sulaiya and S. Banerjee, "A Review on Plant Leaf Disease Detection Using CNN Deep Learning Models," *International Journal of Advanced Research and Multidisciplinary Trends (IJARMT)*, vol. 2, no. 1, pp. 642–653, 2025, [Online]. Available: <https://www.ijarnt.com/index.php/j/article/view/260/177>
- [13] A. J. Rozaqi, A. Sunyoto, and M. rudyanto Arief, "Deteksi Penyakit pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network," *Creative Information Technology Journal*, vol. 8, no. 1, pp. 22–31, 2021, doi: 10.24076/citec.2021v8i1.263.
- [14] F. Marpaung, F. Aulia, and R. C. Nabila, "Computer Vision Dan Pengolahan Citra Digital," 2022, *PUSTAKA AKSARA*.
- [15] H. A. Faiq and H. Sabita, "Pengembangan Model Deep Learning Untuk Pengenalan Wajah pada Sistem Keamanan," *Jurnal TEKNIKA*, vol. 18, no. 1, pp. 197–209, 2024, doi: 10.5281/zenodo.10881284.
- [16] N. Hendrastuty, "Penerapan Data Mining Menggunakan Algoritma K-Means Clustering Dalam Evaluasi Hasil Pembelajaran Siswa," *Jurnal Ilmiah Informatika dan Ilmu Komputer (JIMA-ILKOM)*, vol. 3, no. 1, pp. 46–56, 2024, doi: 10.58602/jima-ilkom.v3i1.26.
- [17] W. R. Perdani, R. Magdalena, and N. K. C. Pratiwi, "Deep Learning untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur EfficientNet," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 2, pp. 322–333, 2022, doi: 10.26760/elkomika.v10i2.322.
- [18] K. Kristiawan and A. Widjaja, "Perbandingan Algoritma Machine Learning dalam Menilai Sebuah Lokasi Toko Ritel," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 1, pp. 35–46, 2021, doi: 10.28932/jutisi.v7i1.3182.
- [19] F. R. Valerian, M. Syarif, and D. A. Fatah, "Klasifikasi Tingkat Obesitas Menggunakan Metode Gbm Dan Confusion Matrix," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 2, pp. 2242–2249, 2025, doi: 10.36040/jati.v9i2.13062.
- [20] R. Swastika, S. Mukodimah, F. Susanto, M. Muslihudin, and S. I. P. Adab, *IMPLEMENTASI DATA MINING (Clustering, Association, Prediction, Estimation, Classification)*. Penerbit Adab, 2023.