



# Klasifikasi Tingkat Kematangan Roasting Biji Kopi Berbasis Deep Learning dengan Arsitektur MobileNet

Tegar Firmansyah<sup>1</sup>, Rudi Kurniawan<sup>2</sup>, Asep Toyib Hidayat<sup>3,\*</sup>

<sup>1</sup>Fakultas Ilmu Teknik, Program Studi Informatika, Universitas Bina Insan, Lubuklinggau

Jl. Jendral H.M Soeharto, Kelurahan Lubuk Kupang, Kecamatan Lubuklinggau Selatan I, Kota Lubuklinggau, Indonesia

<sup>2</sup>Fakultas Ilmu Teknik, Program Studi Rekayasa Sistem Komputer, Universitas Bina Insan, Lubuklinggau

Jl. Jendral H.M Soeharto, Kelurahan Lubuk Kupang, Kecamatan Lubuklinggau Selatan I, Kota Lubuklinggau, Indonesia

<sup>3</sup>Fakultas Ilmu Teknik, Program Studi Sistem Informasi, Universitas Bina Insan, Lubuklinggau

Jl. Jendral H.M Soeharto, Kelurahan Lubuk Kupang, Kecamatan Lubuklinggau Selatan I, Kota Lubuklinggau, Indonesia

Email: <sup>1</sup>tegarfrmnsyah@gmail.com, <sup>2</sup>rudi.kurniawan@univbinainsan.ac.id <sup>3,\*</sup>asepfighter@gmail.com

Email Penulis Korespondensi: asepfighter@gmail.com

Submitted: 22/01/2025; Accepted: 31/01/2025; Published: 31/01/2025

**Abstrak**—Kopi merupakan salah satu bahan minuman yang banyak dikonsumsi di Indonesia dan memiliki nilai ekonomi tinggi untuk meningkatkan perekonomian masyarakat serta sebagai sumber devisa negara. Proses roasting menjadi tahapan penting dalam pengolahan kopi karena memengaruhi aroma dan rasa kopi. Hal yang sering dihadapi adalah penentuan tingkat roasting kopi secara visual sering kali kurang akurat dan rawan kesalahan manusia. Mengatasi masalah tersebut, maka pada penelitian ini digunakan pendekatan deep learning dengan metode transfer learning berbasis arsitektur MobileNet untuk mengklasifikasikan tingkat kematangan roasting kopi berdasarkan citra digital. MobileNet dipilih karena arsitekturnya yang ringan dan cepat, cocok untuk implementasi pada perangkat seluler. Penelitian ini bertujuan membandingkan kinerja model dalam mendeteksi tingkat roasting kopi secara otomatis, efisien, dan objektif. Dengan pendekatan ini, diharapkan penggemar kopi maupun produsen dapat dengan mudah mengenali jenis roasting kopi, mendukung konsistensi kualitas produk, dan mengurangi ketergantungan pada tenaga ahli dalam proses roasting. Penelitian ini menganalisis kinerja model klasifikasi dengan hasil yang menunjukkan performa sangat baik. Model mencapai akurasi total 99,50%, dengan nilai precision, recall, dan f1-score yang konsisten tinggi pada semua kelas, termasuk beberapa kelas dengan skor sempurna (1.000). Evaluasi menggunakan kurva ROC dan AUC juga menunjukkan kemampuan model dalam membedakan kelas secara sempurna (AUC = 1.000). Analisis confusion matrix mengungkapkan bahwa kesalahan klasifikasi sangat minim dan terkonsentrasi pada kelas tertentu, seperti Dark dan Medium, memberikan ruang untuk perbaikan lebih lanjut. Hasil ini menegaskan relevansi praktis model dalam aplikasi klasifikasi gambar atau pengenalan pola yang membutuhkan akurasi tinggi. Meskipun demikian, pengujian pada dataset baru dan pengoptimalan tambahan, seperti tuning hyperparameter atau augmentasi data, disarankan untuk meningkatkan generalisasi model. Secara keseluruhan, model ini menunjukkan potensi besar dan keandalan yang tinggi untuk aplikasi dunia nyata.

**Kata Kunci:** Mobilenet; Roasting Kopi; Deep Learning.

**Abstract**—Coffee is one of the most widely consumed beverage ingredients in Indonesia and has high economic value to improve the community's economy and as a source of foreign exchange. The roasting process is an important stage in coffee processing because it affects the aroma and flavor of coffee. What is often encountered is that visually determining the level of coffee roasting is often inaccurate and prone to human error. To overcome this problem, this study uses a deep learning approach with a transfer learning method based on MobileNet architecture to classify the level of coffee roasting maturity based on digital images. MobileNet was chosen due to its lightweight and fast architecture, suitable for implementation on mobile devices. This research aims to compare the performance of the model in detecting coffee roasting level automatically, efficiently, and objectively. With this approach, it is expected that coffee enthusiasts and producers can easily recognize the type of coffee roasting, support product quality consistency, and reduce dependence on experts in the roasting process. This study analyzed the performance of the classification model with the results showing excellent performance. The model achieved a total accuracy of 99.50%, with consistently high precision, recall, and f1-score values across all classes, including several classes with perfect scores (1,000). Evaluation using ROC curves and AUC also demonstrated the model's ability to distinguish between the two classes.

**Keywords:** MobileNet; Coffee Roasting; Deep Learning

## 1. PENDAHULUAN

Kopi adalah salah satu bahan minuman yang paling banyak dikonsumsi oleh masyarakat Indonesia. Kopi diyakini memiliki nilai ekonomi yang tinggi untuk meningkatkan ekonomi masyarakat dan sebagai sumber devisa Negara. Menurut data Badan Pusat Statistik (BPS) pada tahun 2021, Indonesia memproduksi biji kopi mencapai 774,6 ribu ton yang dimana pada tahun sebelumnya produksi kopi hanya sebesar 753,9 ribu ton, hal ini menunjukkan adanya peningkatan produksi kopi di Indonesia sebesar 2,75[1]. Produksi kopi dalam negeri tercatat telah mencapai 600.000 ton per tahun dan lebih dari 80% hasil produksi tersebut berasal dari perkebunan rakyat. Sedangkan melalui penjualan ekspor kopi, devisa yang didapatkan dapat mencapai kurang lebih US\$ 824.02 juta[2].

Aroma dan rasa kopi dipengaruhi oleh tingkat penyangraian (roasting). Proses roasting merupakan salah satu tahapan yang penting dalam pengolahan kopi. Proses penyangraian (roasting) dapat menghasilkan berbagai level, ada 4 level roasting yang dilakukan yaitu unroasted, light roasted, medium roasted, dan dark roasted. Untuk mengetahui tingkat Roasting biji kopi dapat dilihat secara kasat mata dari warna hasil Roasting. Namun hal ini dianggap kurang akurat dan kurang optimal karena memungkinkannya terjadi human error, akibatnya sulit untuk



menentukan tingkat Roasting biji kopi yang baik dan tepat. Adapun tindakan yang dapat dicapai untuk membantu penanganan masalah tersebut yaitu dengan memanfaatkan kecerdasan buatan seperti teknologi pengenalan citra metode Deep Learning.

Klasifikasi adalah proses menemukan sekumpulan pola atau fungsi-fungsi yang mendeskripsikan dan memisahkan kelas data satu dengan yang lainnya, dan digunakan untuk memprediksi data yang belum memiliki kelas data tertentu. Deep Learning merupakan bagian dari Machine Learning yang dapat mempelajari metode komputasinya sendiri[3]–[5]. MobileNet adalah streamlined architecture yang menggunakan konvolusi yang dapat dipisahkan secara mendalam untuk membangun deep convolutional neural networks yang ringan dan menyediakan model yang efisien untuk aplikasi mobile dan embedded vision. MobileNet atau MobileNetV1 merupakan model yang memiliki ukuran kecil baik dari jumlah parameter maupun ukuran model yang dihasilkan. Seperti namanya, Mobile, para peneliti dari Google membuat arsitektur CNN yang dapat digunakan untuk kebutuhan mobile. MobileNetV1 adalah sebuah arsitektur model yang dikembangkan untuk pengembangan aplikasi pada perangkat mobile ataupun perangkat lain yang memiliki keterbatasan sumber daya perangkat keras dengan mengurangi ukuran dan kompleksitas model menggunakan depthwise separable convolutions. Perbedaan mendasar antara arsitektur MobileNet dan arsitektur CNN pada umumnya adalah penggunaan lapisan atau layer konvolusi dengan ketebalan filter yang sesuai dengan ketebalan input image[6][7].

Artificial intelligence adalah suatu program yang digunakan untuk merancang komputer untuk meniru cara berfikir ataupun nalar manusia guna melakukan tugas-tugas tertentu. Python merupakan bahasa pemrograman tingkat tinggi yang sifatnya interpreter yaitu bahasa pemrograman yang mendukung paradigma pemrograman object oriented programming (OOP), prosedural dan fungsional di hampir semua platform sistem operasi. Python telah digunakan untuk mengembangkan berbagai macam software, seperti systems programming, user interfaces, internet scripting, product customization, numeric programming, dan lain sebagainya. Computer vision (CV) adalah kemampuan komputer untuk menampilkan objek digital dan mengoleksi data secara visual komputer agar mampu melihat sebuah object sehingga bisa melakukan beberapa pekerjaan yang tidak bisa dilakukan oleh manusia. Tensorflow adalah framework machine learning yang bersifat open source yang didukung oleh Google dalam rangka pengembangan penelitian berbasis komputer cerdas. Keras adalah interface library yang bertujuan menyederhanakan implementasi algoritma-algoritma deep learning di atas TensorFlow[8].

Kecerdasan buatan atau Artificial Intelligent (AI) merupakan cabang ilmu komputer yang dapat dimanfaatkan dalam berbagai bidang. Deep learning banyak digunakan pada penelitian dengan tema pengolahan citra dalam berbagai bidang seperti bidang kesehatan, pertanian dan sosial. Dalam bidang perkebunan di Indonesia, salah satu komoditas penting dan masih memiliki peluang untuk dikembangkan adalah komoditas kopi. Penelitian yang pernah dilakukan oleh Assri dkk, dimana hasil testing dari penelitian tersebut mendapatkan hasil akurasi sebesar 96% pada epoch ke 10. Perbedaan dengan penelitian ini terletak pada objek penelitian. Penelitian ini menggunakan biji kopi sebagai objeknya[9].

Penelitian dengan metode serupa dengan objek yang berbeda juga pernah dilakukan oleh Arvi dkk pada tahun 2021, dimana penelitian ini mengklasifikasikan objek buah Mangga Badami untuk menentukan tingkat kematangan dengan metode CNN. Dataset yang digunakan berjumlah 204 citra, terdiri dari 35 Mangga Badami Busuk, 75 Mangga Badami Mentah, dan 94 Mangga Badami Matang. Sedangkan dalam penelitian ini menggunakan objek biji kopi untuk menentukan tingkat kematangan[10]. Tujuan dari penelitian ini yaitu untuk membandingkan kinerja arsitektur MobileNet dalam melakukan deteksi tingkat kematangan roasting kopi melalui gambar (image classification) berdasarkan hasil evaluasi model.

## 2. METODOLOGI PENELITIAN

### 2.1 Metode Pengumpulan Data

Pada penelitian ini penulis menggunakan pendekatan kualitatif. Kualitatif merupakan data yang berbentuk kalimat, kata ataupun gambar. Pemilihan Kualitatif dikarenakan data lebih banyak bersifat keterangan atau penjelasan yang bukan berbentuk angka. Data-data pada penelitian ini data primer yaitu berupa kata-kata, ataupun perilaku yang diamati melalui observasi yaitu dating langsung ketempat penelitian di Tempat Pembuatan Kopi Bubuk Cap Lesung dan wawancara dengan pemilik usaha Kopi Cap Lesung serta data sekunder yaitu literatur mengumpulkan data-data dari jurnal dan buku. Untuk mendapatkan data yang akurat peneliti menggunakan beberapa metode pengumpulan data diantaranya adalah sebagai berikut ini:

1. Observasi

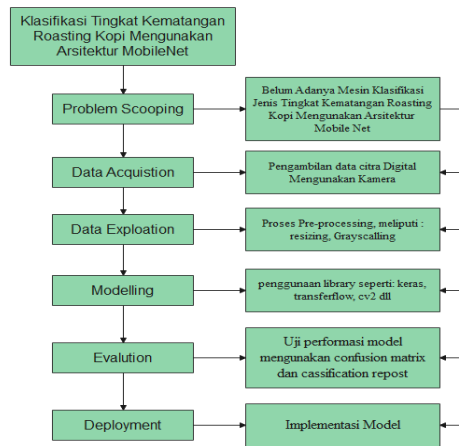
Merupakan teknik atau pendekatan untuk mendapatkan data primer dengan mengamati langsung objek datanya sehingga data dapat diperoleh secara orisinil pada saat terjadinya dan mencatatkan hasil observasi tersebut. Dengan melakukan observasi langsung untuk mencari informasi data baik alat dan bahan serta segala sesuatu yang digunakan dalam penelitian.

2. Literatur Review

Menggunakan metode pengumpulan data Literatur yaitu dengan mencari referensi dari buku, majalah, jurnal, artikel, internet, dan sumber lainnya yang berkaitan dengan judul yang diambil, kemudian dirangkum untuk disusun dan disempurnakan.

## 2.2 Tahapan Penelitian

Tahapan penelitian ini mengacu pada metode perancangan sistem yang digunakan yaitu framework AI life cycle. Gambar 1 berikut menyajikan tahapan penelitian yang menjadi acuan dalam metodologi penelitian.



**Gambar 1.** Tahapn Penelitian

## 2.3 Metode Analisa


Dalam penelitian ini penulis menggunakan metode framework AI life cycle untuk membangun klasifikasi jenis padi menggunakan Arsitektur MobileNet. Berikut merupakan langkah-langkah pengembangan perangkat tersebut:

a) Problem Scoping

Problem Scoping terkait dengan lingkup masalah sekaligus proses awal dalam AI Project Life Cycle, dengan menggunakan 4w+1h yakni what (apa), where (dimana), when (kapan), who (siapa), dan how (bagaimana).

b) Data Acquisition

Data Acquisition adalah proses pengumpulan, pengukuran dan validitas data, dengan cara mencari data apa saja yang dibutuhkan dan bagaimana cara mendapatkannya. Data diambil menggunakan kamera berjumlah 1600 gambar yang dibagi menjadi dua kategori utama, yaitu 1200 gambar pada kategori train dan 300 gambar pada kategori test. Jumlah kelas sebanyak 4 (kelas) antara lain: Drak, Green, Light, dan medium. Dataset terdiri dari 2 folder utama, yaitu train dan test. Masing-masing folder terdiri dari setiap kelas yang ada, yaitu: light, green, dark, dan medium. Sebaran data dari masing-masing kelas. Dalam membangun model, diperlukan data validasi yang diambil sebesar 20 % dari data train.



**Gambar 2.** Sampel Data pada masing-masing kelas

c) Data Exploration

Data Exploration adalah tahapan setelah Data Acquisition dimana tahapan ini bertujuan untuk memahami karakteristik data yang telah dikumpulkan. prosespreprocessing yang dilakukan antara lain resizing dan grayscale

d) Modelling

Modelling adalah tahap pengembangan model meliputi pemilihan algoritma dan training data. Pada tahap inilah pembuatan model dilakukan.

e) Evaluation

Merupakan tahapan dimana dilakukan pengujian performansi terhadap model yang sudah dibangun. Metode pengujian yang dilakukan meliputi: confusion matrix dan classification report.

f) Deployment

Setelah didapatkan model baik atau yang siap digunakan, tahap deployment ini mengimplementasikan penerapan dari model Arsitektur MobileNet yang sudah dibuat. Model disimpan dalam format .h5 sehingga bisa dijalankan dan tidak diperlukan proses training kembali.

**2.4 Metode Pengujian Dan Pengelolaan Data**

Adapun metode pengujian sistem dalam penelitian ini adalah Confusion Matrix. Confusion Matrix bertujuan menggambarkan performa dari sebuah model atau algoritma secara spesifik. Seperti yang terlihat pada tabel 1 berikut ini:

**Tabel 1.** Confusion Matrix

	<b>Predicted Negative</b>	<b>Predicted Positive</b>
<b>Actual Negative</b>	True Negative (TN)	False Positive (FP)
<b>Actual Positive</b>	False Negative (FN)	True Positive (TP)

Penjelasan Confusion Matrix diatas:

1. True Positive, data-data yang memiliki kelas positif, dan model juga memprediksi benar positif.
2. True Negative, data-data yang memiliki kelas positif, dan model memprediksi juga benar negatif.
3. False Positive, data-data yang memiliki kelas positif, namun model memprediksi positif.
4. False Negative, data-data yang memiliki kelas positif, namun model memprediksi negatif.

Melalui data tersebut, dapat diperoleh data data lain untuk mengukur perfoma sebuah model, antara lain:

1. Accuracy, total keseluruhan seberapa sering model benar dalam klasifikasi jenis padi. Formula accuracy dapat ditulis menggunakan persamaan berikut:

$$\frac{TP+TN}{Total} \tag{1}$$

2. Precision, ketika model memprediksi positif, seberapa sering prediksi itu benar. Formula precision dapat ditulis menggunakan persamaan berikut:

$$\frac{TP}{FN+TP} \tag{2}$$

3. Recall (Sensitivity / True Positive Rate), ketika kelas aktualnya positif, seberapa sering model memprediksi positif. Formula recall dapat ditulis menggunakan persamaan berikut:

$$\frac{TP}{FN+TP} \tag{3}$$

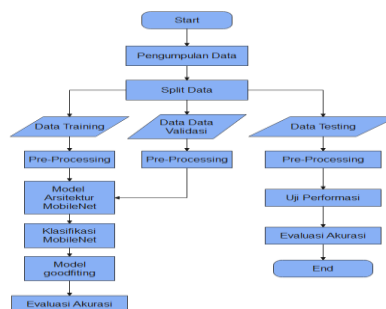
4. F1-Score, merupakan rata-rata harmonik dari Precision dan Recall. Formula f1-score dapat ditulis menggunakan persamaan berikut:

$$2 * \frac{precision * recall}{precision + recall} \tag{4}$$

**2.5 Alur Kerja Sistem**

1. Alur Kerja Sistem

Gambar 3 berikut menyajikan alur kerja sistem. Alur kerja sistem berawal dari proses pengumpulan data yaitu pengambilan dataset, kemudian dilakukan split data (permbagian data) antara data train dan data test. Kemudian dilakukan proses resize untuk pelatihan Arsitektur MobileNet. Setelah model mencapai goodfitting, maka dilakukan pengujian dengan menggunakan data testing yang dilanjutkan dengan melakukan evaluasi model dengan menggunakan uji performansi[11].



**Gambar 3.** Gambar Alur kerja sistem

## 2. Pre-processing

Sebelum melatih model arsitektur MobileNet, kami melakukan pra-pemrosesan data untuk memastikan konsistensi dan kualitas dataset. Adapun tahapan-tahapan pre-processing yang dilakukan adalah grayscale, thresholding, segmentasi, dan resize.

## 3. Arsitektur MobileNet

Setelah proses segmentasi selesai, kemudian dilakukan klasifikasi menggunakan arsitektur Mobile-Net. Arsitektur tersebut telah dimodifikasi untuk mendapatkan model performa yang baik. Pada arsitektur ini dimulai dengan lapisan konvolusi pertama kemudian diikuti dengan 13 lapisan dari lapisan depthwise convolution dan setiap lapisan diikuti oleh lapisan pointwise convolution. Fungsi aktivasi Batch normalization (BN) dan Rectified Linear Unit (ReLU) diterapkan setelah setiap lapisan konvolusi depthwise dan pointwise. Fungsi ini digunakan untuk membuat jaringan lebih cepat dan stabil. Setelah fitur citra input diekstraksi oleh semua lapisan convolutional, kemudian digunakan lapisan Global Average Pooling untuk mengurangi ukuran peta fitur yang diekstraksi. Kemudian yang terakhir yaitu lapisan Dense yang menggunakan fungsi aktivasi Softmax. Proses selanjutnya yaitu output, menampilkan hasil dari klasifikasi yang telah dilakukan berdasarkan Empat kelas yaitu Drak, Green, Light, dan medium [12]–[14].

## 4. Klafikasi Fitur

Pada tahap ini terdapat 1 layer yaitu fully connected layer dan fungsi aktivasi yang digunakan yaitu softmax. Berikut ini adalah penjelasan dari layer dan fungsi aktivasi pada tahap klasifikasi fitur

### a) Flatten

Flatten adalah proses membentuk ulang fitur (reshape feature map) menjadi sebuah vector agar bisa digunakan sebagai input dari fully connected layer.

### b) Fully-Conneted layer

Layer tersebut adalah layer yang biasanya digunakan dalam penerapan MLP dan bertujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear. Setiap neuron pada convolution layer perlu ditransformasi menjadi data satu dimensi terlebih dahulu sebelum dapat dimasukkan ke dalam sebuah fully-connected layer. Karena hal tersebut menyebabkan data kehilangan informasi spasialnya dan tidak reversibel, fully- connected layer hanya dapat diimplementasikan di akhir jaringan.

### c) Softmax Activation

Softmax adalah fungsi yang mengambil sebagai input vektor dari bilangan real dari  $K$ , dan menormalisasi menjadi distribusi probabilitas yang terdiri dari probabilitas  $K$ . Sebelum menerapkan softmax, beberapa komponen vektor bisa negatif, atau lebih besar dari satu; dan mungkin tidak berjumlah 1, tetapi setelah menerapkan softmax, setiap komponen akan berada dalam interval  $(0 - 1)$ , dan komponen akan bertambah hingga 1, sehingga mereka dapat diartikan sebagai probabilitas. Selanjutnya, komponen input yang lebih besar sesuai dengan probabilitas yang lebih besar. Softmax sering digunakan dalam neural network, Softmax ini digunakan unuk menentukan output yang sesuai.

### d) Evaluasi Model

Melakukan evaluasi model dengan menghitung berapa besar akurasi yang dihasilkan.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Hasil

#### 3.1.1 Persiapan Distribusi Data

Dataset terdiri dari 2 folder utama, yaitu train dan test. Masing-masing folder terdiri dari setiap kelas yang ada, yaitu: light, green, dark, dan medium. Gambar 4 menyajikan sebaran data dari masing-masing kelas. Dalam membangun model, diperlukan data validasi yang diambil sebesar 20 % dari data train.



Gambar 4. Distribusi Data

### 3.1.2 Preprocessing

Untuk meningkatkan ketajaman gambar, diperlukan proses enhancement dengan menggunakan metode Contrast Limited Adaptive Histogram Equalization (CLAHE). Gambar 5 menyajikan hasil dari proses CLAHE. Metode ini menetapkan nilai batas pada histogram, yang dikenal sebagai clip limit. Clip limit ini menunjukkan batas maksimum tinggi suatu histogram[15].



Gambar 5. CLAHE

### 3.1.3 Ekstraksi fitur dengan arsitektur MobileNetV2 dan fully connected layer

Model Summary menyajikan ringkasan model yang dibangun. Model yang diberikan adalah arsitektur jaringan saraf konvolusional (CNN) yang menggunakan MobileNetV2 sebagai backbone untuk ekstraksi fitur, diikuti dengan beberapa lapisan tambahan untuk klasifikasi[16]. Berikut adalah rincian dari setiap komponen:

#### 1. Struktur Model

##### a. Input Layer

- 1) Tipe: InputLayer
- 2) Output Shape: (None, 224, 224, 3)
- 3) Deskripsi: Ini adalah lapisan input yang menerima gambar berukuran 224x224 piksel dengan 3 saluran warna (RGB). None menunjukkan bahwa ukuran batch dapat bervariasi.

##### b. MobileNetV2

- 1) Tipe: Functional
- 2) Output Shape: (None, 7, 7, 1280)
- 3) Parameter #: 2,257,984
- 4) Deskripsi: MobileNetV2 adalah model CNN yang dirancang untuk efisiensi dan kecepatan, terutama pada perangkat mobile. Ia mengurangi jumlah parameter dan komputasi dengan menggunakan teknik seperti depthwise separable convolutions. Output dari lapisan ini adalah tensor dengan dimensi spasial yang lebih kecil (7x7) dan jumlah fitur sebanyak 1280.

##### c. Batch Normalization

- 1) Output Shape: (None, 7, 7, 1280)
- 2) Parameter #: 5,120
- 3) Deskripsi: Lapisan ini digunakan untuk menormalkan output dari lapisan sebelumnya. Ini membantu dalam mempercepat pelatihan dan meningkatkan stabilitas model.

##### d. Global Average Pooling

- 1) Output Shape: (None, 1280)
- 2) Parameter #: 0
- 3) Deskripsi: Lapisan ini meratakan output dari lapisan sebelumnya menjadi vektor satu dimensi dengan panjang fitur sebanyak 1280. Ini menggantikan kebutuhan akan lapisan fully connected tradisional dan membantu mengurangi overfitting.

##### e. Dense Layer

- 1) Output Shape: (None, 512)
- 2) Parameter #: 655,872
- 3) Deskripsi: Lapisan dense ini memiliki 512 neuron yang terhubung ke semua neuron di lapisan sebelumnya. Ini berfungsi untuk mengubah dimensi fitur menjadi representasi yang lebih kompak sebelum klasifikasi akhir.

##### f. Dropout Layer

- 1) Output Shape: (None, 512)
- 2) Parameter #: 0
- 3) Deskripsi: Lapisan dropout digunakan untuk mencegah overfitting dengan secara acak menonaktifkan sejumlah neuron selama pelatihan. Ini membantu model generalisasi lebih baik pada data baru.

- g. Output Layer
  - 1) Output Shape: (None, 4)
  - 2) Parameter #: 2,052
  - 3) Deskripsi: Ini adalah lapisan akhir yang menghasilkan prediksi untuk empat kelas (Light, Green, Dark, Medium). Jumlah neuron di lapisan ini sesuai dengan jumlah kelas yang ingin diprediksi.
- 2. Ringkasan Parameter
  - a. Total Parameters: 2,921,028
  - b. Trainable Parameters: 660,484
  - c. Non-trainable Parameters: 2,260,544

```

Model: "model"
-----
Layer (type)                Output Shape                Param #
-----
input_1 (InputLayer)        [(None, 224, 224, 3)]      0
mobilenetv2_1.00_224 (Func (None, 7, 7, 1280)         2257984
tional)
batch_normalization (BatchN (None, 7, 7, 1280)         5120
ormalization)
global_average_pooling2d (G (None, 1280)                0
lobalAveragePooling2D)
dense (Dense)                (None, 512)                 655872
dropout (Dropout)           (None, 512)                 0
output_layer (Dense)         (None, 4)                   2052
-----
Total params: 2,921,028
Trainable params: 660,484
Non-trainable params: 2,260,544

```

**Gambar 6.** Model Summary

Total parameter model menunjukkan bahwa meskipun ada banyak parameter di seluruh model (terutama di MobileNetV2), hanya sebagian kecil dari mereka yang dapat dilatih (660,484). Ini menunjukkan bahwa banyak parameter berasal dari lapisan pre-trained MobileNetV2 yang tidak diubah selama pelatihan.

Non-trainable parameters sebagian besar berasal dari lapisan yang telah dilatih sebelumnya dalam MobileNetV2. Model ini merupakan arsitektur CNN yang efisien dan kuat untuk tugas klasifikasi gambar dengan memanfaatkan kekuatan MobileNetV2. Dengan penggunaan batch normalization dan dropout, model ini dirancang untuk meningkatkan performa dan generalisasi sambil menjaga efisiensi komputasi. Arsitektur ini sangat cocok untuk aplikasi di mana kecepatan dan akurasi diperlukan dalam pengenalan gambar[17].

**3.1.4 Pelatihan Sistem**


Hyperparameter memungkinkan untuk melakukan konfigurasi variabel eksternal yang digunakan untuk mengelola pelatihan model machine learning. Tabel 4.1 menyajikan konfigurasi hyperparameter yang digunakan.

**Tabel 2.** Konfigurasi Hyperparameter

NO	Hyperparameter	Value
1	Batch size	32
2	Learning rate	0.001
3	Epoch	50
4	Optimizer	Adam

**3.1.5 Hasil Pelatihan Model**


Gambar 7 menyajikan data tentang grafik loss dan accuracy. Terlihat jelas bahwa model berjalan dengan baik yang menunjukkan model tidak terjadi overfitting



**Gambar 7.** Grafik loss dan Accuracy

### 3.1.6 Evaluasi Model

Evaluasi model antara lain melihat seberapa bagus model dalam mengidentifikasi setiap kelas yang ada. Evaluasi model ini meliputi confusion matrix, dan classification report. Gambar 8 menyajikan hasil dari confusion matrix. Baris pertama menunjukkan bahwa dari total 100 contoh untuk kelas Dark, model memprediksi dengan benar sebanyak 99 dan salah memprediksi sebanyak 1 sebagai Medium. Baris kedua menunjukkan bahwa semua contoh untuk kelas Green diprediksi dengan benar. Baris ketiga menunjukkan bahwa semua contoh untuk kelas Light diprediksi dengan benar. Baris keempat menunjukkan bahwa dari total contoh untuk kelas Medium, satu contoh salah diprediksi sebagai Light, sementara sisanya diprediksi dengan benar.



**Gambar 8.** Confusion Matrix

Gambar 9 menyajikan classification report dari model klasifikasi. Kelas Dark: Model sangat baik dalam mengidentifikasi kelas ini dengan precision yang sempurna (1.0000) meskipun recall sedikit lebih rendah (0.9900). Kelas Green: Model menunjukkan performa sempurna dengan precision dan recall keduanya mencapai 1.0000. Kelas Light: Precision sangat tinggi (0.9901) dan recall sempurna (1.0000), menunjukkan bahwa model hampir tidak membuat kesalahan dalam klasifikasi kelas ini. Kelas Medium: Precision (0.9900) dan recall (0.9900) juga sangat baik, menunjukkan bahwa model mampu mengenali kelas ini dengan baik [18].

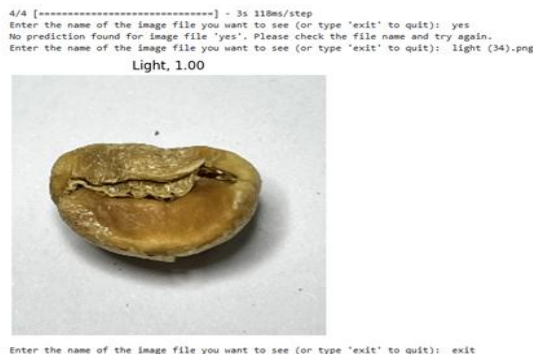
	precision	recall	f1-score	support
Dark	0.9900	0.9900	0.9900	100
Green	1.0000	1.0000	1.0000	100
Light	1.0000	1.0000	1.0000	100
Medium	0.9900	0.9900	0.9900	100
accuracy			0.9950	400
macro avg	0.9950	0.9950	0.9950	400
weighted avg	0.9950	0.9950	0.9950	400

**Gambar 9.** Classification Report

Akurasi Total sebesar **0.9950**. Ini menunjukkan bahwa model benar dalam memprediksi sekitar 99.50% dari semua contoh dalam dataset. Rata-Rata Macro Average antara lain: Precision 0.9950, Recall: 0.9950, F1-Score: 0.9950. Rata-rata makro menghitung rata-rata dari metrik tanpa mempertimbangkan jumlah contoh di setiap kelas, memberikan gambaran umum tentang kinerja model di semua kelas. Weighted Average antara lain: Precision: 0.9950, Recall: 0.9950, F1-Score: 0.9950. Rata-rata berbobot mempertimbangkan jumlah contoh di setiap kelas, memberikan gambaran yang lebih representatif tentang kinerja model pada dataset secara keseluruhan.

### 3.1.7 Pengujian Dengan Input Data

Pengujian dengan input data dimaksudkan untuk menguji model yang telah dibangun. Gambar 10 menyajikan hasil pengujian dari proses input data pada model. [19]



**Gambar 10.** Pengujian Model

### 3.2 Pembahasan

Model menunjukkan performa yang sangat baik dalam klasifikasi empat kelas dengan akurasi total sebesar 99.50% dan nilai f1-score mendekati sempurna di semua kelas. Confusion matrix mengindikasikan bahwa kesalahan yang terjadi relatif kecil dan terfokus pada beberapa contoh tertentu, terutama pada kelas Dark dan Medium. Dengan hasil ini, model dapat dianggap handal untuk aplikasi klasifikasi yang dihadapi, meskipun tetap ada ruang untuk perbaikan lebih lanjut, terutama dalam mengurangi kesalahan pada kelas tertentu jika diperlukan untuk aplikasi kritis. Dari 300 data uji, terdapat 3 misklasifikasi yang didapat, yaitu 2 sampel ‘dark’ yang diprediksi ‘medium’ dan 1 sampel ‘medium’ yang diprediksi ‘light’. Gambar 11 menyajikan misklasifikasi yang dihasilkan dari hasil proses klasifikasi.

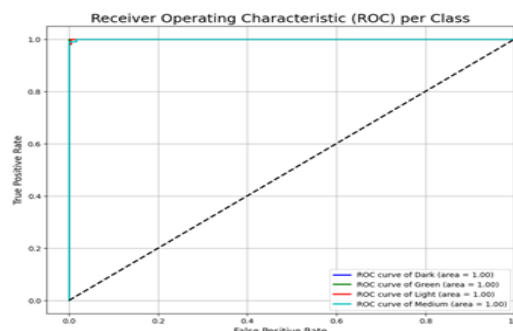


**Gambar 11.** Misclassification

Gambar 12 menyajikan kurva RoC. Kurva ROC (Receiver Operating Characteristic) adalah alat penting dalam evaluasi model klasifikasi, yang menggambarkan performa model dengan memplot rasio positif yang benar (True Positive Rate, TPR) terhadap rasio positif yang salah (False Positive Rate, FPR) pada berbagai ambang batas klasifikasi. Berikut adalah gambaran tentang kurva ROC dan implikasi dari hasil yang menunjukkan nilai 1.000 untuk masing-masing kelas. [20]

1. Sumbu X dan Y:
  - a. Sumbu X (FPR): Menunjukkan tingkat kesalahan dalam memprediksi kelas positif (false positive rate).
  - b. Sumbu Y (TPR): Menunjukkan kemampuan model dalam mengidentifikasi kelas positif dengan benar (true positive rate).
2. Garis Diagonal:
  - a. Garis diagonal dari titik (0,0) ke (1,1) mewakili kinerja model acak. Model yang lebih baik akan memiliki kurva yang berada di atas garis ini, mendekati titik (0,1).
3. Area Under Curve (AUC):
  - a. AUC adalah ukuran dari keseluruhan kinerja model. Nilai AUC berkisar antara 0 hingga 1, di mana nilai 1 menunjukkan model sempurna yang dapat membedakan antara kelas positif dan negatif tanpa kesalahan.
  - b. Jika AUC = 1.000 untuk masing-masing kelas, ini menunjukkan bahwa model dapat mengklasifikasikan semua contoh dengan sempurna tanpa kesalahan.
4. Interpretasi Hasil AUC = 1.000
  - a. Kinerja Sempurna: Nilai AUC sebesar 1.000 berarti bahwa model berhasil mengidentifikasi semua contoh positif dan negatif dengan akurasi sempurna di semua ambang batas klasifikasi.
  - b. Tidak Ada Kesalahan Klasifikasi: Semua prediksi untuk setiap kelas benar, tanpa adanya false positives atau false negatives.
  - c. Keandalan Model: Model ini sangat dapat diandalkan untuk aplikasi praktis karena tidak hanya menunjukkan akurasi tinggi tetapi juga konsistensi dalam memprediksi setiap kelas.

Kurva ROC adalah alat yang kuat untuk menilai dan membandingkan kinerja model klasifikasi. Hasil yang menunjukkan nilai AUC = 1.000 untuk masing-masing kelas menandakan bahwa model tersebut sangat efektif dan dapat digunakan dengan percaya diri dalam situasi di mana akurasi prediksi sangat penting.



**Gambar 12.** Curva RoC



## 4. KESIMPULAN

Berdasarkan analisis hasil evaluasi model klasifikasi yang telah dilakukan, dapat disimpulkan bahwa model menunjukkan performa luar biasa dengan akurasi total sebesar 99.50%. Semua metrik kinerja (precision, recall, dan f1-score) untuk masing-masing kelas berada pada tingkat yang sangat tinggi, dengan beberapa kelas mencapai nilai sempurna (1.000). Precision dan recall untuk setiap kelas menunjukkan bahwa model tidak hanya mampu mengidentifikasi contoh positif dengan akurat tetapi juga meminimalkan kesalahan dalam prediksi negatif. Ini penting untuk aplikasi di mana kesalahan klasifikasi dapat memiliki konsekuensi serius. Dengan nilai AUC mencapai 1.000 untuk masing-masing kelas, model ini menunjukkan kemampuan sempurna dalam membedakan antara kelas-kelas yang ada, tanpa menghasilkan false positives atau false negatives. Analisis confusion matrix mengindikasikan bahwa kesalahan klasifikasi sangat minim dan terfokus pada beberapa contoh tertentu, terutama di kelas Dark dan Medium. Ini menunjukkan bahwa meskipun model sangat baik, ada ruang untuk perbaikan lebih lanjut dalam mengurangi kesalahan tersebut. Meskipun hasilnya sangat positif, penting untuk terus memantau performa model pada dataset baru dan mempertimbangkan teknik seperti hyperparameter tuning atau augmentasi data jika diperlukan untuk meningkatkan generalisasi model. Secara keseluruhan, model ini menunjukkan potensi besar dalam tugas klasifikasi yang dihadapi, dan hasil evaluasi memberikan keyakinan akan keandalannya dalam aplikasi dunia nyata.

## REFERENCES

- [1] I. Alfiantama, M. I. Kresnawan, and A. P. Handoko, "Klasifikasi Tingkat Roasting Biji Kopi Dengan Metode CNN," *Pros. Semin. Nas. Teknol. Dan Sains Tahun 2024*, vol. 3, pp. 285–290, 2024.
- [2] Galih Wasis Wicaksono and Andreawan, "ResNet101 Model Performance Enhancement in Classifying Rice Diseases with Leaf Images," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 2, pp. 345–352, 2023, doi: 10.29207/resti.v7i2.4575.
- [3] S. N. Ria, M. Walid, and B. A. Umam, "Pengolahan Citra Digital Untuk Identifikasi Jenis Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN)," *Energy - J. Ilm. Ilmu-Ilmu Tek.*, vol. 12, no. 2, pp. 9–16, 2022, doi: 10.51747/energy.v12i2.1118.
- [4] M. F. Naufal and S. F. Kusuma, "Analisis Perbandingan Algoritma Machine Learning Dan Deep Learning Untuk Klasifikasi Citra Sistem Isyarat Bahasa Indonesia (Sibi)," *Jtiik*, vol. 10, no. 4, pp. 873–882, 2023, doi: 10.25126/jtiik.2023106828.
- [5] N. T. Adam, Z. A. Tyas, and T. Hardiani, "Deteksi Gestur Sistem Isyarat Bahasa Indonesia Menggunakan Metode Deep learning SSD MobileNet V2 FPNLite," *Sainteks*, vol. 21, no. 2, pp. 129–142, 2024, doi: 10.30595/sainteks.v21i2.24006.
- [6] Nurkhasanah and Murinto, "Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network Classification of Facial Skin Diseases Using the Method of the Convolutional Neural Network," *Sainteks*, vol. 18, no. 2, pp. 183–190, 2021.
- [7] D. D. Mahendra and F. S. Mukti, "Sistem Deteksi dan Pengendalian Serangan Denial of Service pada Server Berbasis Snort dan Telegram-API," *Techno.Com*, vol. 21, no. 3, pp. 511–522, 2022, doi: 10.33633/tc.v21i3.6466.
- [8] N. Wardhani and M. Adnan, "Kos Untuk Mahasiswa Di Luwuk Banggai Dengan Metode Saw ( Simple Additive Weighting )," 2017.
- [9] M. U. Muhammad Yudya A Hasibuan, Wahdini Marleta, Assri Yani Sibuea, Muhammad Sultan, "Klasifikasi Jenis Biji Kopi Menggunakan Convolutionalneural Network Dan Transfer Learning Pada Model Vgg16 Dan Glcm 47e954," *Senastika Univ. Malikussaleh KLASIFIKASI*, pp. 1–11, 2024.
- [10] D. S. P. Arvi Arkadia, Sekar Ayu Damayanti, "Klasifikasi Buah Mangga Badami Untuk Menentukan Tingkat Kematangan dengan Metode CNN," *Semin. Nas. Mhs. Ilmu Komput. dan Apl. Jakarta-Indonesia*, vol. 2, no. 2, pp. 158–165, 2021, [Online]. Available: <https://conference.upnvj.ac.id/index.php/senamika/article/view/1813/0>.
- [11] U. UNGKAWA and G. AL HAKIM, "Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 3, p. 731, 2023, doi: 10.26760/elkomika.v11i3.731.
- [12] R. A. Saputra, S. Wasiyanti, A. Supriyatna, and D. F. Saefudin, "Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi," *Swabumi*, vol. 9, no. 2, pp. 184–188, 2021, doi: 10.31294/swabumi.v9i2.11678.
- [13] W. Hastomo, Sugiyanto, and Sudjiran, "Convolution Neural Network Arsitektur Mobilenet-V2 Untuk Mendeteksi Tumor Otak," *Semin. Nas. Teknol. Inf. dan Komun. STI&K*, vol. 5, no. 1, pp. 17–21, 2021.
- [14] A. Fuadi and A. Suharso, "Perbandingan Arsitektur Mobilenet Dan Nasnetmobile Untuk Klasifikasi Penyakit Pada Citra Daun Kentang," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 7, no. 3, pp. 701–710, 2022, doi: 10.29100/jupi.v7i3.3026.
- [15] A. R. Freyssenita Kanditami, Deni Saepudin, "Analisis Contrast Limited Adaptive Histogram Equalization (CLAHE) dan Region Growing dalam Deteksi Gejala Kanker Payudara pada Citra Mammogram," *Elektro*, vol. 11, no. 2, pp. 1–13, 2014.
- [16] I. F. Annur, J. Umami, M. N. Annafii, N. Trisnaningrum, and O. V. Putra, "Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetv2," *Fountain Informatics J.*, vol. 8, no. 1, pp. 7–14, 2023, doi: 10.21111/fij.v8i1.9419.
- [17] G. A. Pratama, E. Y. Puspaningrum, and H. Maulana, "Convolutional Neural Network Dan Faster Region Convolutional Neural Network Untuk Klasifikasi Kualitas Biji Kopi Arabika," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 2776–2785, 2024, doi: 10.23960/jitet.v12i3.4887.
- [18] H. Rahman, R. S. D'Cruze, M. U. Ahmed, R. Sohlberg, T. Sakao, and P. Funk, "Artificial Intelligence-Based Life Cycle



- Engineering in Industrial Production: A Systematic Literature Review,” IEEE Access, vol. 10, no. December, pp. 133001–133015, 2022, doi: 10.1109/ACCESS.2022.3230637.
- [19] O. Trisnawati and M. Prastuti, “Peramalan Curah Hujan di Stasiun Juanda Menggunakan Metode ARIMA Box-Jenkins dan Radial Basis Function Neural Network,” J. Sains dan Seni ITS, vol. 11, no. 1, 2022, doi: 10.12962/j23373520.v11i1.63165.
- [20] D. Ahmad and N. Haq, “Makalah Hardware, Software Dan Brainware Komputer,” Makal. Hardware, Softw. Dan Brainware Komput., p. 22, 2019.