

Model Deep Learning Berbasis Inception V3 untuk Klasifikasi Penyakit Daun Apel Menggunakan Citra Digital

Khairun Nisa Arifin Nur^{1*}, Anjar Wanto², Agus Perdana Windarto², Solikhun³

¹Magister Informatika, STIKOM Tunas Bangsa, Kota Pematang Siantar, Indonesia

²Magister Informatika, STIKOM Tunas Bangsa, Kota Pematang Siantar, Indonesia

³Teknik Informatika, STIKOM Tunas Bangsa, Kota Pematang Siantar, Indonesia

Email: ^{1,*}khairunnisa@amiktunasbangsa.ac.id, ²anjarwanto@amiktunasbangsa.ac.id, ³agus.perdana@amiktunasbangsa.ac.id, ⁴solikhun@amiktunasbangsa.ac.id

Email Penulis Korespondensi: khairunnisa@amiktunasbangsa.ac.id

Submitted: 17/02/2025; Accepted: 31/05/2025; Published: 31/05/2025

Abstrak—Tanaman apel memiliki nilai ekonomi tinggi, tetapi produktivitasnya sering terganggu oleh penyakit pada daun yang dapat menurunkan kualitas dan hasil panen. Identifikasi penyakit daun apel masih banyak dilakukan secara manual, yang rentan terhadap kesalahan dan memerlukan keahlian khusus. Oleh karena itu, diperlukan metode yang dapat meningkatkan akurasi dan efisiensi klasifikasi penyakit daun apel. Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi penyakit daun apel dengan menerapkan arsitektur *Convolutional Neural Network (CNN) Inception V3*. Metode ini melibatkan pengumpulan citra daun apel yang terinfeksi, preprocessing data, serta pelatihan dan evaluasi model. Hasil penelitian menunjukkan bahwa model *Inception V3* mampu mencapai akurasi sebesar 96%, lebih tinggi dibandingkan metode sebelumnya. Keunggulan utama arsitektur ini terletak pada kemampuannya dalam menangkap fitur dengan berbagai skala secara simultan, sehingga meningkatkan kemampuan model dalam mengenali pola penyakit secara lebih akurat. Dengan hasil ini, penelitian ini berkontribusi dalam pengembangan teknologi deteksi penyakit tanaman berbasis kecerdasan buatan serta memberikan solusi praktis bagi petani dalam meningkatkan produktivitas pertanian apel.

Kata Kunci: CNN; Deteksi Penyakit Tanaman; *Inception V3*; Klasifikasi Penyakit Daun Apel

Abstract—Apple plants have high economic value, but their productivity is often disrupted by leaf diseases that can reduce quality and yield. Apple leaf disease identification is still largely performed manually, which is prone to errors and requires specialized expertise. Therefore, a method is needed to improve the accuracy and efficiency of apple leaf disease classification. This study aims to enhance the accuracy of apple leaf disease classification by implementing the Convolutional Neural Network (CNN) architecture, specifically Inception V3. The method involves collecting images of infected apple leaves, data preprocessing, and model training and evaluation. The results show that the Inception V3 model achieved an accuracy of 96%, which is higher than previous methods. The main advantage of this architecture lies in its ability to capture features at multiple scales simultaneously, improving the model's ability to recognize disease patterns more accurately. With these findings, this study contributes to the development of AI-based plant disease detection technology and provides a practical solution for farmers to enhance apple farming productivity.

Keywords: CNN; Plant Disease Detection; Inception V3; Apple Leaf Disease Classification

1. PENDAHULUAN

Apel merupakan salah satu buah yang memiliki nilai ekonomi tinggi dan banyak dibudidayakan di berbagai negara, termasuk Indonesia [1]. Buah ini memiliki permintaan pasar yang stabil karena kandungan nutrisinya yang kaya serta manfaatnya bagi kesehatan [2]. Namun, produktivitas tanaman apel sering kali terhambat oleh berbagai faktor, salah satunya adalah serangan penyakit pada daun [3]. Statistik menunjukkan bahwa kerugian akibat penyakit tanaman dapat mencapai 20-30% dari total hasil panen, dan dalam beberapa kasus, angka ini dapat lebih tinggi tergantung pada jenis penyakit dan kondisi lingkungan [4]. Penyakit daun apel dapat disebabkan oleh jamur, bakteri, atau virus yang menyerang jaringan daun, sehingga menghambat proses fotosintesis dan menurunkan kualitas serta hasil panen [5]. Jika tidak dideteksi dan dikendalikan secara tepat, penyakit ini dapat menyebabkan kerugian ekonomi yang signifikan bagi petani [6].

Saat ini, identifikasi penyakit daun apel masih banyak dilakukan secara manual oleh petani atau ahli pertanian berdasarkan pengamatan visual [7]. Metode ini memiliki beberapa keterbatasan, seperti ketidakakuratan dalam membedakan jenis penyakit, keterbatasan tenaga ahli di lapangan, serta potensi kesalahan manusia (human error) [8]. Oleh karena itu, diperlukan suatu pendekatan yang mampu mengklasifikasikan penyakit daun apel secara cepat dan akurat untuk membantu petani dalam pengambilan keputusan yang lebih efektif.

Dalam beberapa tahun terakhir, klasifikasi penyakit daun apel telah menarik perhatian signifikan karena implikasinya terhadap produktivitas dan keberlanjutan pertanian. Berbagai metodologi telah diterapkan untuk meningkatkan akurasi dan efisiensi deteksi penyakit, dengan fokus pada pemanfaatan teknik pembelajaran mesin yang canggih. Dengan meninjau berbagai literatur yang relevan, penelitian ini dapat memperoleh landasan teori yang kuat serta menemukan peluang pengembangan guna meningkatkan akurasi dalam klasifikasi penyakit daun apel.

Salah satu studi yang mencolok adalah penelitian tentang "*The Orchard Guard*" menggunakan model MobileNetV2 untuk deteksi penyakit daun apel. Studi ini membandingkan kinerja tiga arsitektur CNN yang berbeda, termasuk MobileNet, Inception V3, dan ResNet-50, mengungkapkan bahwa MobileNetV2 mencapai

akurasi 73,50%, sementara ResNet-50 mengungguli dengan akurasi 77,65% [9]. Ini menunjukkan efektivitas model ringan dalam aplikasi seluler, yang sangat penting untuk penerapan di lapangan.

Selanjutnya, penelitian yang dilakukan oleh Ali mempersembahkan AppleLeafNet, sebuah kerangka kerja pembelajaran mendalam yang ringan dan efisien yang dirancang untuk mendiagnosis penyakit daun apel. Kerangka kerja ini menekankan perlunya model yang efisien yang dapat beroperasi pada perangkat dengan sumber daya terbatas sambil mempertahankan akurasi diagnostik yang tinggi [10].

Lebih lanjut, karya oleh [11], yang menggunakan mekanisme perhatian baru dalam kerangka jaringan saraf konvolusional, lebih lanjut memvalidasi pentingnya perhatian dalam meningkatkan akurasi klasifikasi. Dan yang terakhir penelitian oleh [12] mengimplementasikan teknologi deep learning menggunakan arsitektur MobileNet berbasis transfer learning untuk identifikasi penyakit pada daun tanaman apel.

Penelitian sebelumnya oleh [13] berfokus pada klasifikasi penyakit Daun Apel menggunakan model ResNet50 untuk klasifikasi daun apel menjadi dua kategori (sehat dan busuk). Penelitian ini terbatas pada dua kategori klasifikasi, yang mungkin tidak cukup untuk memberikan gambaran menyeluruh tentang kesehatan daun apel. Dengan hanya mengklasifikasikan menjadi sehat dan busuk, potensi penyakit lain yang mungkin ada tidak terdeteksi. Penelitain Kulsum ini mendapat Akurasi sebesar 91%.

ResNet50 memiliki keunggulan utama dalam menangani masalah vanishing gradient melalui residual learning [14], memungkinkan pelatihan jaringan yang lebih dalam tanpa kehilangan informasi penting [15]. Arsitektur ini sangat baik dalam mempertahankan fitur penting pada gambar dengan menggunakan shortcut connections yang mempercepat konvergensi dan meningkatkan akurasi [8]. Namun, ResNet50 memiliki keterbatasan dalam menangkap fitur dengan berbagai skala karena hanya menggunakan satu ukuran kernel dalam setiap lapisan konvolusinya [16]. Selain itu, model ini cenderung lebih kompleks dan memerlukan daya komputasi yang besar, sehingga kurang efisien untuk aplikasi real-time atau perangkat dengan keterbatasan sumber daya [17].

Dari pembahasan yang telah diuraikan, dapat diidentifikasi suatu permasalahan, yaitu perlunya peningkatan akurasi klasifikasi Penyakit Daun Apel menggunakan Model Arsitektur Inception V3. Inception V3 melengkapi kekurangan ResNet50 dengan pendekatan multi-kernel pada satu lapisan, yang memungkinkan model menangkap fitur dengan berbagai skala secara simultan [18]. Dengan struktur ini, Inception V3 dapat lebih efektif dalam mengenali detail halus maupun pola besar dalam gambar, meningkatkan kemampuan generalisasi model [19]. Selain itu, arsitektur ini dirancang lebih efisien dalam penggunaan komputasi dibandingkan ResNet50, menjadikannya lebih cocok untuk implementasi di perangkat dengan keterbatasan sumber daya [20].

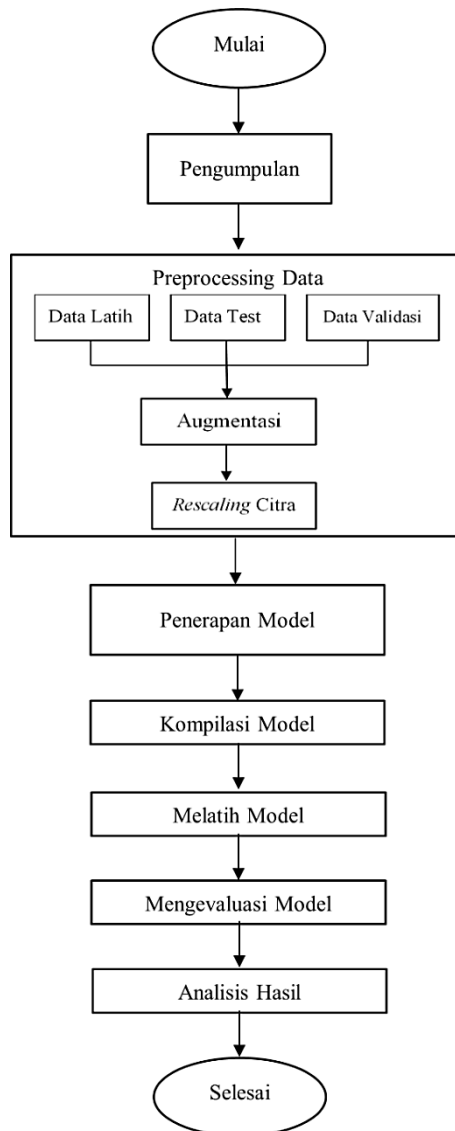
Arsitektur CNN Inception V3 juga dikenal karena kemampuannya dalam menangkap fitur kompleks dari citra dengan efisiensi tinggi [21]. Metode ini akan melibatkan pengumpulan data citra daun apel yang terinfeksi, diikuti dengan preprocessing data untuk meningkatkan kualitas citra sebelum pelatihan model. Dengan menggunakan pendekatan ini, diharapkan dapat dicapai tingkat akurasi yang tinggi dalam klasifikasi penyakit, yang akan memudahkan petani dalam mengambil tindakan cepat untuk mengatasi masalah yang muncul [12], [22].

Tujuan dari penelitian ini adalah untuk menerapkan model klasifikasi penyakit daun apel yang efektif menggunakan arsitektur CNN Inception V3. Penelitian ini diharapkan dapat memberikan manfaat teoritis dalam pengembangan ilmu pengetahuan di bidang pertanian dan teknologi informasi, serta manfaat praktis bagi petani dalam meningkatkan hasil panen dan mengurangi kerugian akibat penyakit. Dengan sistem deteksi yang lebih cepat dan akurat, diharapkan petani dapat melakukan tindakan pencegahan yang lebih baik dan meningkatkan produktivitas pertanian apel secara keseluruhan [23], [24].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan sistematis untuk memastikan bahwa model klasifikasi penyakit daun apel yang dikembangkan memiliki performa optimal. Tahapan pertama adalah pengumpulan data, di mana dataset yang digunakan terdiri dari tiga kategori, yaitu *Apple Rust*, *Apple Healthy*, dan *Apple Black Rot*. Setelah data dikumpulkan, dilakukan *preprocessing* data untuk meningkatkan kualitas input sebelum digunakan dalam proses pelatihan model. Langkah-langkah yang dilakukan dalam preprocessing meliputi pembagian dataset menjadi data pelatihan (70%), data validasi (15%), dan data pengujian (15%), augmentasi citra yang hanya diterapkan pada data pelatihan guna meningkatkan variasi dan ketahanan model, serta normalisasi citra melalui proses rescaling untuk menyamakan skala nilai piksel. Visualisasi tahapan penelitian ini dapat dilihat pada Gambar 1, yang menunjukkan alur proses mulai dari pengumpulan data hingga evaluasi model.



Gambar 1. Alur Penelitian

Selanjutnya, pada Gambar 1 ditunjukkan, setelah preprocessing, penelitian ini memanfaatkan model *pre-trained InceptionV3* sebagai *backbone*. Model ini digunakan tanpa fully connected layer pada bagian akhir dan dimodifikasi dengan menambahkan lapisan *Global Average Pooling* serta lapisan *Dense* yang disesuaikan dengan jumlah kelas dalam dataset. Untuk meningkatkan akurasi, dilakukan *fine-tuning* model dengan cara membekukan lapisan awal *InceptionV3* sehingga hanya lapisan tambahan yang dilatih. Model kemudian dikompilasi menggunakan *optimizer Adam* dan fungsi loss *categorical_crossentropy*, yang sesuai untuk masalah klasifikasi multi-kelas.

Gambar 1 juga menunjukkan proses berikutnya yaitu melatih model, di mana model dilatih menggunakan data pelatihan dan divalidasi menggunakan data validasi untuk memantau performa serta mencegah *overfitting*. Setelah pelatihan selesai, dilakukan evaluasi model dengan menguji model menggunakan data pengujian untuk mengukur akurasi dan *loss*. Hasil evaluasi juga dianalisis melalui *classification report*, yang mencakup metrik evaluasi seperti *precision*, *recall*, dan *f1-score*. Untuk memahami performa model lebih lanjut, dilakukan analisis hasil, yang meliputi visualisasi *confusion matrix* untuk melihat distribusi prediksi model serta grafik akurasi dan *loss* selama proses pelatihan. Dengan mengikuti tahapan penelitian ini secara sistematis, diharapkan model yang dikembangkan mampu melakukan klasifikasi penyakit daun apel dengan tingkat akurasi yang tinggi serta dapat diimplementasikan secara efektif dalam mendeteksi kondisi kesehatan tanaman apel.

2.2 Convolutional Neural Network (CNN)

CNN merupakan arsitektur deep learning yang secara khusus dirancang untuk pengolahan data berbentuk grid seperti citra [25]. CNN mampu mengekstraksi fitur spasial dari citra melalui lapisan konvolusi, aktivasi non-linear, dan pooling secara bertahap [26]. CNN banyak digunakan dalam klasifikasi citra karena kemampuannya menangkap pola visual dengan tingkat akurasi tinggi [27].

2.3 Deteksi Penyakit Tanaman

Deteksi penyakit tanaman berbasis citra digital merupakan pendekatan modern untuk mengidentifikasi penyakit secara otomatis [28]. Citra daun yang menunjukkan gejala penyakit seperti bercak, perubahan warna, atau deformasi dianalisis menggunakan model pembelajaran mesin atau deep learning untuk mengenali jenis penyakit secara akurat.

2.4 Inception V3

Inception V3 adalah salah satu model CNN yang dikembangkan oleh Google, dirancang untuk menyeimbangkan efisiensi komputasi dan kedalaman jaringan [29]. Dengan menggunakan struktur ‘network-in-network’, Inception V3 dapat mengekstraksi fitur dari berbagai skala secara bersamaan [30]. Model ini terbukti efektif dalam tugas klasifikasi citra pada berbagai domain, termasuk pertanian dan medis [31].


2.5 Klasifikasi Penyakit Daun Apel

Klasifikasi penyakit daun apel merupakan studi kasus dari tugas klasifikasi citra dalam domain pertanian [32]. Tantangan dalam klasifikasi ini meliputi kemiripan visual antar jenis penyakit dan kondisi pencahayaan pada citra [33]. Dataset dalam penelitian ini terdiri dari tiga kelas utama: Apple Rust, Apple Black Rot, dan Apple Healthy.

2.6 Dataset

Dataset yang digunakan dalam penelitian ini bersumber dari platform Kaggle (<https://www.kaggle.com/datasets/vipoooool/new-plant-diseases-dataset/data>), yang terdiri dari kumpulan gambar daun apel yang diklasifikasikan ke dalam tiga kategori: Apple Rust, Apple Healthy, dan Apple Black Rot. Setiap kategori berisi 300 gambar, sehingga totalnya mencapai 900 gambar. Gambar-gambar ini diambil dalam berbagai kondisi pencahayaan dan sudut yang berbeda untuk meningkatkan keberagaman data. Setelah itu, gambar-gambar tersebut menjalani tahap prapemrosesan untuk memastikan kualitas data sebelum digunakan dalam proses pelatihan dan evaluasi model.

Deteksi penyakit tanaman melalui citra daun merupakan pendekatan modern berbasis visi komputer yang memanfaatkan kecerdasan buatan, terutama dalam mengenali pola visual dari gejala penyakit. Citra daun yang menunjukkan gejala seperti bercak, perubahan warna, atau deformasi, dapat menjadi indikator penting dalam diagnosis otomatis penyakit tanaman. Gambar 2 merupakan contoh citra yang digunakan dari masing-masing jenis Penyakit Daun Apel.



Gambar 2. Citra Jenis Penyakit Daun Apel

3. HASIL DAN PEMBAHASAN

3.1 Preprocessing Data

Pada penelitian ini, pengolahan data dilakukan untuk memastikan bahwa data yang digunakan dalam proses pelatihan model memiliki kualitas yang baik dan terstruktur dengan benar. Salah satu langkah penting dalam tahap ini adalah pembagian dataset ke dalam tiga subset utama, yaitu data pelatihan (*training*) sebesar 70%, data validasi (*validation*) sebesar 15%, dan data pengujian (*testing*) sebesar 15%. Pembagian ini bertujuan untuk memastikan model dapat belajar secara optimal dari data pelatihan, dievaluasi selama proses validasi, serta diuji pada data yang belum pernah dilihat sebelumnya guna mengukur performa sebenarnya dari model klasifikasi penyakit daun apel. Detail pembagian data ditunjukkan pada Tabel 1.

Tabel 1. Pembagian Data


No.	Nama Kelas	Pembagian Data	Jumlah
1	<i>Apple Rust</i>	<i>Train (70%)</i>	210
		<i>Test (15%)</i>	45
		<i>Validation (15%)</i>	45

No.	Nama Kelas	Pembagian Data	Jumlah
2	Apple Healthy	Train (70%)	210
		Test (15%)	45
		Validation (15%)	45
3	Apple Black Rot	Train (70%)	210
		Test (15%)	45
		Validation (15%)	45

Tabel 1 menunjukkan pembagian data untuk klasifikasi penyakit daun apel menggunakan arsitektur CNN *Inception V3*. Data terdiri dari tiga kelas: *Apple Rust*, *Apple Healthy*, dan *Apple Black Rot*, masing-masing dengan total 300 sampel. Data dibagi menjadi tiga subset, yaitu *train* (70%) dengan 210 sampel per kelas untuk pelatihan model, *test* (15%) dengan 45 sampel per kelas untuk menguji performa model setelah pelatihan, dan *validation* (15%) dengan 45 sampel per kelas untuk menyempurnakan model selama proses pelatihan guna menghindari *overfitting*. Pembagian ini memastikan bahwa model mendapatkan cukup data untuk belajar sekaligus memiliki dataset terpisah untuk evaluasi kinerja.

3.2 Augmentasi Data

Untuk meningkatkan variasi data, augmentasi dilakukan dengan rotasi, pergeseran lebar/tinggi, zoom, dan flipping secara horizontal pada data latih. Data validasi dan uji hanya dilakukan rescaling tanpa augmentasi. Metode ini memungkinkan model untuk mengidentifikasi pola visual dari berbagai perspektif dan variasi sambil tetap mempertahankan konteks visual [34]. Proses augmentasi dilakukan menggunakan pustaka TensorFlow atau Keras. Gambar 3 merupakan contoh ilustrasi augmentasi data.



Gambar 3. Ilustrasi Augmentasi Data

Gambar 3 memperlihatkan contoh proses augmentasi yang diterapkan pada citra daun apel dengan penyakit Apple Rust. Citra di bagian tengah merupakan citra asli, sedangkan tiga citra di sekitarnya merupakan hasil augmentasi menggunakan beberapa teknik yaitu rotasi, flipping horizontal, zoom, dan translasi. Teknik augmentasi ini digunakan untuk memperbanyak variasi data latih tanpa menambah data baru, sehingga dapat meningkatkan kemampuan model dalam mengenali pola visual dari berbagai sudut pandang dan kondisi yang berbeda.

3.3 Penerapan Model Inception V3

Pada tahap ini, dilakukan implementasi model Convolutional Neural Network (CNN) dengan arsitektur InceptionV3 untuk melakukan klasifikasi citra daun apel ke dalam beberapa kelas penyakit.

3.3.1 Pemanggilan Arsitektur InceptionV3

Model *InceptionV3* dipanggil tanpa bagian *fully connected*-nya (bagian atas atau *top layer*), dengan parameter *include_top=False*, sehingga hanya mengambil bagian *feature extractor*-nya saja. Bobot awal model diambil dari pelatihan pada dataset *ImageNet*.

```
from tensorflow.keras.applications import InceptionV3
base_model = InceptionV3(weights='imagenet', include_top=False)
```

Gambar 4. Pemanggilan Arsitektur *Inception V3*

3.3.2 Penambahan Layer Klasifikasi

Karena bagian atas model tidak disertakan, maka ditambahkan beberapa layer baru di atas *output base_model* untuk menyesuaikan dengan jumlah kelas pada dataset daun apel. Layer yang ditambahkan adalah *GlobalAveragePooling2D*, *Dense* dengan 1024 *neuron*, dan *Dense* akhir sebagai layer klasifikasi dengan aktivasi *softmax*.

```

from tensorflow.keras.layers import Dense, GlobalAveragePooling2D
from tensorflow.keras.models import Model

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
predictions = Dense(len(train_generator.class_indices), activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=predictions)

```

Gambar 5. Penambahan Layer Klasifikasi

3.4 Kompilasi Model

Setelah struktur model disusun, dilakukan proses kompilasi dengan menggunakan optimizer *Adam* dan fungsi *loss categorical_crossentropy* karena target klasifikasi bersifat multi-kelas. *Learning rate* yang digunakan adalah 0.0001.

```

from tensorflow.keras.optimizers import Adam

model.compile(optimizer=Adam(learning_rate=0.0001),
              loss='categorical_crossentropy',
              metrics=['accuracy'])

```

Gambar 6. Kompilasi Model

3.5 Pelatihan Model

Model kemudian dilatih menggunakan data train dan divalidasi menggunakan data validation selama 20 epoch. Data train telah diberikan augmentasi untuk meningkatkan generalisasi model.

```

history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // train_generator.batch_size,
    validation_data=val_generator,
    validation_steps=val_generator.samples // val_generator.batch_size,
    epochs=20
)


```

Gambar 7. Pelatihan Model

3.6 Evaluasi Model

3.6.1 Kurva *Loss* dan Akurasi

Kurva *loss* dan akurasi digunakan untuk menganalisis performa model selama proses pelatihan [34]. Kurva ini menunjukkan bagaimana perubahan nilai akurasi dan *loss* pada data latih serta validasi selama 20 *epoch*. Dengan melihat tren kurva, dapat dievaluasi apakah model mengalami *overfitting*, *underfitting*, atau telah mencapai tingkat generalisasi yang optimal. Jika kurva akurasi meningkat secara stabil dan *loss* menurun tanpa perbedaan yang signifikan antara data latih dan validasi, maka model dapat dikatakan memiliki kinerja yang baik. Sebaliknya, jika terdapat selisih besar antara kedua kurva, maka diperlukan optimasi lebih lanjut untuk meningkatkan generalisasi model [35]. Kurva akurasi dan *loss* ditunjukkan pada Gambar 4.


Gambar 8. Kurva *Loss* dan Akurasi

Berdasarkan kurva akurasi dan loss yang ditunjukkan pada Gambar 4, model menunjukkan performa yang baik selama proses pelatihan. Pada kurva *loss* (grafik kiri), terlihat bahwa nilai *train loss* dan *validation loss* mengalami penurunan secara bertahap, yang menandakan bahwa model berhasil mempelajari pola dalam data dengan baik. Namun, terdapat sedikit fluktuasi pada *validation loss* setelah epoch ke-10, yang dapat mengindikasikan adanya sedikit *overfitting* meskipun tidak terlalu signifikan.

Sementara itu, pada kurva akurasi (grafik kanan), akurasi model meningkat dengan cepat pada beberapa epoch awal, lalu stabil mendekati nilai >95% setelah sekitar epoch ke-5. Perbedaan antara *train accuracy* dan *validation accuracy* relatif kecil, yang menunjukkan bahwa model memiliki generalisasi yang baik terhadap data uji. Secara keseluruhan, hasil ini menunjukkan bahwa model *InceptionV3* yang digunakan mampu mengklasifikasikan penyakit daun apel dengan tingkat akurasi yang tinggi dan tingkat error yang rendah.

3.6.2 Confussion Matrix

Confussion matrix digunakan untuk mengevaluasi performa model dalam mengklasifikasikan kategori daun apel berdasarkan data uji. Matriks ini memberikan gambaran mengenai jumlah prediksi yang benar dan salah untuk setiap kelas, sehingga dapat membantu dalam mengidentifikasi potensi kesalahan klasifikasi yang terjadi. Dengan melihat distribusi nilai pada *confussion matrix*, dapat dianalisis sejauh mana model mampu membedakan setiap kelas dengan baik serta apakah terdapat kelas tertentu yang sering salah diklasifikasikan [36]. Analisis ini penting untuk memahami kelemahan model dan menentukan strategi perbaikan yang dapat dilakukan. *Confussion matrix* ditunjukkan pada Gambar 5.



Gambar 9. Confussion Matrix

Berdasarkan hasil *confussion matrix*, model menunjukkan performa klasifikasi yang sangat baik dengan tingkat kesalahan yang rendah. Dari total 45 sampel untuk setiap kelas, model mampu mengklasifikasikan sebagian besar data dengan benar.

- Apple Healthy*: 42 sampel diklasifikasikan dengan benar, sedangkan 1 sampel salah diklasifikasikan sebagai *Apple Rust* dan 2 sampel sebagai *Apple Black Rot*.
- Apple Rust*: 44 sampel diklasifikasikan dengan benar, dengan 1 sampel salah diklasifikasikan sebagai *Apple Black Rot*.
- Apple Black Rot*: 44 sampel diklasifikasikan dengan benar, dengan 1 sampel salah diklasifikasikan sebagai *Apple Healthy*.

Kesalahan klasifikasi yang terjadi relatif kecil, menunjukkan bahwa model memiliki akurasi tinggi dan generalisasi yang baik dalam membedakan ketiga kategori daun apel. Namun, adanya beberapa kesalahan menunjukkan bahwa karakteristik visual antara beberapa kategori masih memiliki kemiripan, sehingga kemungkinan model mengalami sedikit ambiguitas dalam membedakan beberapa sampel tertentu. Untuk lebih meningkatkan performa, bisa dilakukan optimasi lebih lanjut seperti fine-tuning model atau augmentasi data tambahan. Selanjutnya, Gambar 6 menampilkan *Classification Report*, yang menyajikan metrik evaluasi termasuk akurasi, presisi, recall, dan F1-score.

Classification Report:				
	precision	recall	f1-score	support
Apple__healthy	0.98	0.93	0.95	45
Apple__rust	0.98	0.98	0.98	45
Apple__black_rot	0.94	0.98	0.96	45
accuracy			0.96	135
macro avg	0.96	0.96	0.96	135
weighted avg	0.96	0.96	0.96	135

Gambar 10. *Classification Report*

Berdasarkan hasil *classification report* yang ditunjukkan pada Gambar 6, model menunjukkan performa klasifikasi yang sangat baik dengan akurasi keseluruhan sebesar 96%. Nilai precision, recall, dan f1-score untuk setiap kelas juga tergolong tinggi, yang menandakan bahwa model mampu mengklasifikasikan data dengan baik.

- Apple Healthy* memiliki *precision* 0.98, *recall* 0.93, dan *f1-score* 0.95, menunjukkan bahwa meskipun model sangat akurat dalam mengidentifikasi kelas ini, terdapat beberapa sampel yang salah diklasifikasikan ke kelas lain.
- Apple Rust* memperoleh *precision* 0.98, *recall* 0.98, dan *f1-score* 0.98, yang menandakan model mampu mengenali kelas ini dengan sangat baik.
- Apple Black Rot* memiliki *precision* 0.94, *recall* 0.98, dan *f1-score* 0.96, menunjukkan bahwa meskipun *recall* tinggi, *precision* sedikit lebih rendah dibanding kelas lainnya, yang berarti ada beberapa kasus di mana model salah mengklasifikasikan kelas lain sebagai *Apple Black Rot*.

Secara keseluruhan, nilai *macro average* dan *weighted average* sebesar 0.96 menunjukkan bahwa model memiliki keseimbangan performa yang baik dalam mengenali setiap kelas. Namun, terdapat sedikit kesalahan klasifikasi yang dapat dioptimalkan lebih lanjut, misalnya dengan fine-tuning model, peningkatan jumlah data latih, atau teknik augmentasi data untuk meningkatkan generalisasi model.

3.7 Pembahasan Hasil Penelitian

Model *Inception V3* yang digunakan dalam penelitian ini menunjukkan performa yang sangat baik dengan akurasi mencapai 96%. Kurva akurasi dan loss menunjukkan peningkatan performa yang stabil selama pelatihan, dengan sedikit fluktuasi pada *validation loss* setelah *epoch* ke-10. Analisis confusion matrix menunjukkan bahwa model mampu mengklasifikasikan sebagian besar sampel dengan benar, meskipun terdapat beberapa kesalahan klasifikasi antara kategori yang memiliki karakteristik visual mirip. *Classification report* juga menunjukkan nilai *precision*, *recall*, dan *f1-score* yang tinggi, menandakan keseimbangan performa model dalam mengenali setiap kelas.

Dibandingkan dengan penelitian sebelumnya yang menggunakan *ResNet50* dan hanya mampu mengklasifikasikan dua kategori dengan akurasi 91%, model *Inception V3* memberikan peningkatan yang signifikan dalam akurasi dan jumlah kategori yang dapat dikenali. Keunggulan *InceptionV3* dalam menangkap fitur dari berbagai skala memungkinkan klasifikasi yang lebih akurat. Meskipun demikian, penelitian ini masih memiliki keterbatasan dalam membedakan sampel dengan karakteristik visual yang sangat mirip. Untuk meningkatkan performa lebih lanjut, dapat dilakukan optimasi melalui fine-tuning, penambahan jumlah data latih, serta augmentasi data agar model dapat lebih baik dalam menangani variasi sampel di lapangan.

4. KESIMPULAN

Berdasarkan hasil penelitian mengenai klasifikasi penyakit daun apel menggunakan arsitektur *Convolutional Neural Network (CNN) Inception V3*, diperoleh temuan bahwa model yang dikembangkan mampu mencapai akurasi tinggi dalam mengklasifikasikan tiga jenis daun apel, yaitu *Apple Healthy*, *Apple Rust*, dan *Apple Black Rot*. Model ini menunjukkan performa yang sangat baik dengan akurasi sebesar 96% pada data uji. Keberhasilan ini menegaskan bahwa pendekatan *transfer learning* dengan *Inception V3* dapat menghasilkan model yang andal meskipun dataset yang digunakan memiliki keterbatasan dalam jumlah sampel. Selain itu, hasil evaluasi menggunakan confusion matrix menunjukkan bahwa sebagian besar sampel diklasifikasikan dengan benar, dengan hanya sedikit kesalahan klasifikasi. Hal ini menunjukkan bahwa fitur yang diekstraksi oleh model cukup representatif dalam membedakan setiap kelas penyakit daun apel. Analisis lebih lanjut melalui *classification report* juga memperlihatkan nilai *precision*, *recall*, dan *f1-score* yang berkisar antara 0.94 hingga 0.98, yang menandakan keseimbangan yang baik antara kemampuan model dalam mengenali setiap kelas dengan akurat serta meminimalkan kesalahan klasifikasi. Visualisasi kurva akurasi dan *loss* selama proses pelatihan menunjukkan tren peningkatan yang stabil tanpa indikasi *overfitting* yang signifikan, yang semakin menguatkan efektivitas model yang dikembangkan. Meskipun hasil yang diperoleh cukup baik, penelitian ini masih memiliki

beberapa keterbatasan. Salah satu kekurangan yang ditemukan adalah masih adanya kesalahan klasifikasi pada beberapa sampel dengan karakteristik visual yang mirip, yang menunjukkan bahwa model belum sepenuhnya sempurna dalam membedakan semua variasi penyakit daun apel. Selain itu, penggunaan dataset yang terbatas dapat memengaruhi generalisasi model terhadap sampel baru. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penggunaan dataset yang lebih besar dan beragam untuk meningkatkan kemampuan model dalam menangani variasi visual yang lebih luas. Selain itu, eksplorasi metode augmentasi data atau penggunaan arsitektur deep learning lainnya juga dapat menjadi langkah perbaikan untuk lebih meningkatkan akurasi dan ketahanan model dalam menghadapi data baru.

REFERENCES

- [1] D. G. F. Sagitarian *et al.*, “Biodiversity of edible fruit sold at Pasar Gede, Surakarta City, Central Java, Indonesia,” *Asian J. Agric.*, vol. 7, no. 1, pp. 57–68, 2023, doi: 10.13057/asianjagric/g070108.
- [2] Y. G. Akyereko, G. B. Yeboah, F. D. Wireko-Manu, F. Alemawor, F. C. Mills-Robertson, and W. Odoom, “Nutritional value and health benefits of cashew apple,” *JSAFA reports*, vol. 3, no. 3, pp. 110–118, 2023, doi: 10.1002/jsf2.107.
- [3] B. Xing, D. Wang, and T. Yin, “The Evaluation of the Grade of Leaf Disease in Apple Trees Based on PCA-Logistic Regression Analysis,” *Forests*, vol. 14, no. 7, 2023, doi: 10.3390/f14071290.
- [4] C. A. Bradley *et al.*, “Soybean Yield Loss Estimates Due to Diseases in the United States and Ontario, Canada, from 2015 to 2019,” *Plant Heal. Prog.*, vol. 22, no. 4, pp. 483–495, 2021, doi: 10.1094/PHP-01-21-0013-RS.
- [5] S. Manzoor *et al.*, “Comparative biochemical and physiological responses to the virus - induced mosaic disease in apple (*Malus domestica*),” *J. Plant Dis. Prot.*, no. July, 2024, doi: 10.1007/s41348-024-00974-2.
- [6] A. Sulaiman *et al.*, “Sustainable Apple Disease Management Using an Intelligent Fine-Tuned Transfer Learning-Based Model,” *Sustain.*, vol. 15, no. 17, 2023, doi: 10.3390/su151713228.
- [7] A. Ahmad, D. Saraswat, and A. El, “A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools,” *Smart Agric. Technol.*, vol. 3, no. June 2022, p. 100083, 2023, doi: 10.1016/j.atech.2022.100083.
- [8] M. M. Adnan, M. Shafry, M. Rahim, A. R. Khan, S. Member, and A. Alkhayyat, “Automated Image Annotation With Novel Features Based on Deep ResNet50-SLT,” *IEEE Access*, vol. 11, no. April, 2023, doi: 10.1109/ACCESS.2023.3266296.
- [9] S. J. Banarase, S. Shirbahadurkar, S. Cience, and T. Echnology, “Orchard Guard : Deep Learning powered apple leaf disease detection with MobileNetV2 model,” *J. Integr. Sci. Technol.*, vol. 12, no. 4, pp. 1–8, 2024, doi: 10.54216/jcim.060779.
- [10] M. U. Ali, M. Khalid, M. Farrash, H. F. M. Lahza, A. Zafar, and S. H. Kim, “AppleLeafNet: a lightweight and efficient deep learning framework for diagnosing apple leaf diseases,” *Front. Plant Sci.*, vol. 15, no. November, pp. 1–12, 2024, doi: 10.3389/fpls.2024.1502314.
- [11] H. Cheng and H. Li, “Identification of apple leaf disease via novel attention mechanism based convolutional neural network,” *Front. Plant Sci.*, vol. 14, no. October, pp. 1–11, 2023, doi: 10.3389/fpls.2023.1274231.
- [12] O. N. Abada *et al.*, “KOMPARASI PENGGUNAAN DATA LAB DAN FIELD CONDITION UNTUK MEMBANGUN MODEL KLASIFIKASI PENYAKIT PADA DAUN APEL,” *J. Mhs. Tek. Inform.*, vol. 7, no. 4, pp. 2910–2915, 2023, doi: 10.54216/jmti.06779.
- [13] U. Kulsum and A. Cherid, “Penerapan Convolutional Neural Network Pada Klasifikasi Tanaman Menggunakan ResNet50,” *Simkom*, vol. 8, no. 2, pp. 221–228, 2023, doi: 10.51717/simkom.v8i2.191.
- [14] F. M. Talaat, S. El Sappagh, K. Alnowaiser, and E. Hassan, “Improved prostate cancer diagnosis using a modified ResNet50 - based deep learning architecture,” *BMC Med. Inform. Decis. Mak.*, vol. 0, pp. 1–14, 2024, doi: 10.1186/s12911-024-02419-0.
- [15] L. Zhang, Y. Bian, P. Jiang, and F. Zhang, “A Transfer Residual Neural Network Based on ResNet-50 for Detection of Steel Surface Defects,” *Appl. Sci.*, vol. 13, no. 9, 2023, doi: 10.3390/app13095260.
- [16] J. Hou, H. Zhou, J. Hu, H. Yu, and H. Hu, “A Multi-Scale Convolution and Multi-Layer Fusion Network for Remote Sensing Forest Tree Species Recognition,” *Remote Sens.*, vol. 15, no. 19, 2023, doi: 10.3390/rs15194732.
- [17] H. Nugroho, J. X. Chew, S. Eswaran, and F. S. Tay, “Resource - optimized cnns for real - time rice disease detection with ARM cortex - M microprocessors,” *Plant Methods*, 2024, doi: 10.1186/s13007-024-01280-6.
- [18] H. Sun *et al.*, “Multi-kernel inception aggregation diffusion network for tomato disease detection,” *BMC Plant Biol.*, vol. 24, no. 1, 2024, doi: 10.1186/s12870-024-05797-9.
- [19] Y. Kumaran S, J. J. Jeya, R. Mahesh T, S. B. Khan, S. Alzahrani, and M. Alojail, “Explainable lung cancer classification with ensemble transfer learning of VGG16, Resnet50 and InceptionV3 using grad-cam,” *BMC Med. Imaging*, vol. 24, no. 1, pp. 1–19, 2024, doi: 10.1186/s12880-024-01345-x.

- [20] S. R. Shah *et al.*, “Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50 : A Case Study on Early Detection of a Rice Disease,” *agronomy*, pp. 1–13, 2023, doi: <https://doi.org/10.3390/agronomy13061633>.
- [21] Y. Pan *et al.*, “Fundus image classification using Inception V3 and ResNet-50 for the early diagnostics of fundus diseases,” *Front. Physiol.*, no. February, pp. 1–9, 2023, doi: 10.3389/fphys.2023.1126780.
- [22] M. I. Fathur Rozi, N. O. Adiwijaya, and D. I. Swasono, “Identifikasi Kinerja Arsitektur Transfer Learning Vgg16, Resnet-50, Dan Inception-V3 Dalam Pengklasifikasian Citra Penyakit Daun Tomat,” *J. Ris. Rekayasa Elektro*, vol. 5, no. 2, p. 145, 2023, doi: 10.30595/jrre.v5i2.18050.
- [23] M. Rahman, Asriyanik, and A. Pambudi, “Identifikasi Citra Daun Selada Dalam Menentukan Kualitas Tanaman Menggunakan Algoritma Convolutional Neural Network (CNN),” *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 3, pp. 2830–7062, 2023, doi: 10.23960/jitet.v11i3.s1.3438.
- [24] R. Ronggo, B. Pratomo, and P. Palupingsih, “Analisis Perbandingan Performa Model Klasifikasi Kesehatan Daun Tomat menggunakan Arsitektur VGG , MobileNet , dan Inception V3 Analysis Tomato Leaf Health Classification Model Performance Comparison Using VGG , MobileNet , and Inception V3,” *J. Ilmu Komput. Agri Inform.*, vol. 10, pp. 98–110, 2023.
- [25] D. Billi *et al.*, “Machine Learning and Deep Learning for the Built Heritage Analysis: Laser Scanning and UAV-Based Surveying Applications on a Complex Spatial Grid Structure,” *Remote Sens.*, vol. 15, no. 8, 2023, doi: 10.3390/rs15081961.
- [26] M. Taye and M. Mustafa, “Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions,” *Computation*, vol. 11, no. 3, 2023, doi: 10.3390/computation11030052.
- [27] A. A. Elngar *et al.*, “Image Classification Based On CNN: A Survey,” *J. Cybersecurity Inf. Manag.*, vol. 6, no. 1, p. PP. 18-50, 2021, doi: 10.54216/jcim.060102.
- [28] A. V. Panchal, S. C. Patel, K. Bagyalakshmi, P. Kumar, I. R. Khan, and M. Soni, “Image-based Plant Diseases Detection using Deep Learning,” *Mater. Today Proc.*, vol. 80, no. July, pp. 3500–3506, 2023, doi: 10.1016/j.matpr.2021.07.281.
- [29] K. Sachin, V. P. Singh, S. Pal, and P. Jaiswal, “Energy-efficient model ‘denseNet201 based on deep convolutional neural network’ using cloud platform for detection of COVID-19 infected patients,” *Epidemiol. Method.*, vol. 12, no. 1, pp. 1–14, 2023, doi: 10.1515/em-2021-0047.
- [30] W. Yu, P. Zhou, S. Yan, and X. Wang, “InceptionNeXt: When Inception Meets ConvNeXt,” *IEEE Access*, pp. 5672–5683, 2023, doi: 10.1109/CVPR52733.2024.00542.
- [31] M. Dutta, D. Gupta, Y. Gulzar, M. S. Mir, C. W. Onn, and A. B. Soomro, “Leveraging Inception V3 for Precise Early and Late Blight Disease Classification in Potato Crops,” *Trait. du Signal*, vol. 41, no. 2, pp. 705–715, 2024, doi: 10.18280/ts.410213.
- [32] F. N. Al-Wesabi, A. A. Albraikan, A. M. Hilal, M. M. Eltahir, M. A. Hamza, and A. S. Zamani, “Artificial intelligence enabled apple leaf disease classification for precision agriculture,” *Comput. Mater. Contin.*, vol. 70, no. 3, pp. 6223–6238, 2022, doi: 10.32604/cmc.2022.021299.
- [33] A. Bhargava, A. Shukla, O. P. Goswami, M. H. Alsharif, P. Uthansakul, and M. Uthansakul, “Plant Leaf Disease Detection, Classification, and Diagnosis Using Computer Vision and Artificial Intelligence: A Review,” *IEEE Access*, vol. 12, no. February, pp. 37443–37469, 2024, doi: 10.1109/ACCESS.2024.3373001.
- [34] T. Kumar, R. O. B. Brennan, S. Member, A. Mileo, and M. Bendecheche, “Image Data Augmentation Approaches : A Comprehensive Survey and Future Directions,” *IEEE Access*, vol. 12, no. December, 2024, doi: 10.1109/ACCESS.2023.3266296.
- [35] H. A. O. Li, G. K. Rajbahadur, D. Lin, Z. M. Jiang, and S. Member, “Keeping Deep Learning Models in Check : A History-Based Approach to Mitigate Overfitting,” *IEEE Access*, vol. 12, no. March, pp. 70676–70689, 2024, doi: 10.1109/ACCESS.2024.3402543.
- [36] S. Farhadpour, T. A. Warner, and A. E. Maxwell, “Selecting and Interpreting Multiclass Loss and Accuracy Assessment Metrics for Classifications With Class Imbalance: Guidance and Best Practices,” *Remote Sens.*, vol. 16, no. 3, p. 533, 2024, doi: 10.3390/rs16030533.