

# KLASIFIKASI PENYAKIT BUAH KAKAO BERBASIS CITRA MENGGUNAKAN TRANSFER LEARNING DENGAN MODEL MOBILENETV2

Anna Adelia Sari<sup>\*1</sup>, Nurhikma Arifin<sup>1</sup>, Chairi Nur Insani<sup>1</sup>

<sup>1</sup>Program Studi Informatika, Fakultas Teknik, Universitas Sulawesi Barat, Majene, Indonesia

Penulis korespondensi: Anna Adelia Sari (adheliaanna8@gmail.com)

*Kakao merupakan komoditas unggulan Indonesia yang produktivitasnya kerap menurun akibat serangan hama dan penyakit. Penelitian ini mengembangkan model identifikasi otomatis penyakit kakao berbasis Transfer Learning MobileNetV2 yang ringan untuk deteksi real-time. Dataset sebanyak 405 citra empat kelas: black pod rot 108, healthy 106, helopeltis 100, dan pod borer 91, dibagi 70% training 10% validation, dan 20% testing. Pada tahap pelatihan, diterapkan augmentasi data meliputi RandomFlip, Random Rotation, RandomZoom, dan RandomTranslation guna memperbanyak variasi visual sampel. Konfigurasi pelatihan menggunakan optimizer Adam, batch size 32, random seed 45, serta teknik early stopping. Penelitian menguji variasi learning rate (0.001, 0.0001) dan epoch (30, 50, 70, 100), menghasilkan performa terbaik pada learning rate 0,0001 dengan 70 epoch. Model mencapai akurasi pengujian 92,86%, presisi 92,78%, recall 92,86%, dan F1-score 92,79%. Hasil ini menunjukkan MobileNetV2 mampu mengenali ciri penyakit secara konsisten, sehingga sangat potensial menjadi dasar aplikasi diagnostik lapangan yang cepat dan akurat bagi petani kakao.*

**Kata Kunci** - Deep Learning, Kakao, Klasifikasi, MobileNetV2, Transfer Learning.

## I. PENDAHULUAN

Kakao (*Theobroma cacao*) merupakan salah satu komoditas perkebunan penting yang berperan besar bagi perekonomian Indonesia, baik sebagai sumber pendapatan petani maupun penyumbang devisa [1], [2]. Berdasarkan data International Cocoa Organization (ICCO) tahun 2023, Indonesia berada dalam jajaran empat besar produsen kakao dunia dan menjadi yang terbesar di Asia. Kedudukan ini mencerminkan potensi besar sektor kakao Indonesia untuk terus dikembangkan pada masa mendatang. Meskipun demikian, produksi kakao nasional pada tahun 2023 mengalami penurunan sebesar 2,84% dari tahun sebelumnya, dan sangat bergantung pada perkebunan rakyat [2].

Meskipun memiliki potensi besar, produksi kakao nasional sering terhambat oleh serangan hama dan penyakit. Penyakit pada buah kakao merupakan faktor utama yang dapat mengakibatkan penurunan produksi

secara signifikan [3]. Secara spesifik, di dua desa fokus penelitian, kerugian terbesar disebabkan oleh Black Pod Rot, Penggerek Buah Kakao (*Pod Borer*), dan *Helopeltis* (Hama Penghisap Buah). Tingkat kerusakan dari ketiga masalah ini sulit diidentifikasi dan dibedakan gejalanya pada tahap awal oleh petani. Kendala utamanya adalah kebanyakan petani, terutama di wilayah terpencil, sering kesulitan dalam mengenali dan membedakan jenis penyakit atau hama kakao secara akurat akibat keterbatasan pengetahuan. Akibatnya, tindakan penanganan yang dilakukan sering kali tidak tepat atau terlambat, yang memperparah kerugian dan menurunkan kualitas hasil panen [4].

Untuk mengatasi keterbatasan petani dalam identifikasi penyakit, pemanfaatan teknologi klasifikasi citra berbasis *Deep Learning* menawarkan solusi yang objektif, akurat, dan cepat, jaringan saraf tiruan convolutional neural network (CNN) telah terbukti efektif dalam mengenali pola visual penyakit tanaman [5], [6], termasuk kakao [1]. Penelitian yang dilakukan oleh Diarra Mamadou dkk. melanjutkan penelitian deteksi penyakit buah kakao dengan fokus pada pendekatan hybrid, dengan menggabungkan ekstraksi fitur dari *MobileNetV2* dengan klasifikasi menggunakan algoritma Machine Learning. Kombinasi *MobileNetV2*-SVM terbukti paling efisien dengan mencapai akurasi tertinggi 86,04% [7]. Gado & Primandari mengembangkan sistem klasifikasi penyakit buah kakao berbasis Android menggunakan *Transfer Learning* dengan arsitektur *NASNet-Mobile*, dataset yang digunakan terdiri dari 2000 citra dengan empat kelas (Black Pod, *Helopeltis* sp, Pod Borer, dan Normal), model ini menunjukkan kinerja yang tinggi dengan akurasi uji (testing) 94,88% [4]. F. T. P. Aji mengembangkan identifikasi penyakit buah kakao menggunakan arsitektur CNN, Penelitian ini mengklasifikasikan lima kelas: kepik penghisap buah, penggerek buah kakao, busuk buah, antraknosa, dan buah sehat, dengan total 250 citra yang dibagi menjadi 60% data latih, 20% validasi, dan 20% data uji, model CNN berhasil mencapai akurasi rata-rata 98% [8]. A. G. Kadek Rizki Ariawan, dkk. membandingkan kinerja model DenseNet-121 dan *MobileNetV2* dalam klasifikasi citra penyakit buah kakao, kedua model diimplementasikan menggunakan teknik *Transfer Learning*, hasil pengujian menunjukkan bahwa model *DenseNet-121* memberikan

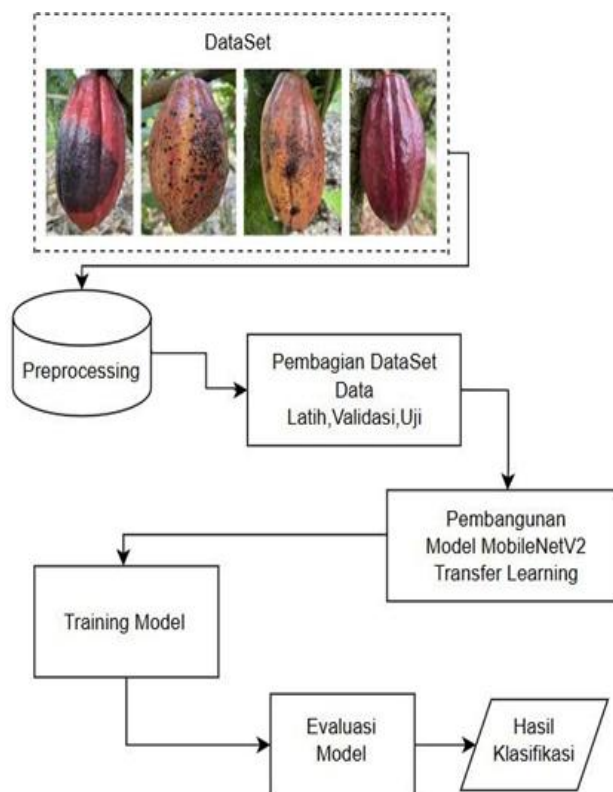
hasil klasifikasi terbaik dengan nilai akurasi 99,69%, precision 99,69%, dan recall 99,69%, yang sedikit lebih unggul dibandingkan dengan *MobileNetV2* [9].

Selain berfokus pada klasifikasi penyakit buah kakao, arsitektur *MobileNetV2* yang dikenal karena efisiensi dan desain ringannya telah banyak diterapkan dan menunjukkan kinerja yang unggul pada klasifikasi penyakit di berbagai jenis komoditas tanaman lain, seperti penelitian yang dilakukan oleh Oddy Virgantara Putra, dkk. membandingkan lima arsitektur *Transfer Learning* (*MobileNetV2*, *NasNet Mobile*, *EfficientNet B7*, *Inception V3*, *VGG 16*) serta model Simple CNN untuk klasifikasi penyakit dan hama pada tanaman padi, penelitian ini menemukan bahwa *MobileNetV2* mencapai akurasi terbaik sebesar 97,5% [10]. Firmansyah mengimplementasikan *Transfer Learning* dengan arsitektur *MobileNetV2* untuk mendeteksi penyakit pada daun bawang merah, penelitian ini mampu mencapai akurasi sebesar 87,1% [11]. Sella Lestari melakukan analisis komparatif antara arsitektur *MobileNetV1* dan *MobileNetV2* untuk klasifikasi sepuluh jenis penyakit pada tanaman tomat. Hasil penelitian menunjukkan bahwa *MobileNetV2* mencapai akurasi lebih tinggi sebesar 97,76% dibandingkan dengan *MobileNetV1* (96,36%) [12]. Rahmad Gunawan, dkk. melakukan klasifikasi penyakit pada daun kentang dengan menggunakan *Transfer Learning* dan optimalisasi arsitektur *MobileNetV2*. Berdasarkan hasil klasifikasi menunjukkan performa tinggi dengan akurasi 95,31%, presisi 95,81%, recall 95,31%, dan F1-Score 95,38% [13].

Implementasi arsitektur CNN pada penelitian sebelumnya telah membuktikan akurasi yang tinggi dalam klasifikasi penyakit buah kakao [8]. Selain itu, metode *Transfer Learning* yang memanfaatkan arsitektur *MobileNetV2* juga menunjukkan kinerja unggul pada komoditas pertanian lain [11]. Oleh karena itu, penelitian ini berfokus pada penerapan *Transfer Learning* dengan *MobileNetV2* untuk klasifikasi empat kategori penyakit dan hama buah kakao yaitu: Sehat (*Healthy*), *Black Pod Rot*, Penggerek Buah Kakao (*Pod Borer*), dan *Helopeltis*. Diharapkan, hasil penelitian ini dapat memberikan solusi deteksi yang akurat, cepat, dan efisien bagi petani dalam penanganan penyakit buah kakao.

## II. METODE PENELITIAN

Penelitian ini bertujuan untuk melakukan klasifikasi penyakit pada buah kakao menggunakan metode Deep Learning dengan arsitektur *MobileNetV2*. “Penelitian ini dimulai dengan menggunakan dataset citra buah kakao, selanjutnya melakukan pre-processing. Dataset yang telah diproses kemudian dibagi menjadi data latih, data validasi, dan data uji. Kemudian dilanjutkan dengan melakukan pelatihan data menggunakan arsitektur CNN *MobileNet V2* dengan pendekatan *Transfer Learning*, tahap terakhir melakukan evaluasi model dengan menggunakan confusion matrix untuk mengetahui tingkat *accuracy*, *precision*, *recall* dan *f1-score*. Alur metodologi penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Metode Klasifikasi

### A. Dataset

Data gambar yang digunakan dalam penelitian ini diperoleh melalui metode pengumpulan data primer. Data primer tersebut mencakup citra buah kakao yang diambil secara langsung di dua lokasi perkebunan, yaitu di Desa Riso, Kecamatan Tapango, Kabupaten Polewali Mandar, Sulawesi Barat, serta di Dusun Talongga, Desa Seppong, Kecamatan Tammerodo Sendana, Kabupaten Majene, Provinsi Sulawesi Barat. Proses pengambilan citra dilakukan dengan mendokumentasikan kondisi buah kakao sesuai kategori yang diteliti, dengan total 405 citra yang berhasil dikumpulkan. Dataset tersebut terdiri dari empat kategori, yaitu buah kakao sehat (*healthy*) serta buah kakao yang mengalami gangguan penyakit seperti *Black Pod Rot*, *Pod Borer*, dan *Helopeltis*.

### B. Preprocessing Data

Tahap *preprocessing* data dilakukan untuk menyeragamkan format citra sebelum proses pelatihan model. Seluruh citra dikonversi ke format RGB dan diubah ukurannya menjadi  $224 \times 224$  piksel agar sesuai dengan input model. Selanjutnya, dilakukan normalisasi nilai piksel dengan membagi setiap nilai piksel dengan 255 sehingga berada pada rentang 0–1, Selain itu, pada data latih juga diterapkan teknik data augmentation menggunakan beberapa transformasi citra seperti *RandomFlip* (horizontal), *RandomRotation*, *RandomZoom*, dan *RandomTranslation*. Augmentasi data bertujuan untuk meningkatkan kinerja model klasifikasi citra dengan menghasilkan variasi baru dari dataset, memperbanyak sampel pelatihan, serta membantu mengurangi risiko overfitting [14].

C. Pembagian Data

Dataset kemudian dibagi menjadi 70% data latih 10 % data validasi dan 20% data uji. Label kelas dikonversi ke dalam bentuk one-hot encoding untuk mendukung klasifikasi multikelas. Proses *preprocessing* diverifikasi melalui visualisasi citra sebelum dan sesudah preprocessing serta analisis distribusi data.

Tabel 1. Distribusi Data

Nama Kelas	Training set	Validation Set	Testing Set	Total dataset
Black Pod Rot	75	10	23	108
Healthy	74	10	22	106
Helopeltis	70	10	20	100
Pod Borer	63	9	19	91
<b>TOTAL</b>	<b>282</b>	<b>39</b>	<b>84</b>	<b>405</b>

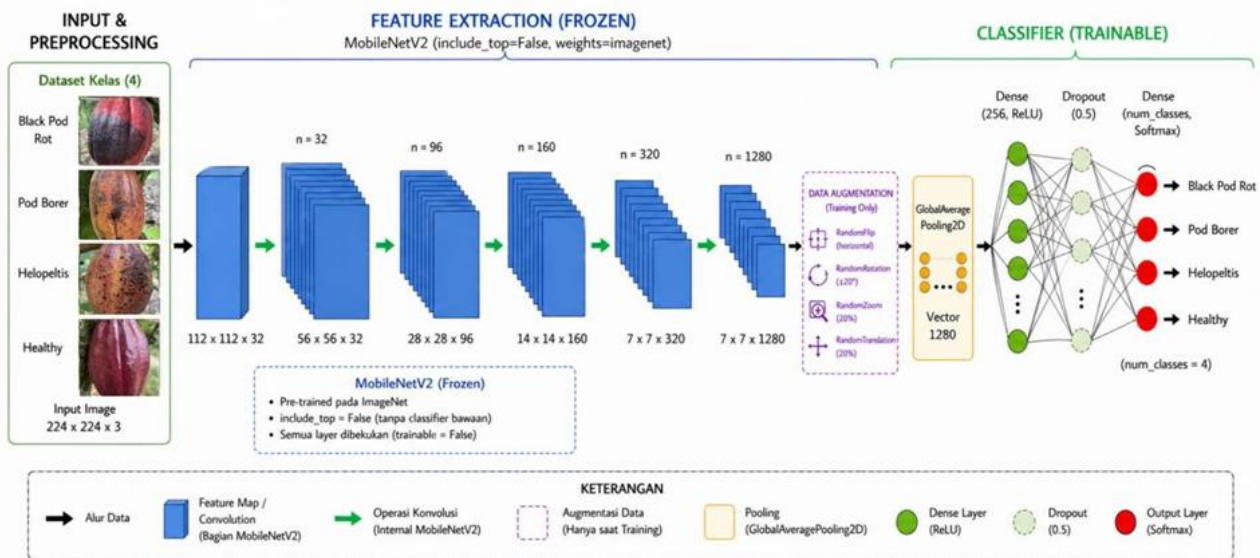
D. MobileNetV2

MobileNetV2 merupakan pengembangan dari mobileNet yang di rancang untuk meningkatkan efisiensi komputasi sekaligus mempertahankan akurasi model. Arsitektur ini memperkenalkan inverted residual block dan linear bottleneck, yang memungkinkan model mempertahankan informasi penting saat dimensi fitur diperkecil. Karakteristiknya yang ringan namun presisi menjadikan MobileNetV2 pilihan utama sebagai model

pre-trained untuk klasifikasi citra pada perangkat seluler maupun sistem pemrosesan real-time [15].

Penelitian ini mengimplementasikan klasifikasi citra menggunakan arsitektur *MobileNetV2* melalui pendekatan *Transfer Learning* berbasis *feature extraction*. Citra input berukuran (224x224x3) di mana nilai 3 mendeskripsikan bahwa citra memiliki 3 buah channel yaitu red, green, dan blue (RGB) diproses oleh base model yang telah dibobot dari *ImageNet* dengan konfigurasi (*include\_top=False*) dan seluruh bobot pada base model dibekukan (*trainable=False*). Pembekuan total ini bertujuan mempertahankan representasi fitur visual yang telah dipelajari dari *ImageNet* sekaligus mencegah *overfitting*. Fitur diekstraksi melalui bottleneck layers berbasis *depthwise separable convolution* (dilengkapi *Batch Normalization* dan *ReLU6*), menghasilkan feature map 7x7x1280. Selama pelatihan, modul augmentasi data diterapkan untuk memperbanyak variasi sampel. Fitur kemudian dikonversi menjadi vektor 1280 dimensi menggunakan *GlobalAveragePooling2D*, sebelum diproses oleh lapisan klasifikasi baru yang terdiri dari *Dense(256, ReLU)*, *Dropout(0.5)*, dan lapisan output *Dense(4, Softmax)* untuk memprediksi empat kelas penyakit kakao, *black pod rot*, *pod borer*, *helopeltis*, dan *healthy*.

Berikut di bawah ini adalah gambaran arsitektur *MobileNetV2*.



Gambar 2. Arsitektur *MobileNetV2*

E. Transfer Learning

*Transfer Learning* merupakan teknik dalam *deep learning* yang memanfaatkan bobot dari model yang telah dilatih sebelumnya pada dataset besar untuk menyelesaikan permasalahan yang berbeda namun masih memiliki kesamaan karakteristik data. Implementasi *Transfer Learning* memungkinkan proses training data pada arsitektur CNN menjadi lebih singkat sekaligus mengoptimalkan akurasi klasifikasi [16]. Pelatihan model pada penelitian ini menggunakan pendekatan *Transfer Learning* dengan model yang digunakan adalah *MobileNetV2*, yang telah melalui proses pelatihan awal menggunakan dataset *ImageNet*. Pendekatan ini dipilih karena dapat meningkatkan efisiensi proses pelatihan model. Hal ini disebabkan model telah memiliki

kemampuan awal dalam mengenali berbagai fitur visual dasar seperti tepi, bentuk, dan tekstur, yang dapat membantu proses identifikasi penyakit [11].

F. Evaluasi Model

Evaluasi model dilakukan untuk mengetahui kinerja model dalam melakukan klasifikasi citra penyakit pada buah kakao. Proses evaluasi dilakukan dengan menggunakan data uji (*test set*) yang tidak digunakan selama proses pelatihan model. Hal ini bertujuan untuk mengukur kemampuan model dalam mengenali data baru yang belum pernah dipelajari sebelumnya. Salah satu metode yang digunakan untuk melakukan evaluasi pada proses klasifikasi adalah *confusion matrix*, yaitu alat yang digunakan untuk menilai tingkat ketepatan maupun

kesalahan prediksi yang dihasilkan oleh suatu algoritma klasifikasi [13].

Pada tahap ini, pengujian model klasifikasi menggunakan adalah *Accuracy*, *Precision*, *Recall* dan *F1-Score*.

Dengan perumusan:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

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

$$F1\ Score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (4)$$

### III. HASIL DAN PEMBAHASAN

Pada penelitian ini dilakukan proses pelatihan dan pengujian model dalam mengidentifikasi empat kelas target, yaitu *pod borer*, *black pod rot*, *helopeltis*, dan *healthy* menggunakan arsitektur *MobileNetV2* untuk klasifikasi penyakit pada buah kakao. Proses penelitian dilakukan dengan pendekatan *Transfer Learning*.

#### A. Analisis Hasil

##### 1. Hasil Pengujian dengan LR 0.001

Pengujian dilakukan dengan variasi jumlah *epoch* (30,50,70 dan 100) dan *learning rate* 0,001. Pengujian ini bertujuan untuk mengidentifikasi apakah peningkatan jumlah iterasi pelatihan dapat meningkatkan kemampuan generalisasi model atau justru menyebabkan *overfitting* dan untuk mengetahui pengaruh parameter tersebut terhadap performa model. Hasil pengujian dapat dilihat pada tabel 2

Tabel 2. Hasil Pengujian dengan LR0.001

Epoch	LR	Train Acc	Val Acc	Test Acc
30	0.001	96,81	87,18	89,29
50	0.001	99,65	89,74	90,48
70	0.001	100	92,31	90,48
100	0.001	100	89,74	90,48

Berdasarkan hasil pengujian pada Tabel 2 dengan *learning rate* 0.001, terlihat bahwa penambahan jumlah *epoch* sebanding dengan peningkatan akurasi pelatihan. Nilai *Train Acc* meningkat secara signifikan dari 96,81% pada *epoch* 30 menjadi 99% pada *epoch* 50 dan mencapai 100% pada *epoch* 70 dan 100. Namun, peningkatan akurasi pelatihan ini tidak diikuti oleh peningkatan yang konsisten pada akurasi validasi dan pengujian. Nilai *Val Acc* menunjukkan fluktuasi dengan puncak tertinggi sebesar 92,31% pada *epoch* 70, namun kemudian menurun menjadi 89,74% pada *epoch* 100. Sementara itu, *Test Acc* hanya meningkat dari 89,29% pada *epoch* 30 menjadi 90,48% pada *epoch* 50, dan stagnan pada nilai yang sama hingga *epoch* 100.

Kondisi ini menunjukkan terjadinya *overfitting* yang mulai muncul setelah *epoch* 50. Hal ini terlihat dari *gap* yang semakin melebar antara *Train Acc* (100%) dan *Test Acc* (90,48%) yang mencapai selisih 9,52% pada *epoch* 70 dan 100, diikuti oleh penurunan *Val Acc* dari 92,31%

(*epoch* 70) menjadi 89,74% (*epoch* 100) meskipun *Train Acc* tetap sempurna. Selain itu, stagnannya nilai *Test Acc* setelah *epoch* 50 menunjukkan bahwa model telah mencapai batas kemampuan generalisasi. Akibatnya, model cenderung menghafal pola data latih secara sempurna setelah *epoch* 70, namun kehilangan kemampuan untuk beradaptasi dengan variasi data baru.

Berdasarkan kondisi tersebut, *epoch* optimal untuk model ini adalah 50, di mana keseimbangan antara akurasi pelatihan (99,65%), validasi (89,74%), dan pengujian (90,48%) masih terjaga dengan baik tanpa indikasi *overfitting* yang signifikan. *Learning rate* 0,001 terbukti cukup besar untuk dataset ini, menyebabkan model cepat mencapai konvergensi pada data latih namun kurang mampu menggeneralisasi fitur yang lebih kompleks pada data uji.

##### 2. Hasil Pengujian dengan LR 0.001

Pengujian kedua dilakukan dengan variasi jumlah *epoch* (30,50,70 dan 100) dan *learning rate* 0,0001. Tujuan dari pengujian ini adalah untuk mengidentifikasi apakah *learning rate* yang lebih kecil dapat menghasilkan generalisasi yang lebih baik serta memperkecil perbedaan antara akurasi pada pelatihan dan pengujian. Hasil pengujian untuk konfigurasi *learning rate* 0,0001 ditampilkan pada Tabel 3.

Tabel 3. Hasil Pengujian dengan LR 0.0001

Epoch	LR	Train Acc	Val Acc	Test Acc
30	0.0001	87,94	87,18	89,29
50	0.0001	92,20	87,18	91,67
70	0.0001	96,10	89,74	92,86
100	0.0001	98,94	89,74	90,48

Berdasarkan hasil pengujian pada Tabel 3 dengan *learning rate* 0,0001, terlihat pola pembelajaran yang lebih stabil dan terkontrol dibandingkan dengan *learning rate* 0,001. Nilai *Train Acc* meningkat secara bertahap dari 87,94 % pada *epoch* 30 menjadi 98,94% pada *epoch* 100, menunjukkan bahwa model tetap mampu mempelajari pola pada data latih meskipun dengan laju pembelajaran yang lebih lambat. Selain itu, konfigurasi ini menunjukkan hasil yang lebih seimbang dengan peningkatan *Test Acc* yang signifikan hingga mencapai puncaknya pada *epoch* 70 dengan nilai 92,86%, sementara *Val Acc* juga meningkat dari 87,18% menjadi 89,74%.

Pada *epoch* 70, model mencapai titik optimal di mana *Train Acc* (96,10%), *Val Acc* (89,74%), dan *Test Acc* (92,86%) menunjukkan keseimbangan yang baik antara kemampuan mempelajari data latih dan generalisasi ke data baru dengan selisih yang relatif kecil. Tingginya nilai *Test Acc* dibandingkan *Val Acc* pada konfigurasi ini dapat diatribusikan pada perbedaan ukuran dan karakteristik kedua set data. *Validation set* yang hanya terdiri dari 39 citra memiliki varians statistik yang lebih besar, sehingga performa model pada set ini lebih sensitif terhadap fluktuasi acak. Dengan jumlah sampel yang terbatas, setiap kesalahan prediksi memberikan dampak persentase yang lebih besar terhadap akurasi keseluruhan. Sebaliknya, *test set* yang terdiri dari 84 citra memberikan evaluasi yang lebih stabil dan representatif terhadap

kemampuan generalisasi model. Selain itu, distribusi sampel pada validation set yang secara acak mengandung lebih banyak citra dengan karakteristik ambigu atau sulit diklasifikasikan juga dapat berkontribusi terhadap perbedaan nilai akurasi tersebut.


Namun, peningkatan *epoch* menjadi 100% justru menyebabkan penurunan *Test Acc* menjadi 90,48% meskipun *Train Acc* terus meningkat menjadi 98,94%, yang mengindikasikan awal terjadinya *overfitting*. Dengan demikian, *epoch 70* dapat dianggap sebagai titik konvergensi optimal untuk *learning rate 0,0001*, di mana model berhasil mencapai generalisasi terbaik tanpa menghafal data latih secara berlebihan.

**B. Hasil Evaluasi Model**

Setelah mendapatkan parameter terbaik, dilakukan analisis mendalam terhadap performa model pada data pengujian (*test set*) yang belum pernah dilihat sebelumnya oleh model. Evaluasi ini bertujuan untuk memastikan kemampuan generalisasi model dalam mengidentifikasi empat kategori buah kakao.

**1. Confusion Matrix**

*Confusion matrix* digunakan untuk memberikan gambaran detail mengenai performa model dalam mengklasifikasikan setiap kategori penyakit buah kakao pada data pengujian. Melalui matriks ini, dapat diketahui distribusi prediksi benar dan salah yang dilakukan oleh model terhadap empat kelas target: *black pod rot*, *healthy*, *helopeltis*, dan *pod borer*.



Gambar 3. *Confusion Matrix*

Berdasarkan data pada gambar 3, dapat diuraikan hasil klasifikasi sebagai berikut:

- a. 22 citra berhasil diklasifikasikan dengan benar. Satu citra terprediksi sebagai *Healthy*, karena gejala infeksi awal yang belum menunjukkan perubahan warna dan tekstur yang mencolok. Satu citra *Pod Borer* terprediksi sebagai *Black Pod Rot* akibat kemiripan visual berupa noda kehitaman pada permukaan buah.
- b. 22 citra terprediksi benar. Satu kesalahan berasal dari citra *Black Pod Rot* yang terprediksi sebagai *Healthy*, konsisten dengan kesulitan membedakan tahap infeksi awal.

- c. 18 citra *Helopeltis* diprediksi dengan benar. Dua citra *Helopeltis* diklasifikasikan sebagai *Pod Borer*, dan dua citra *Pod Borer* juga diklasifikasikan sebagai *Helopeltis*. Kesalahan prediksi ini terjadi karena kedua penyakit menampilkan bercak kecil atau lubang mikro pada permukaan buah yang secara visual sulit dibedakan pada resolusi citra yang digunakan.
- d. 16 citra *Pod Borer* diprediksi dengan benar. Satu citra diklasifikasikan sebagai *Black Pod Rot* karena kemiripan warna gelap pada area kerusakan buah. Dua citra lainnya diklasifikasikan sebagai *Helopeltis* akibat kesamaan pola bercak kecil atau lesi permukaan yang sulit dibedakan secara visual pada resolusi citra yang digunakan.

Berdasarkan Gambar 3, dominasi nilai pada diagonal utama menunjukkan bahwa model mampu memprediksi dengan akurat untuk sebagian besar sampel. Kelas *healthy* dan *black pod rot* menunjukkan kinerja terbaik dengan hampir seluruh sampel terklasifikasi benar. Kesalahan prediksi paling sering terjadi antara kelas *helopeltis* dan *pod borer* akibat kemiripan gejala visual berupa bercak kecil pada tahap awal infeksi. Pola kesalahan ini konsisten dengan nilai *precision* dan *recall* yang sedikit lebih rendah pada kedua kelas tersebut.

**2. Classification Report**

Evaluasi model dengan konfigurasi optimal *epoch 70* dengan *learning rate 0,0001* dilakukan pada 84 citra data uji. Kinerja diukur menggunakan metrik evaluasi seperti *precision*, *recall*, *F1-score*, dan *accuracy*. Hasil penilaian kinerja model untuk setiap kategori dirangkum dengan rinci dalam Tabel 4.

Tabel 4. *Classification Report*

Kelas	Precision	Recall	F1-Score	Support
Black Pod Rot	0.9565	0.9565	0.9565	23
Healthy	0.9565	1.0000	0.9778	22
Helopeltis	0.9000	0.9000	0.9000	20
Pod Borer	0.8889	0.8421	0.8649	19
Accuracy			0.9286	84
Macro avg	0.9255	0.9247	0.9248	84
Weighted avg	0.9278	0.9286	0.9279	84

Secara keseluruhan, Tabel 4 memberikan rincian metrik kinerja masing-masing kategori data uji. Kategori *Healthy* menunjukkan performa yang sangat baik dengan tingkat *recall* sempurna 100% dan *F1-Score* mencapai 97,78%. Kategori lain seperti *Black Pod Rot* dan *Helopeltis* juga menunjukkan nilai metrik yang tinggi dan seimbang, masing-masing memperoleh *F1-Score* sebesar 95,65% dan 90%, yang menunjukkan keseimbangan optimal antara *precision* dan *recall*. Terdapat sedikit penurunan performa pada kelas *Pod Borer* dengan nilai *precision* sebesar 88,89%, *recall* sebesar 84,21% dan *F1-Score* 86,49%, yang menunjukkan bahwa model mengalami sedikit kesulitan dalam mengenali gejala penyakit kelas ini dengan kelas lainnya akibat kemiripan visual. Namun, secara keseluruhan, nilai akurasi sebesar

92,86% dan rata-rata *weighted average* sebesar 92,79% menegaskan bahwa model menunjukkan performa yang konsisten dan seimbang di seluruh kategori dalam mengidentifikasi penyakit buah kakao.

#### IV. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengimplementasikan metode *Deep Learning* dengan menggunakan pendekatan *Transfer Learning* pada arsitektur *MobileNetV2* untuk klasifikasi penyakit pada buah kakao yang mencakup empat kategori, yaitu *black pod rot*, *healthy*, *helopeltis*, dan *pod borer*. Berdasarkan hasil pengujian yang dilakukan, penentuan *hyperparameter* terbukti sangat berpengaruh terhadap performa model dalam mengenali fitur penyakit. Hasil paling optimal dicapai pada pengujian menggunakan *learning rate* 0,0001 dan 70 *epoch*, yang menghasilkan akurasi pelatihan sebesar 96,10%, validasi 89,74%, dan pengujian 92,86% dengan nilai *presisi* 92,78%, *recall* 92,86%, dan *F1-score* 92,79%. Evaluasi pada epoch optimal menunjukkan bahwa model berhasil mencapai konvergensi dengan performa yang konsisten pada data validasi dan pengujian, mengindikasikan kemampuan generalisasi yang baik tanpa indikasi *overfitting* yang signifikan.

Sebagai saran untuk penelitian selanjutnya, perlu dilakukan penambahan jumlah variasi dataset, terutama pada kelas yang memiliki tingkat kesalahan prediksi cukup tinggi, guna meningkatkan fleksibilitas model dalam mengenali pola citra yang lebih beragam. Selain itu, disarankan untuk melakukan perbandingan dengan arsitektur CNN lainnya seperti *ResNet* atau *EfficientNet*. Terakhir, pengembangan aplikasi berbasis seluler dapat dilakukan agar hasil penelitian ini dapat dirasakan manfaatnya secara langsung oleh petani kakao di lapangan dalam mendeteksi penyakit secara cepat dan akurat.

#### DAFTAR PUSTAKA

- [1] I. Komang *et al.*, "Identifikasi Penyakit Buah Kakao Jembrana Menggunakan Metode Resnet152v2," *Journal of Informatics Engineering and Technology (JIETECH)*, vol. 05, no. 1, pp. 12–20, 2024, [Online]. Available: [www.jembranakab.go.id](http://www.jembranakab.go.id)
- [2] *Badan Pusat Statistik*. 2024.
- [3] Valentino Keytumu, Julianus Jeksen, and Henderikus Beja, "Hama Dan Penyakit Pada Tanaman Kakao," *Jurnal Informasi Pengabdian Masyarakat*, vol. 1, no. 4, pp. 60–67, Oct. 2023, doi: 10.47861/jipm-nalanda.v1i4.545.
- [4] G. A. S. Gado and P. N. Primandari, "Sistem Klasifikasi Berbasis Android Untuk Penyakit Buah Kakao Menggunakan CNN Nasnet-Mobile," *Jurnal Teknologi Terpadu*, vol. 11, no. 1, pp. 27–35, 2025.
- [5] K. Penyakit *et al.*, "Klasifikasi Penyakit Daun Tomat Menggunakan Algoritma CNN Mobilenet V2," *INOTEK*, vol. 9, pp. 2549–7952, 2025.
- [6] R. Rahmanda and D. Oktaviani, "Implementasi Arsitektur MobileNetV2 Untuk Klasifikasi Penyakit Pada Daun Cabai Berbasis Convolution Neural Network," *Jurnal Ilmu Komputer*, vol. 10, no. 1, pp. 22–29, 2025, doi: 10.47007/komp.v7i01.xxxxx.
- [7] D. Mamadou, K. Jean AYIKPA, A. Bakary BALLO, and B. Médard KOUASSI, "Cocoa Pods Diseases Detection by MobileNet Confluence and Classification Algorithms," *IJACSA International Journal of Advanced Computer Science and Applications*, vol. 14, no. 9, pp. 334–352, 2023, [Online]. Available: [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org)
- [8] F. T. P. Aji, "Identifikasi Jenis Penyakit Buah Kakao (Theobroma Cacao L.) Berbasis Citra Buah Menggunakan Metode Deep Learning Convolutional Neural Networks (CNN)," Universitas Lampung, 2022.
- [9] K. R. Ariawan, A. A. G. Ekayana, I. P. Y. Indrawan, K. R. Winatha, and I. N. A. F. Setiawan, "Performance Comparison of DenseNet-121 and MobileNetV2 for Cacao Fruit Disease Image Classification," *Indonesian Journal of Data and Science*, vol. 6, no. 1, pp. 30–38, Mar. 2025, doi: 10.56705/ijodas.v6i1.233.
- [10] O. Virgantara Putra, M. Zaim Mustaqim, D. Muriatmoko, J. Teknik Informatika, and F. Sains dan Teknologi, "Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2 Transfer Learning for Rice Disease and Pest Classification using MobileNetV2," *Techno.COM*, vol. 22, no. 3, pp. 562–575, 2023.
- [11] F. D. Firmansyah, "Deteksi Penyakit Daun Bawang Merah Menggunakan Transfer Learning Dengan MobileNetV2 Berbasis Citra.pdf," Universitas Semarang, 2025.
- [12] S. Lestari, "Analisis Arsitektur Mobilenet pada Klasifikasi Penyakit Tanaman Tomat," Universitas Medan Area, 2024.
- [13] R. Gunawan, F. Salim, A. I. Wahyudhy, A. Y. Wibowo, G. Yordan, and R. F. Filamori, "Klasifikasi Penyakit Daun Kentang dengan Transfer Learning Menggunakan CNN optimalisasi Arsitektur MobileNetV2," *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 2, pp. 254–258, Sep. 2025, doi: 10.37859/coscitech.v6i2.8599.
- [14] A. G. Pradana, D. R. I. M. Setiadi, and A. R. Muslikh, "Fine tuning model Convolutional Neural Network EfficientNet-B4 dengan augmentasi data untuk klasifikasi penyakit kakao," *Journal of Information System and Application Development*, vol. 2, no. 1, pp. 01–11, Jun. 2024, doi: 10.26905/jisad.v2i1.11899.
- [15] S. Ceren, "Sistem Klasifikasi Penyakit pada Buah Jeruk Menggunakan MobileNetV2," *Prosiding Seminar Penyakit pada Buah Jeruk Menggunakan MobileNetV2*, vol. 5, pp. 226–234, 2026.
- [16] V. V. Oktariato, "Identifikasi Tanaman Hias Menggunakan Convolutional Neural Network Dengan Implementasi Transfer Learning," Universitas Ma Chung, 2023.