

**KLASIFIKASI TINGKAT KEMATANGAN ROASTING BIJI
KOPI MENGGUNAKAN CONVOLUTIONAL NEURAL
NETWORK BERBASIS MOBILENETV2**



Disusun Oleh:

Nama : Renalda Geriel R A
NIM : 21523007

**PROGRAM STUDI INFORMATIKA – PROGRAM SARJANA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM INDONESIA**

2026


HALAMAN PENGESAHAN DOSEN PEMBIMBING

**KLASIFIKASI TINGKAT KEMATANGAN ROASTING BIJI
KOPI MENGGUNAKAN CONVOLUTIONAL NEURAL
NETWORK BERBASIS MOBILENETV2**



Yogyakarta, 13 Janurai 2026

Pembimbing,


(Irving Vitra Papunungan, S.T, M.Sc., Ph.D.) (Arrie Kurniawardhani, S.Si., M.Kom.)

HALAMAN PENGESAHAN DOSEN PENGUJI

**KLASIFIKASI TINGKAT KEMATANGAN ROASTING BIJI
KOPI MENGGUNAKAN CONVOLUTIONAL NEURAL
NETWORK BERBASIS MOBILENETV2**

	
	Renalda Geriel Rafidan Arsyani
	21523007
	Yogyakarta, 13 Januari 2026
Tim Penguji	
Ketua	
Arrie Kurniawardhani, S.Si., M.Kom.	
Anggota I	
Mukhammad Andri Setiawan, S.T., M.Sc., Ph.D.	
Anggota II	
Sheila Nurul Huda, S.Kom., M.Cs.	

Mengetahui,

Ketua Program Studi Informatika – Program Sarjana

Fakultas Teknologi Industri

Universitas Islam Indonesia



(Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D.)

HALAMAN PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan di bawah ini:

Nama : Renalda Geriel R A

NIM : 21523007

Tugas akhir dengan judul:

KLASIFIKASI TINGKAT KEMATANGAN ROASTING BIJI KOPI MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK BERBASIS MOBILENETV2

Menyatakan bahwa seluruh komponen dan isi dalam tugas akhir ini adalah hasil karya saya sendiri. Apabila di kemudian hari terbukti ada beberapa bagian dari karya ini adalah bukan hasil karya sendiri, tugas akhir yang diajukan sebagai hasil karya sendiri ini siap ditarik kembali dan siap menanggung risiko dan konsekuensi apapun.

Demikian surat pernyataan ini dibuat, semoga dapat dipergunakan sebagaimana mestinya.

Yogyakarta, 13 Januari 2026



(Renalda Geriel R A)

HALAMAN PERSEMBAHAN

Skripsi ini saya persembahkan kepada kedua orang tua saya yang senantiasa memberikan doa, kasih sayang, dukungan moral, dan materi. Terima kasih atas kesabaran, pengorbanan, dan kepercayaan yang selalu mengiringi setiap langkah saya dalam menempuh pendidikan. Skripsi ini juga dipersembahkan kepada dosen pembimbing yang telah dengan penuh kesabaran memberikan arahan, bimbingan, dan ilmu yang sangat berarti. Tak lupa kepada seluruh keluarga, sahabat, dan rekan seperjuangan yang telah memberikan semangat dan dukungan selama proses penyusunan skripsi ini.

HALAMAN MOTO

“I’ve always belived that you should never, ever give up and you should always keep fighting even when there’s only slighetest chance. “

“ Aku selalu percaya bahwa kamu tidak boleh, apa pun yang terjadi, menyerah, dan kamu harus selalu terus berjuang, bahkan ketika hanya ada sedikit sekali harapan. ”

- Michael Schumacher, 7X Formula One World Champion –

“ There’s more to learn when you have failures, that is where the biggest growth comes form. “

“ Ada lebih banyak hal yang bisa dipelajari ketika kamu mengalami kegagalan, dari situlah pertumbuhan terbesar berasal.”

- Lewis Hamilton, 7X Formula One World Champion –

“ I think you can improve on everything, you’re never perfect. “

“ Aku pikir kamu selalu bisa memperbaiki segala hal, kamu tidak pernah benar-benar sempurna.”

- Max Verstappen, 4X Formula One World Champion –

“ There is no reason not to be motivated, you cannot always be the best, but you can do your best. “

“ Tidak ada alasan untuk tidak termotivasi, kamu mungkin tidak selalu bisa menjadi yang terbaik, tetapi kamu selalu bisa melakukan yang terbaik.”

- Sebastian Vettel, 4X Formula One World Champion –

KATA PENGANTAR

Puji dan syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa, karena atas rahmat dan karunia-Nya saya dapat menyelesaikan skripsi ini dengan baik. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Informatika, Fakultas Teknologi Industri, Universitas Islam Indonesia.

Penyusunan skripsi ini bertujuan untuk memenuhi persyaratan akademik jenjang Strata Satu (S1), serta sebagai bentuk penerapan dan pengembangan ilmu pengetahuan yang telah saya peroleh selama mengikuti proses perkuliahan. Selain itu, penulisan skripsi ini diharapkan dapat memberikan kontribusi, baik secara teoritis maupun praktis, sesuai dengan bidang ilmu yang dipelajari.

Pada kesempatan ini, saya menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Bapak/Ibu dosen pembimbing yang telah meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan serta arahan selama proses penyusunan skripsi.
2. Bapak/Ibu dosen penguji yang telah memberikan saran dan masukan yang membangun demi penyempurnaan skripsi ini.
3. Orang tua dan keluarga yang senantiasa memberikan doa, dukungan, serta motivasi kepada saya.
4. Teman-teman serta seluruh pihak yang telah membantu dan mendukung saya dalam menyelesaikan skripsi ini.

Saya menyadari bahwa skripsi ini masih memiliki keterbatasan dan kekurangan. Oleh karena itu, saya sangat mengharapkan kritik dan saran yang bersifat membangun guna penyempurnaan penelitian ini. Saya berharap skripsi ini dapat memberikan manfaat bagi pengembangan ilmu pengetahuan serta menjadi referensi bagi penelitian selanjutnya.

Akhir kata, semoga skripsi ini dapat memberikan manfaat bagi semua pihak yang membutuhkan.

Yogyakarta, 13 Januari 2026



(Renalda Geriel R A)

SARI

Proses *roasting* merupakan tahapan penting dalam pengolahan kopi yang sangat menentukan kualitas rasa dan aroma kopi yang dihasilkan. Tingkat kematangan *roasting* biji kopi umumnya diklasifikasikan menjadi beberapa kategori, seperti *green bean*, *light roast*, *medium roast*, dan *dark roast*. Penentuan tingkat kematangan *roasting* secara konvensional masih banyak bergantung pada pengamatan visual manusia, sehingga bersifat subjektif dan rentan terhadap kesalahan. Oleh karena itu, diperlukan suatu sistem otomatis berbasis teknologi kecerdasan buatan yang mampu mengklasifikasikan tingkat kematangan *roasting* biji kopi secara akurat dan konsisten.

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi tingkat kematangan *roasting* biji kopi berbasis citra digital menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV2*. Dataset yang digunakan berupa citra biji kopi berformat PNG yang terbagi ke dalam empat kelas, yaitu *green*, *light*, *medium*, dan *dark*. Data kemudian melalui tahap *pre-processing* yang meliputi pengaturan ukuran citra menjadi 224×224 piksel, normalisasi menggunakan fungsi *preprocess_input*, serta augmentasi data untuk meningkatkan variasi dan ketahanan model terhadap perbedaan kondisi citra.

Dataset dibagi ke dalam tiga subset, yaitu data latih sebesar 75%, data validasi sebesar 15%, dan data uji sebesar 10%. Model *MobileNetV2* digunakan sebagai *base model* dengan bobot pra-latih ImageNet dan dikombinasikan dengan beberapa lapisan tambahan seperti *Global Average Pooling*, *Dense*, *Batch Normalization*, dan *Dropout*. Proses pelatihan dilakukan dalam dua tahap, yaitu tahap *transfer learning* dengan pembekuan bobot model dasar, serta tahap *fine-tuning* dengan membuka sebagian lapisan untuk meningkatkan performa model. Evaluasi model dilakukan menggunakan metrik akurasi, *loss*, *precision*, *recall*, dan *F1-score*, serta dianalisis menggunakan *confusion matrix*.

Hasil pengujian menunjukkan bahwa model yang diusulkan mampu mengklasifikasikan tingkat kematangan *roasting* biji kopi dengan performa yang baik pada data uji. Nilai akurasi yang diperoleh menunjukkan bahwa arsitektur *MobileNetV2* efektif digunakan untuk tugas klasifikasi citra biji kopi dengan kompleksitas komputasi yang relatif rendah. Dengan demikian, sistem ini berpotensi untuk diterapkan sebagai alat bantu dalam proses kontrol kualitas *roasting* biji kopi secara otomatis dan objektif.

Kata kunci: Biji Kopi, Roasting, Klasifikasi Citra, Convolutional Neural Network, MobileNetV2.

GLOSARIUM

Akurasi	Ukuran kinerja model klasifikasi yang menunjukkan persentase prediksi yang benar dibandingkan dengan keseluruhan data yang diuji.
Artificial Intelligence (AI)	Bidang ilmu komputer yang mempelajari pengembangan sistem atau mesin yang mampu meniru kecerdasan manusia, seperti belajar, menalar, dan mengambil keputusan.
Augmentasi	
Data	Teknik prapemrosesan yang digunakan untuk meningkatkan variasi data latih dengan melakukan transformasi citra, seperti rotasi, pergeseran, pembalikan, dan perubahan kecerahan.
Batch	
Normalization	Teknik normalisasi pada jaringan saraf yang bertujuan untuk menstabilkan dan mempercepat proses pelatihan dengan menormalkan distribusi aktivasi pada setiap lapisan.
Batch Size	Jumlah data yang diproses oleh model dalam satu iterasi pelatihan.
Citra Digital	Representasi visual suatu objek dalam bentuk data numerik dua dimensi yang dapat diproses dan dianalisis oleh komputer.
Confusion Matrix	Matriks evaluasi yang menampilkan perbandingan antara label sebenarnya dan hasil prediksi model untuk setiap kelas.
Convolutional Neural Network (CNN)	Jenis jaringan saraf tiruan yang dirancang khusus untuk pengolahan data citra dengan menggunakan operasi konvolusi dalam proses ekstraksi fitur.
Data Latih	Bagian dataset yang digunakan untuk melatih model agar mampu mempelajari pola dan karakteristik data.
Data Uji	Bagian dataset yang digunakan untuk menguji kinerja akhir model setelah proses pelatihan selesai.

Data Validasi	Bagian dataset yang digunakan untuk memantau kinerja model selama proses pelatihan dan membantu mencegah terjadinya <i>overfitting</i> .
Deep Learning	Cabang dari <i>machine learning</i> yang menggunakan jaringan saraf tiruan dengan banyak lapisan untuk mempelajari representasi data yang kompleks.
Dense Layer	Lapisan jaringan saraf di mana setiap neuron terhubung dengan seluruh neuron pada lapisan sebelumnya.
Dropout	Teknik regularisasi yang menonaktifkan sejumlah neuron secara acak selama pelatihan untuk mengurangi risiko <i>overfitting</i> .
Epoch	Satu siklus penuh proses pelatihan model terhadap seluruh data latih.
Fine-Tuning	Proses penyesuaian lanjutan dengan membuka sebagian lapisan model pralatih agar dapat beradaptasi lebih baik dengan dataset penelitian.
F1-Score	Metrik evaluasi yang merupakan rata-rata harmonis antara <i>precision</i> dan <i>recall</i> .
Global Average	
Pooling	Lapisan yang mereduksi dimensi fitur dengan menghitung nilai rata-rata dari setiap <i>feature map</i> .
ImageNet	Dataset citra berskala besar yang umum digunakan untuk melatih model CNN pralatih.
Klasifikasi	Proses pengelompokan data ke dalam kelas tertentu berdasarkan karakteristik atau pola yang dipelajari.
Learning Rate	Parameter yang menentukan besar kecilnya perubahan bobot model pada setiap iterasi pelatihan.
Loss Function	Fungsi matematis yang digunakan untuk mengukur tingkat kesalahan antara hasil prediksi model dan nilai sebenarnya.
Machine Learning	Cabang dari kecerdasan buatan yang memungkinkan sistem belajar dari data tanpa diprogram secara eksplisit.
MobileNetV2	Arsitektur Convolutional Neural Network yang dirancang ringan dan efisien dengan memanfaatkan <i>depthwise separable convolution</i> dan <i>inverted residual</i> .
Overfitting	Kondisi ketika model terlalu menyesuaikan diri dengan data latih sehingga performanya menurun pada data baru.
Pra-pemrosesan	

(Pre-processing)	Tahapan awal pengolahan data sebelum pelatihan model, seperti normalisasi dan perubahan ukuran citra.
Precision	Metrik evaluasi yang menunjukkan tingkat ketepatan prediksi positif yang dihasilkan model.
Recall	Metrik evaluasi yang menunjukkan kemampuan model dalam mengenali seluruh data positif yang sebenarnya.
Roasting	Proses penyangraian biji kopi dengan suhu dan waktu tertentu untuk menghasilkan karakter rasa, aroma, dan warna tertentu.
Softmax	Fungsi aktivasi yang menghasilkan nilai probabilitas untuk setiap kelas pada masalah klasifikasi multikelas.
Transfer Learning	Metode pelatihan model dengan memanfaatkan bobot dari model pralatih yang telah dilatih pada dataset besar.

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGESAHAN DOSEN PEMBIMBING	iii
HALAMAN PENGESAHAN DOSEN PENGUJI	iv
HALAMAN PERNYATAAN KEASLIAN TUGAS AKHIR	v
HALAMAN PERSEMBAHAN	vi
HALAMAN MOTO	vii
KATA PENGANTAR	viii
SARI	ix
GLOSARIUM.....	x
DAFTAR ISI.....	xiii
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR.....	xv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	2
1.3 Batasan Masalah.....	2
1.4 Pertanyaan Penelitian	3
1.5 Tujuan dan Manfaat Penelitian.....	3
BAB II KAJIAN PUSTAKA.....	4
2.1 Biji Kopi dan Proses Roasting.....	4
2.2 Pengolahan Citra Digital	4
2.3 Machine Learning.....	5
2.4 Deep Learning	5
2.5 Convolutional Neural Network	5
2.6 MobileNetV2.....	6
2.7 Kajian Penelitian Terdahulu	6
BAB III METODOLOGI PENELITIAN	12
3.1 Desain Penelitian	12
3.2 Dataset Penelitian	13
3.3 Instrumen Penelitian.....	14
3.4 Pra-Pemrosesan Data	15
3.5 Perancangan Arsitektur Model.....	18
3.6 Proses Pelatihan Model.....	20
3.7 Evaluasi Model.....	20
3.8 Perbandingan Kinerja dan Efisiensi Model.....	20
3.9 Uji Coba Sistem.....	21
BAB IV HASIL DAN PEMBAHASAN.....	22
4.1 Kasus Pertama.....	22
4.2 Kasus Kedua.....	27
4.3 Kasus Ketiga.....	31
4.4 Perbandingan Hasil Klasifikasi.....	36
4.5 EfficientNetB0.....	37
4.6 ResNet50.....	42
4.7 Perbandingan MobileNetV2 Dengan Arsitektur Lain.....	46
4.8 Percobaan Pengujian Klasifikasi Nyata.....	48
4.9 Percobaan Pengujian Klasifikasi Lanjutan.....	51
BAB V KESIMPULAN DAN SARAN	54
5.1 Kesimpulan.....	54
5.2 Saran.....	55
DAFTAR PUSTAKA.....	56

DAFTAR TABEL

Tabel 2.1 Perbandingan Metode.....	7
Tabel 2.2 Perbandingan Arsitektur.....	9
 Tabel 3.1 Parameter Kasus Uji Coba	 20
 Tabel 4.1 Perbandingan Hasil Klasifikasi.	 36
Tabel 4.2 Perbandingan Performa Model.	46
Tabel 4.3 Perbandingan Efisiensi Model.	46

DAFTAR GAMBAR

Gambar 3.1 Diagram Alur Penelitian.....	12
Gambar 3.2 Contoh Gambar Dataset Penelitian.....	14
Gambar 3.3 Arsitektur MobileNetV2.....	18
Gambar 4.1 Grafik Akurasi dan Loss Pelatihan.....	23
Gambar 4.2 Hasil Evaluasi Akurasi dan Loss Pengujian.....	24
Gambar 4.3 Hasil Precission, Reccall, dan F1-Score.....	24
Gambar 4.4 Hasil Confusion Matrix Counts dan Normalized.....	25
Gambar 4.5 Hasil Klasifikasi.....	26
Gambar 4.6 Grafik Akurasi dan Loss Pelatihan.....	28
Gambar 4.7 Hasil Evaluasi Akurasi dan Loss Test.....	28
Gambar 4.8 Hasil Evaluasi Precission, Recall, dan F1-Score.....	29
Gambar 4.9 Hasil Confusion Matrix Counts dan Normalized.....	30
Gambar 4.10 Hasil Klasifikasi.....	31
Gambar 4.11 Grafik Akurasi dan Loss Pelatihan.....	33
Gambar 4.12 Hasil Evaluasi Akurasi dan Loss Pengujian.....	34
Gambar 4.13 Hasil Precission, Recall, dan F1-Score.....	34
Gambar 4.14 Hasil Confusion Matrix Counts dan Normalized.....	35
Gambar 4.15 Hasil Klasifikasi.....	36
Gambar 4.16 Grafik Akurasi dan Loss Pelatihan.....	38
Gambar 4.17 Hasil Evaluasi Akurasi dan Loss Pengujian.....	38
Gambar 4.18 Hasil Precision, Recall, dan F1-Score.....	39
Gambar 4.19 Hasil Confusion Matrix Counts dan Normalized.....	40
Gambar 4.20 Hasil Klasifikasi.....	41
Gambar 4.21 Grafik Akurasi dan Loss Pelatihan.....	42
Gambar 4.22 Hasil Evaluasi Akurasi dan Loss Pengujian.....	43
Gambar 4.23 Hasil Precision, Recall, dan F1-Score.....	43
Gambar 4.24 Hasil Confusion Matrix Counts dan Normalized.....	44
Gambar 4.25 Hasil Klasifikasi.....	45
Gambar 4.26 Hasil Klasifikasi Gambar Biji Kopi Nyata Kelas Green.....	48
Gambar 4.27 Hasil Klasifikasi Gambar Biji Kopi Nyata Kelas Light.....	49

Gambar 4.28 Hasil Klasifikasi Gambar Biji Kopi Nyata Kelas Medium	49
Gambar 4.29 Hasil Klasifikasi Gambar Biji Kopi Nyata Kelas Dark.....	50
Gambar 4.30 Hasil Klasifikasi Gambar Banyak Biji Kopi	51
Gambar 4.31 Hasil Klasifikasi Gambar Biji Kopi Banyak Kelas	52

BAB I PENDAHULUAN

1.1 Latar Belakang

Kopi merupakan salah satu komoditas pertanian yang memiliki nilai ekonomi tinggi dan berperan penting dalam industri pangan, baik di tingkat nasional maupun global. Kualitas akhir kopi sangat dipengaruhi oleh proses pascapanen, khususnya pada tahap penyangraian (*roasting*) biji kopi. Proses *roasting* menyebabkan terjadinya perubahan fisik dan kimia yang kompleks pada biji kopi, termasuk perubahan warna, tekstur permukaan, serta pembentukan senyawa aroma dan cita rasa yang khas.

Tingkat kematangan *roasting* umumnya diklasifikasikan ke dalam beberapa kategori, yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*. Setiap tingkat kematangan memiliki karakteristik visual yang berbeda, terutama pada warna dan tekstur permukaan biji kopi. Namun, perbedaan karakteristik visual tersebut tidak selalu bersifat kontras. Pada praktiknya, tingkat kesulitan klasifikasi meningkat pada kelas-kelas yang berdekatan secara tingkat kematangan, khususnya pada tahap transisi antara *light roast* dan *medium roast*. Pada fase ini, perbedaan warna dan tekstur sering kali bersifat subtil dan sulit dibedakan secara konsisten oleh pengamat manusia.

Permasalahan klasifikasi visual yang bersifat halus ini menjadi tantangan utama dalam penentuan tingkat kematangan *roasting* biji kopi berbasis pengamatan visual. Kesulitan tersebut tidak hanya muncul akibat keterbatasan persepsi manusia terhadap perbedaan warna yang tipis, tetapi juga dipengaruhi oleh variasi pencahayaan, sudut pengambilan gambar, serta kondisi permukaan biji kopi. Akibatnya, perbedaan hasil penilaian dapat terjadi antar pengamat maupun antar proses *roasting*, terutama ketika klasifikasi dilakukan pada skala produksi yang berkelanjutan.

Perkembangan teknologi kecerdasan buatan, khususnya pada bidang pengolahan citra digital dan *deep learning*, membuka peluang untuk mengatasi permasalahan klasifikasi visual tersebut secara otomatis. *Convolutional Neural Network* (CNN) telah terbukti efektif dalam mengekstraksi fitur visual secara hierarkis langsung dari citra, termasuk fitur warna dan tekstur yang sulit dirumuskan secara eksplisit. Namun demikian, penggunaan arsitektur CNN berukuran besar dengan jumlah parameter yang sangat banyak tidak selalu menjadi solusi yang optimal, terutama ketika objek yang diklasifikasikan memiliki kompleksitas bentuk yang relatif sederhana, tetapi perbedaan visual antar kelas bersifat halus.

Dalam konteks klasifikasi tingkat kematangan *roasting* biji kopi, tantangan utama terletak pada kemampuan model dalam membedakan perbedaan visual yang subtil antar kelas berdekatan, bukan pada pengenalan objek dengan struktur kompleks. Oleh karena itu, arsitektur CNN ringan menjadi lebih relevan karena mampu memfokuskan proses pembelajaran pada representasi fitur visual yang penting tanpa membawa kompleksitas komputasi yang berlebihan. Salah satu arsitektur CNN ringan yang banyak digunakan adalah *MobileNetV2*, yang dirancang untuk menghasilkan keseimbangan antara akurasi klasifikasi dan efisiensi komputasi melalui penggunaan *depthwise separable convolution* dan *inverted residual*.

Berdasarkan uraian tersebut, permasalahan utama dalam penelitian ini bukan hanya kebutuhan akan sistem klasifikasi otomatis, tetapi juga tantangan dalam membedakan tingkat kematangan *roasting* biji kopi yang memiliki kemiripan visual tinggi, khususnya antara *light roast* dan *medium roast*. Perbedaan visual yang bersifat subtil tersebut berpotensi menimbulkan ketidakkonsistenan hasil klasifikasi antar proses dan antar pengamat. Oleh karena itu, diperlukan suatu sistem klasifikasi otomatis berbasis citra yang mampu menangkap perbedaan visual halus secara konsisten, sekaligus memiliki efisiensi komputasi yang memadai. Penelitian ini mengusulkan penggunaan *Convolutional Neural Network* berbasis *MobileNetV2* untuk mengklasifikasikan tingkat kematangan *roasting* biji kopi sebagai upaya untuk menjawab tantangan tersebut.

1.2 Rumusan Masalah

1. Bagaimana kinerja model *Convolutional Neural Network* (CNN) berbasis *MobileNetV2* dalam mengklasifikasikan tingkat kematangan *roasting* biji kopi yang memiliki kemiripan visual tinggi antar kelas berdekatan, khususnya antara *light roast* dan *medium roast*?
2. Sejauh mana arsitektur CNN ringan seperti *MobileNetV2* mampu mencapai tingkat akurasi klasifikasi yang tinggi sekaligus mempertahankan efisiensi komputasi pada permasalahan klasifikasi citra biji kopi multikelas?

1.3 Batasan Masalah

1. Penelitian ini dibatasi pada proses klasifikasi tingkat kematangan *roasting* biji kopi berdasarkan citra dua dimensi. Penelitian ini tidak mempertimbangkan aspek lain,

seperti rasa, aroma, maupun kandungan kimia biji kopi yang dianalisis secara laboratoris.

2. Tingkat kematangan *roasting* biji kopi yang diklasifikasikan dalam penelitian ini dibatasi hanya pada empat kelas, yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*. Metode yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* dengan arsitektur *MobileNetV2* sebagai model utama.

1.4 Pertanyaan Penelitian

1. Sejauh mana model *Convolutional Neural Network* berbasis *MobileNetV2* mampu membedakan tingkat kematangan *roasting* biji kopi yang memiliki kemiripan visual tinggi antar kelas berdekatan, khususnya antara *light roast* dan *medium roast*, berdasarkan citra digital?
2. Bagaimana kinerja model *MobileNetV2* ditinjau dari keseimbangan antara akurasi klasifikasi dan efisiensi komputasi pada permasalahan klasifikasi tingkat kematangan *roasting* biji kopi multikelas?

1.5 Tujuan dan Manfaat Penelitian

Tujuan dari penelitian ini adalah untuk merancang model *Convolutional Neural Network* berbasis *MobileNetV2* dalam mengklasifikasikan tingkat kematangan *roasting* biji kopi secara otomatis. Selain itu, penelitian ini bertujuan untuk mengevaluasi kinerja model menggunakan metrik evaluasi yang relevan serta menganalisis hasil klasifikasi yang dihasilkan.

Manfaat yang diharapkan dari penelitian ini meliputi manfaat akademis dan manfaat praktis. Secara akademis, penelitian ini diharapkan dapat menjadi referensi dan bahan rujukan bagi pengembangan penelitian selanjutnya di bidang pengolahan citra digital serta penerapan metode *deep learning* pada komoditas pertanian. Secara praktis, hasil penelitian ini diharapkan dapat dimanfaatkan sebagai dasar dalam pengembangan sistem bantu otomatis pada industri kopi guna meningkatkan konsistensi mutu produk dan efisiensi proses produksi.

BAB II

KAJIAN PUSTAKA

2.1 Biji Kopi dan Proses Roasting

Biji kopi merupakan hasil dari tanaman kopi yang melalui serangkaian tahapan pascapanen sebelum siap dikonsumsi, salah satunya adalah proses penyangraian (*roasting*). Proses *roasting* dilakukan dengan pemanasan biji kopi pada rentang suhu dan durasi tertentu untuk memicu reaksi fisik dan kimia, seperti reaksi maillard, karamelisasi, serta degradasi senyawa organik. Proses ini menyebabkan perubahan signifikan pada warna, tekstur permukaan, ukuran biji, serta pembentukan aroma dan cita rasa khas kopi.

Tingkat kematangan *roasting* umumnya diklasifikasikan ke dalam beberapa kategori, yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*. Perbedaan tingkat kematangan tersebut menghasilkan variasi karakteristik visual, terutama pada warna dan tekstur permukaan biji kopi. *Green bean* memiliki warna hijau pucat dengan permukaan relatif halus, sedangkan *dark roast* memiliki warna coklat tua hingga kehitaman dengan tekstur permukaan yang lebih berminyak.

Namun demikian, perbedaan visual antar kelas tidak selalu bersifat kontras. Pada fase transisi antara *light roast* dan *medium roast*, perubahan warna dan tekstur terjadi secara bertahap dan sering kali bersifat subtil. Kondisi ini menyebabkan kesulitan dalam proses klasifikasi berbasis pengamatan visual, baik oleh manusia maupun sistem otomatis, sehingga diperlukan pendekatan yang mampu menangkap perbedaan visual halus secara konsisten.

2.2 Pengolahan Citra Digital

Pengolahan citra digital merupakan bidang ilmu yang mempelajari teknik untuk memperoleh, memproses, dan menganalisis citra menggunakan bantuan komputer. Citra digital direpresentasikan dalam bentuk matriks dua dimensi yang terdiri atas nilai intensitas piksel. Informasi visual yang terkandung dalam citra, seperti warna, tekstur, dan pola spasial, dapat diekstraksi dan dianalisis untuk berbagai keperluan, termasuk klasifikasi objek.

Dalam konteks klasifikasi citra, pengolahan citra digital berperan penting pada tahap pra-pemrosesan (*pre-processing*). Tahapan ini meliputi perubahan ukuran citra, normalisasi nilai piksel, serta augmentasi data. Tujuan utama pra-pemrosesan adalah untuk memastikan bahwa citra masukan memiliki format dan karakteristik yang sesuai dengan kebutuhan model pembelajaran mesin, sekaligus meningkatkan ketahanan model terhadap variasi kondisi citra.

2.3 Machine Learning

Machine learning merupakan cabang dari kecerdasan buatan yang berfokus pada pengembangan sistem yang mampu belajar dari data dan membuat prediksi atau keputusan tanpa diprogram secara eksplisit. Dalam pendekatan ini, model dibangun berdasarkan pola yang dipelajari dari data latih, kemudian digunakan untuk memproses data baru yang belum pernah dilihat sebelumnya.

Salah satu pendekatan utama dalam *machine learning* adalah *supervised learning*, yaitu metode pembelajaran yang menggunakan data berlabel untuk mempelajari hubungan antara masukan dan keluaran. Pendekatan ini banyak digunakan dalam permasalahan klasifikasi, termasuk klasifikasi citra, karena memungkinkan model mempelajari batas pemisah antar kelas berdasarkan data yang tersedia.

2.4 Deep Learning

Deep learning merupakan cabang lanjutan dari *machine learning* yang menggunakan jaringan saraf tiruan dengan banyak lapisan (*hidden layers*) untuk mempelajari representasi data pada berbagai tingkat abstraksi. Keunggulan utama *deep learning* terletak pada kemampuannya dalam melakukan ekstraksi fitur secara otomatis tanpa memerlukan perancangan fitur secara manual.

Dalam pengolahan citra, *deep learning* mampu mempelajari fitur visual secara hierarkis, mulai dari fitur tingkat rendah seperti tepi dan tekstur, hingga fitur tingkat tinggi yang merepresentasikan pola kompleks. Kemampuan ini menjadikan *deep learning* sangat efektif dalam menangani permasalahan klasifikasi citra dengan karakteristik visual yang kompleks maupun perbedaan antar kelas yang bersifat halus.

2.5 Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data berbentuk citra. CNN bekerja dengan menerapkan operasi konvolusi untuk mengekstraksi fitur spasial dari citra secara bertahap dan hierarkis.

Struktur CNN umumnya terdiri atas beberapa lapisan utama, yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*. Melalui kombinasi lapisan tersebut, CNN mampu

mempelajari hubungan spasial antar piksel serta menghasilkan representasi fitur yang relevan untuk tugas klasifikasi. Keunggulan CNN terletak pada kemampuannya dalam menangkap informasi visual yang sulit dirumuskan secara eksplisit, seperti perbedaan warna dan tekstur yang bersifat subtil.

2.6 MobileNetV2

MobileNetV2 merupakan salah satu arsitektur CNN yang dirancang dengan fokus pada efisiensi komputasi dan penggunaan sumber daya yang minimal. Arsitektur ini menerapkan konsep *depthwise separable convolution* dan *inverted residual* dengan *linear bottleneck* untuk mengurangi jumlah parameter dan kompleksitas komputasi tanpa mengorbankan performa secara signifikan.

Keunggulan MobileNetV2 terletak pada kemampuannya dalam menghasilkan akurasi klasifikasi yang kompetitif meskipun memiliki ukuran model yang relatif kecil. Karakteristik ini menjadikan MobileNetV2 sangat cocok untuk diterapkan pada sistem dengan keterbatasan sumber daya maupun pada permasalahan klasifikasi citra yang tidak memerlukan arsitektur sangat besar, tetapi membutuhkan kemampuan diskriminasi fitur yang halus.

2.7 Kajian Penelitian Terdahulu

Berbagai penelitian terdahulu telah menerapkan CNN untuk klasifikasi tingkat kematangan biji kopi dan objek serupa berbasis citra. Sebagian besar penelitian tersebut berfokus pada pencapaian akurasi tertinggi dengan menggunakan arsitektur CNN berukuran besar atau model yang memiliki kompleksitas tinggi. Pendekatan tersebut terbukti efektif dalam meningkatkan performa klasifikasi, terutama pada dataset dengan perbedaan visual yang kontras.

Namun demikian, terdapat beberapa keterbatasan yang masih jarang dibahas secara eksplisit dalam penelitian-penelitian sebelumnya. Pertama, mayoritas penelitian menitikberatkan evaluasi pada nilai akurasi semata, tanpa mempertimbangkan efisiensi arsitektur dan kompleksitas komputasi model. Kedua, sedikit penelitian yang secara khusus membahas tantangan klasifikasi antar kelas yang berdekatan secara visual, seperti perbedaan antara *light roast* dan *medium roast* yang memiliki karakteristik warna dan tekstur yang sangat mirip.

Selain itu, tabel perbandingan pada penelitian-penelitian sebelumnya umumnya hanya menyajikan perbedaan metode dan arsitektur secara deskriptif, tanpa diikuti dengan sintesis

ilmiah yang menjelaskan celah penelitian (*research gap*) secara eksplisit. Akibatnya, posisi kontribusi penelitian sering kali tidak dinyatakan secara tegas.

Tabel 2.1 Perbandingan Metode

Metode	Kelebihan Metode	Kekurangan Metode	Output
K-Nearest Neighbor (KNN)	Konsep sederhana dan mudah diimplementasikan, tidak memerlukan proses pelatihan yang kompleks	Sensitif terhadap noise, performa menurun pada dataset besar, dan bergantung pada pemilihan nilai k	Akurasi rendah pada citra kompleks
Support Vector Machine (SVM)	Mampu bekerja dengan baik pada data berdimensi tinggi dan memiliki generalisasi yang baik	Membutuhkan ekstraksi fitur manual dan kurang efektif untuk citra kompleks	Akurasi sedang pada klasifikasi citra
Random Forest	Tahan terhadap overfitting dan mampu menangani data non-linear	Membutuhkan fitur buatan tangan dan interpretasi model relatif sulit	Akurasi sedang hingga baik
Convolutional Neural Network (CNN)	Mampu mengekstraksi fitur secara otomatis, akurasi tinggi pada klasifikasi citra, dan adaptif terhadap variasi data	Membutuhkan sumber daya komputasi lebih besar dan waktu pelatihan lebih lama	Akurasi tinggi pada klasifikasi citra

Dalam penelitian ini, Convolutional Neural Network (CNN) dipilih sebagai metode utama karena memiliki kemampuan yang paling sesuai untuk menangani data berupa citra biji kopi. CNN dirancang secara khusus untuk memproses data visual dan mampu melakukan ekstraksi fitur spasial secara otomatis langsung dari citra mentah. Melalui lapisan konvolusi (*convolutional layers*), CNN dapat mengenali pola visual, seperti warna, tekstur permukaan,

dan bentuk objek, yang merupakan karakteristik penting dalam membedakan kelas pada citra digital (Elvin et al., 2021; Oktafanda & Siregar, 2022). Kemampuan tersebut menjadikan CNN sangat efektif dalam menangani perbedaan visual yang bersifat halus antar kelas, yang sulit ditangkap oleh metode klasifikasi konvensional (Dacipta et al., 2022).

Metode lain yang tercantum dalam tabel perbandingan tidak dipilih karena memiliki keterbatasan dalam pengolahan data citra. Metode K-Nearest Neighbor (KNN) memiliki konsep yang sederhana, namun performanya cenderung tidak stabil pada dataset berukuran besar dan sangat sensitif terhadap keberadaan *noise*. Selain itu, KNN tidak memiliki mekanisme pembelajaran fitur, sehingga kurang efektif untuk menangani citra dengan kompleksitas visual yang tinggi (Sujaini & Putra, 2019; Suryaman & Hidayat, 2021).

Metode Support Vector Machine (SVM) mampu menghasilkan kinerja yang cukup baik pada data berdimensi tinggi, tetapi memerlukan proses ekstraksi fitur secara manual sebelum tahap klasifikasi. Ketergantungan pada fitur buatan tangan (*handcrafted features*) menyebabkan SVM kurang optimal dalam menangkap variasi visual yang kompleks pada citra dengan tingkat perbedaan yang halus (Sujaini & Putra, 2019).

Selanjutnya, metode Random Forest memiliki keunggulan dalam menangani data nonlinier dan relatif tahan terhadap *overfitting*. Namun, metode ini juga bergantung pada kualitas fitur yang diekstraksi secara manual. Dalam kasus klasifikasi citra, keterbatasan tersebut menyebabkan Random Forest kurang mampu memanfaatkan informasi spasial antar piksel secara menyeluruh (Michael et al., 2023; Wijaya & Kurniawan, 2022). Berbeda dengan metode-metode tersebut, CNN mampu mempelajari fitur visual secara otomatis dan hierarkis, sehingga menghasilkan kinerja klasifikasi yang lebih tinggi dan konsisten (Oktafanda & Siregar, 2022; Elvin et al., 2021).

Berdasarkan karakteristik dataset berupa citra biji kopi yang memiliki kompleksitas visual tinggi serta perbedaan antar tingkat kematangan *roasting* yang tidak selalu terlihat secara jelas, metode Convolutional Neural Network dinilai sebagai pendekatan yang paling tepat digunakan dalam penelitian ini. Selanjutnya, arsitektur MobileNetV2 dipilih sebagai implementasi CNN karena mampu memberikan akurasi klasifikasi yang tinggi dengan kebutuhan komputasi yang relatif rendah, sehingga sesuai untuk pengembangan sistem klasifikasi citra yang efisien dan andal (Zaki et al., 2020; Ardiyansah et al., 2023; Febrianto & Nugroho, 2025).

Tabel 2.2 Perbandingan Arsitektur

Arsitektur	Kelebihan Arsitektur	Kekurangan Arsitektur	Output
VGG16	Struktur sederhana dan mudah dipahami, performa stabil pada klasifikasi citra	Jumlah parameter besar dan komputasi tinggi	Akurasi tinggi namun kurang efisien
ResNet50	Mampu menangani jaringan sangat dalam dengan residual connection	Struktur lebih kompleks dan kebutuhan komputasi relatif besar	Akurasi sangat tinggi pada citra kompleks
EfficientNetB0	Efisien dan seimbang antara kedalaman, lebar, dan resolusi jaringan	Struktur relatif lebih kompleks dibanding MobileNet	Akurasi tinggi dengan efisiensi komputasi
MobileNetV2	Ringan, efisien, dan cocok untuk transfer learning	Akurasi sedikit di bawah arsitektur besar	Akurasi tinggi dengan komputasi rendah

Arsitektur MobileNetV2 dipilih sebagai arsitektur *Convolutional Neural Network* (CNN) yang digunakan dalam penelitian ini karena dirancang untuk menghasilkan keseimbangan yang baik antara akurasi klasifikasi dan efisiensi komputasi. MobileNetV2 memiliki struktur jaringan yang ringan dengan jumlah parameter yang relatif kecil, namun tetap mampu mengekstraksi fitur visual yang penting dari citra (Zaki et al., 2020). Karakteristik tersebut sangat sesuai untuk tugas klasifikasi tingkat kematangan *roasting* biji kopi, di mana perbedaan visual antar kelas bersifat halus dan tidak memerlukan arsitektur jaringan yang sangat besar dan kompleks (Ardiyansah et al., 2023).

Arsitektur CNN lain yang tercantum dalam tabel perbandingan tidak dipilih karena pertimbangan efisiensi dan kompleksitas model. Arsitektur VGG16 memiliki struktur jaringan

yang sederhana dan mudah dipahami, namun jumlah parameternya yang sangat besar menyebabkan kebutuhan komputasi dan waktu pelatihan menjadi tinggi. Kondisi ini kurang efisien untuk penelitian dengan dataset berukuran terbatas serta berpotensi meningkatkan risiko *overfitting* (Tanuwijaya & Roseanne, 2021; Wulandari et al., 2023).

Sementara itu, arsitektur ResNet50 menawarkan keunggulan dalam menangani jaringan yang sangat dalam melalui mekanisme *residual connection* dan mampu menghasilkan akurasi yang tinggi. Namun, kompleksitas arsitektur serta kebutuhan sumber daya komputasi yang relatif besar menjadikannya kurang optimal untuk diterapkan dalam penelitian ini, terutama pada skenario penelitian dengan keterbatasan data dan sumber daya komputasi (Nigel & Rahmat, 2024; Astuti et al., 2022).

Selanjutnya, EfficientNetB0 merupakan arsitektur CNN modern yang dirancang untuk mencapai efisiensi melalui penyeimbangan kedalaman, lebar, dan resolusi jaringan. Meskipun EfficientNetB0 mampu menghasilkan akurasi yang tinggi dengan efisiensi yang baik, struktur arsitekturnya masih lebih kompleks dibandingkan MobileNetV2. Dalam konteks penelitian ini, kompleksitas tambahan tersebut tidak memberikan keuntungan yang signifikan mengingat tingkat kompleksitas visual citra biji kopi yang digunakan (Ghofur & Ulum, 2025).

MobileNetV2 menerapkan teknik *depthwise separable convolution* dan *inverted residual* yang memungkinkan model tetap efisien tanpa mengorbankan kemampuan ekstraksi fitur. Selain itu, MobileNetV2 sangat optimal ketika dikombinasikan dengan pendekatan *transfer learning*, terutama pada dataset dengan jumlah data yang terbatas. Dengan memanfaatkan bobot pralatih (*pre-trained weights*), model dapat beradaptasi lebih cepat dan menghasilkan kinerja klasifikasi yang baik (Zaki et al., 2020; Febrianto & Nugroho, 2025).

Berdasarkan pertimbangan tersebut, arsitektur MobileNetV2 dipandang sebagai pilihan yang paling tepat untuk digunakan sebagai implementasi metode CNN dalam penelitian ini, karena mampu memberikan akurasi yang tinggi, efisiensi komputasi yang baik, serta kemudahan dalam pengembangan sistem klasifikasi citra biji kopi yang andal dan berkelanjutan (Ardiansah et al., 2023; Febrianto & Nugroho, 2025).

Berdasarkan kajian terhadap penelitian-penelitian terdahulu, dapat disimpulkan bahwa mayoritas studi klasifikasi tingkat kematangan *roasting* biji kopi menggunakan CNN berfokus pada pencapaian akurasi tertinggi tanpa mempertimbangkan efisiensi arsitektur secara eksplisit. Selain itu, sebagian besar penelitian tidak membahas secara khusus tantangan klasifikasi antar kelas *roasting* yang berdekatan, seperti *light roast* dan *medium roast*, yang

memiliki perbedaan visual yang subtil di mata manusia. Oleh karena itu, penelitian ini menempati posisi sebagai studi yang menekankan keseimbangan antara akurasi dan efisiensi arsitektur CNN ringan, serta secara eksplisit menguji kemampuan model dalam menangani kelas *roasting* yang berdekatan secara visual.


BAB III

METODOLOGI PENELITIAN

3.1 Desain Penelitian

Penelitian ini menggunakan pendekatan eksperimental dengan memanfaatkan metode *deep learning* untuk menyelesaikan permasalahan klasifikasi citra. Pendekatan ini dipilih karena memungkinkan dilakukannya pengujian secara sistematis terhadap pengaruh konfigurasi model dan data terhadap kinerja sistem. Dalam penelitian ini, eksperimen dilakukan dengan melatih model klasifikasi menggunakan citra biji kopi sebagai data masukan (*input*), kemudian mengevaluasi hasil prediksi model terhadap data yang tidak terlibat dalam proses pelatihan.

Desain penelitian disusun secara fleksibel sehingga metodologi yang sama dapat diterapkan pada beberapa skenario pengujian dengan konfigurasi yang berbeda. Dengan demikian, perbedaan hasil yang diperoleh pada setiap skenario dapat dianalisis dan dibandingkan secara objektif berdasarkan metodologi yang seragam.



Gambar 3.1 Diagram Alur Penelitian

3.2 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini berupa citra digital biji kopi yang merepresentasikan berbagai tingkat kematangan *roasting*. Data citra dikumpulkan melalui sumber daring (kaggle) dengan mempertimbangkan kualitas visual citra, seperti tingkat ketajaman, pencahayaan, dan kejelasan objek biji kopi. Seluruh citra yang diperoleh kemudian diseleksi dan dikurasi untuk memastikan kesesuaian dengan kebutuhan penelitian serta meminimalkan keberadaan citra yang tidak relevan atau berkualitas rendah.

Dataset yang digunakan berjumlah 1.600 citra, yang dibagi ke dalam empat kelas tingkat kematangan *roasting*, yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*. Setiap kelas terdiri atas 400 citra, sehingga distribusi data antar kelas bersifat seimbang (*balanced dataset*). Pembagian yang seimbang ini bertujuan untuk mengurangi potensi bias model terhadap kelas tertentu serta meningkatkan keandalan hasil klasifikasi.

Untuk menjaga konsistensi struktur data dan memudahkan proses pemanggilan data secara otomatis oleh sistem, setiap kelas disimpan dalam direktori terpisah. Struktur direktori tersebut memungkinkan proses pemuatan data (*data loading*) dilakukan secara efisien menggunakan mekanisme pembacaan direktori yang disediakan oleh pustaka pembelajaran mesin.

Dalam mendukung proses pelatihan dan evaluasi model, dataset dibagi ke dalam tiga subset utama, yaitu data latih (*training set*), data validasi (*validation set*), dan data uji (*testing set*). Pembagian data dilakukan secara proporsional agar model memiliki jumlah data yang cukup untuk proses pembelajaran, pemantauan kinerja selama pelatihan, serta pengujian kemampuan generalisasi terhadap data yang tidak pernah dilihat sebelumnya. Dengan pembagian dataset tersebut, evaluasi kinerja model dapat dilakukan secara objektif dan terukur.



Gambar 3.2 Contoh Gambar Dataset Penelitian

3.3 Instrumen Penelitian

Perangkat keras yang digunakan dalam penelitian ini berupa sebuah komputer atau laptop dengan spesifikasi yang memadai untuk menangani pemrosesan data citra serta pelatihan model *machine learning*. Perangkat tersebut dilengkapi dengan prosesor AMD Ryzen 7 5800HS dan kartu grafis NVIDIA GeForce GTX 1650. Spesifikasi ini dipilih karena mampu memberikan kinerja komputasi yang cukup tinggi, khususnya dalam mempercepat proses pelatihan model *Convolutional Neural Network* (CNN) yang melibatkan perhitungan matriks dalam jumlah besar. Keberadaan GPU berperan penting dalam meningkatkan efisiensi waktu pelatihan dibandingkan dengan pemrosesan yang hanya mengandalkan CPU.

Selain perangkat keras, penelitian ini juga didukung oleh beberapa perangkat lunak yang digunakan sebagai alat utama dalam pengembangan dan pengujian sistem. Bahasa pemrograman *Python* digunakan sebagai bahasa pemrograman utama karena memiliki sintaks yang sederhana serta didukung oleh berbagai pustaka yang luas untuk pengolahan data, visualisasi, dan pengembangan model *machine learning*. Selain itu, *Python* banyak digunakan dalam penelitian ilmiah, sehingga memudahkan integrasi dengan berbagai pustaka *deep learning* yang tersedia.

Lingkungan pengembangan yang digunakan dalam penelitian ini adalah *Google Colaboratory* (*Google Colab*), yang dipilih karena menyediakan platform interaktif berbasis *cloud* untuk menulis, menjalankan, dan mendokumentasikan kode program. *Google Colab*

memungkinkan peneliti untuk menjalankan eksperimen secara fleksibel tanpa harus sepenuhnya bergantung pada sumber daya lokal, serta memudahkan proses penyimpanan, pengelolaan, dan visualisasi hasil pelatihan model.

3.4 Pra-Pemrosesan Data

Pada penelitian ini, tahap pra-pemrosesan data dirancang sebagai langkah awal yang diterapkan secara konsisten pada seluruh skenario pengujian, yaitu kasus pertama hingga kasus ketiga. Pra-pemrosesan dilakukan untuk memastikan bahwa seluruh citra biji kopi yang digunakan sebagai masukan memiliki format, ukuran, dan karakteristik yang sesuai dengan kebutuhan arsitektur model *Convolutional Neural Network* berbasis *MobileNetV2*.

Langkah awal pra-pemrosesan meliputi penyesuaian ukuran citra menjadi 224×224 piksel dengan tiga kanal warna (RGB). Ukuran ini dipilih karena merupakan ukuran standar masukan pada arsitektur *MobileNetV2*, sehingga citra dapat diproses secara optimal oleh model pralatih. Selain itu, nilai piksel citra dinormalisasi menggunakan fungsi *preprocess_input* agar distribusi data selaras dengan karakteristik bobot pralatih yang berasal dari dataset *ImageNet*.

Selanjutnya, untuk meningkatkan kinerja dan kemampuan generalisasi model, penelitian ini menerapkan teknik augmentasi data secara bertahap dengan tingkat intensitas yang berbeda pada setiap skenario pengujian. Augmentasi data hanya diterapkan pada data latih, sedangkan data validasi dan data uji tidak dikenai augmentasi agar tetap merepresentasikan kondisi data asli. Pendekatan ini bertujuan untuk menjaga objektivitas evaluasi kinerja model pada setiap skenario pengujian.

Melalui perancangan pra-pemrosesan data yang berbeda pada setiap kasus, penelitian ini bertujuan untuk menganalisis pengaruh variasi intensitas augmentasi data terhadap kinerja model klasifikasi tingkat kematangan roasting biji kopi. Dengan demikian, hasil yang diperoleh pada kasus pertama hingga kasus ketiga dapat dibandingkan secara objektif untuk menentukan strategi pra-pemrosesan yang paling efektif dan valid.

Tabel 3.1 Parameter Pra-Pemrosesan

Parameter	Data Latih	Data Validasi	Data Uji	Rotation Range	Dense Neuron	Dropout	Epoch Training	Epoch Fine-Tuning
Kasus 1	55%	35%	10%	15 derajat	32	0.3	10	5
Kasus 2	65%	25%	10%	35 derajat	64	0.5	30	15
Kasus 3	75%	15%	10%	25 derajat	128	0.4	50	25

Dalam penelitian ini, jumlah data uji pada setiap kelas ditetapkan sebanyak 40 citra dari total 400 citra per kelas. Penetapan jumlah tersebut didasarkan pada prinsip ukuran sampel minimal dalam statistika, yaitu $n \geq 30$, yang berkaitan dengan Teorema Limit Pusat (*Central Limit Theorem*). Teorema ini menyatakan bahwa rata-rata atau proporsi yang diperoleh dari sampel berukuran cukup besar akan cenderung mengikuti distribusi normal, terlepas dari distribusi populasi aslinya. Dalam praktik statistik, ukuran sampel minimal sebanyak 30 sering digunakan sebagai batas empiris agar estimasi yang dihasilkan dapat dianggap stabil dan mendekati distribusi normal.

Dalam konteks evaluasi model klasifikasi, metrik seperti akurasi, *precision*, *recall*, dan *F1-score* pada dasarnya merupakan estimasi proporsi dari jumlah prediksi yang benar terhadap total sampel uji. Apabila jumlah sampel terlalu kecil, maka perubahan satu atau dua kesalahan prediksi dapat menyebabkan fluktuasi nilai metrik yang signifikan, sehingga hasil evaluasi menjadi kurang reliabel. Dengan menggunakan 40 citra per kelas pada data uji, jumlah tersebut telah melampaui batas minimal $n \geq 30$, sehingga estimasi metrik evaluasi menjadi lebih stabil dan tidak mudah terpengaruh oleh variasi kecil pada prediksi model.

Selain itu, penggunaan 10% data sebagai data uji juga mempertimbangkan keseimbangan antara kebutuhan evaluasi yang representatif dan kebutuhan pelatihan yang optimal. Dengan total 160 citra uji dari 1600 citra keseluruhan, evaluasi tetap memiliki ukuran sampel yang memadai secara statistik, sementara sebagian besar data tetap dapat dimanfaatkan untuk proses pelatihan model. Oleh karena itu, pembagian data yang digunakan dalam penelitian ini tidak hanya mengikuti praktik umum dalam *machine learning*, tetapi juga memiliki dasar pertimbangan statistik yang dapat dipertanggungjawabkan.

Kasus pertama dirancang sebagai skenario awal untuk mengevaluasi kinerja dasar model *MobileNetV2* dalam mengklasifikasikan tingkat kematangan roasting biji kopi. Pada skenario ini, proses pra-pemrosesan data dilakukan secara minimal, yaitu penyesuaian ukuran citra

menjadi 224×224 piksel dan normalisasi nilai piksel sesuai dengan karakteristik bobot pralatih *MobileNetV2*. Teknik augmentasi data diterapkan secara ringan dengan tujuan mempertahankan karakteristik visual asli biji kopi tanpa menambahkan variasi yang berlebihan.

Pendekatan ini bertujuan untuk membangun baseline performa model sehingga kemampuan dasar *MobileNetV2* dalam mengekstraksi fitur visual, seperti warna dan tekstur permukaan biji kopi, dapat diamati secara jelas. Hasil pengujian pada kasus pertama menunjukkan bahwa model telah mampu melakukan klasifikasi dengan tingkat akurasi yang cukup baik. Namun demikian, masih ditemukan kesalahan klasifikasi pada kelas-kelas yang memiliki kemiripan visual tinggi, khususnya antara light roast dan medium roast. Hal ini mengindikasikan bahwa variasi data latih yang terbatas masih mempengaruhi kemampuan model dalam melakukan generalisasi.

Kasus kedua dikembangkan sebagai tindak lanjut dari kasus pertama dengan meningkatkan variasi data latih melalui penerapan augmentasi data pada tingkat menengah. Augmentasi yang digunakan meliputi rotasi, pergeseran, dan perubahan skala citra dalam batas yang wajar, sehingga variasi orientasi dan posisi objek biji kopi dapat direpresentasikan dengan lebih baik. Strategi ini diterapkan untuk meningkatkan ketahanan model terhadap variasi sudut pengambilan gambar dan kondisi visual yang umum terjadi pada proses pengambilan citra.

Dengan adanya penambahan variasi data yang lebih beragam, model pada kasus kedua menunjukkan peningkatan kinerja dibandingkan dengan kasus pertama. Peningkatan tersebut tercermin dari nilai akurasi, *precision*, *recall*, dan *F1-score* yang lebih stabil pada data uji. Selain itu, analisis confusion matrix menunjukkan penurunan jumlah kesalahan klasifikasi antar kelas yang berdekatan, terutama pada transisi antara light roast dan medium roast. Hasil ini menunjukkan bahwa augmentasi data dengan intensitas menengah mampu membantu model dalam mempelajari representasi fitur yang lebih robust tanpa menghilangkan karakteristik visual utama biji kopi.

Kasus ketiga dirancang sebagai tahap optimasi lanjutan yang bertujuan untuk memperoleh konfigurasi terbaik dari model *MobileNetV2* berdasarkan hasil pengamatan dan evaluasi pada kasus pertama dan kasus kedua. Pada tahap ini, penyesuaian parameter dilakukan secara lebih terarah dengan mempertimbangkan performa sebelumnya, sehingga eksperimen tidak lagi bersifat eksploratif, melainkan difokuskan pada penyempurnaan konfigurasi yang paling menjanjikan. Strategi augmentasi data diterapkan secara terkontrol dengan intensitas yang disesuaikan, sehingga variasi visual yang dihasilkan tetap realistis dan representatif terhadap kondisi citra biji kopi di dunia nyata.

Pendekatan ini merupakan penyempurnaan dari kasus kedua, dengan menekankan keseimbangan antara peningkatan variasi data dan pelestarian karakteristik visual asli objek.

Intensitas augmentasi yang tidak berlebihan bertujuan untuk menghindari distorsi visual yang dapat menurunkan kualitas representasi fitur, sekaligus tetap meningkatkan kemampuan generalisasi model. Dengan demikian, kasus ketiga tidak hanya berfungsi sebagai tahap peningkatan performa, tetapi juga sebagai proses validasi akhir untuk memastikan bahwa konfigurasi yang dipilih benar-benar menghasilkan kinerja klasifikasi yang optimal, stabil, dan dapat diandalkan.

3.5 Perancangan Arsitektur Model

Arsitektur model yang digunakan dalam penelitian ini dirancang dengan memanfaatkan pendekatan *transfer learning* menggunakan arsitektur *MobileNetV2* sebagai model dasar (*base model*). Pemilihan *MobileNetV2* didasarkan pada kemampuannya dalam mengekstraksi fitur visual secara efektif dengan kompleksitas komputasi yang relatif rendah, sehingga sesuai untuk tugas klasifikasi citra biji kopi.

Citra masukan berupa citra biji kopi berwarna (RGB) dengan ukuran 224×224 piksel dan tiga kanal warna. Ukuran ini disesuaikan dengan spesifikasi input standar pada arsitektur *MobileNetV2*. Sebelum diproses oleh model, citra telah melalui tahap pra-pemrosesan berupa perubahan ukuran dan normalisasi nilai piksel agar sesuai dengan bobot pralatih yang digunakan.

Model *MobileNetV2* digunakan sebagai *feature extractor* dengan bobot pralatih dari dataset *ImageNet*. Pada tahap awal pelatihan, bobot pada model dasar dibekukan (*frozen*) untuk mempertahankan fitur-fitur umum yang telah dipelajari, seperti tepi, tekstur, dan pola visual dasar. *MobileNetV2* memanfaatkan konsep *depthwise separable convolution* dan *inverted residual block* yang memungkinkan ekstraksi fitur dilakukan secara efisien tanpa mengorbankan kualitas representasi fitur.

Keluaran dari *MobileNetV2* selanjutnya diproses menggunakan lapisan *Global Average Pooling*. Lapisan ini berfungsi untuk mereduksi dimensi fitur dengan cara menghitung nilai rata-rata dari setiap *feature map*. Penggunaan *Global Average Pooling* membantu mengurangi jumlah parameter model serta menekan risiko terjadinya *overfitting*, dibandingkan dengan penggunaan *fully connected layer* secara langsung.

Setelah proses pooling, fitur yang dihasilkan diteruskan ke lapisan *Dense* sebagai lapisan pembelajaran tingkat lanjut. Jumlah neuron pada lapisan ini divariasikan sesuai dengan skenario pengujian, yaitu 32, 64, 128, dan 256 neuron. Variasi jumlah neuron ini bertujuan untuk mengevaluasi pengaruh kompleksitas model terhadap kemampuan klasifikasi tingkat kematangan *roasting* biji kopi.


Untuk meningkatkan kemampuan generalisasi model dan mencegah *overfitting*, diterapkan lapisan Dropout dengan nilai dropout antara 0,3 hingga 0,6. Dropout bekerja dengan

menonaktifkan sejumlah neuron secara acak selama proses pelatihan, sehingga model tidak terlalu bergantung pada neuron tertentu dan mampu mempelajari representasi fitur yang lebih robust.

Lapisan *Batch Normalization* ditambahkan setelah *Dropout* untuk menstabilkan distribusi aktivasi dan mempercepat proses konvergensi selama pelatihan. Normalisasi ini membantu menjaga kestabilan gradien serta meningkatkan performa pelatihan, terutama ketika model memiliki kompleksitas yang lebih tinggi.

Lapisan keluaran menggunakan *Dense layer* dengan fungsi aktivasi *Softmax* untuk menghasilkan probabilitas pada setiap kelas tingkat kematangan *roasting* biji kopi. Model dirancang untuk mengklasifikasikan citra ke dalam empat kelas, yaitu *green*, *light*, *medium*, dan *dark*. Nilai probabilitas tertinggi pada lapisan ini digunakan sebagai hasil prediksi akhir dari model.

Secara keseluruhan, alur arsitektur model dimulai dari citra masukan yang diproses oleh *MobileNetV2* sebagai ekstraktor fitur, dilanjutkan dengan *Global Average Pooling*, *Dense Layer*, *Dropout*, *Batch Normalization*, dan diakhiri dengan lapisan *Softmax* untuk menghasilkan klasifikasi tingkat kematangan *roasting* biji kopi. Kombinasi arsitektur ini dirancang untuk mencapai keseimbangan antara akurasi klasifikasi, kemampuan generalisasi, dan efisiensi komputasi.



Gambar 3.3 Arsitektur MobileNetV2

3.6 Proses Pelatihan Model

Pelatihan model dilakukan secara bertahap untuk memperoleh kinerja yang optimal. Pada tahap awal, model dasar (*base model*) digunakan dengan bobot yang dibekukan (*frozen weights*), sementara lapisan tambahan (*custom layers*) dilatih untuk menyesuaikan model dengan karakteristik data penelitian. Tahap ini bertujuan untuk memanfaatkan fitur-fitur umum yang telah dipelajari sebelumnya oleh model pralatih tanpa mengubah struktur dasar model secara signifikan.

Tahap selanjutnya merupakan proses penyesuaian lanjutan (*fine-tuning*), di mana sebagian lapisan pada model dasar dibuka (*unfrozen*) untuk dilatih kembali. Proses ini dilakukan dengan pengaturan parameter pelatihan yang lebih hati-hati, seperti laju pembelajaran (*learning rate*) yang lebih kecil, agar penyesuaian bobot berlangsung secara stabil. Selama proses pelatihan, digunakan mekanisme pengendalian untuk memantau kinerja model serta mencegah terjadinya *overfitting*, sehingga model yang dihasilkan memiliki kemampuan generalisasi yang baik.

3.7 Evaluasi Model

Evaluasi model dilakukan untuk menilai kemampuan model dalam melakukan klasifikasi citra secara akurat dan konsisten. Penilaian kinerja model dilakukan menggunakan data uji (*testing set*) yang tidak terlibat dalam proses pelatihan. Beberapa metrik evaluasi digunakan untuk memberikan gambaran kinerja model secara menyeluruh, termasuk metrik yang mengukur ketepatan prediksi secara umum serta kemampuan model dalam mengenali setiap kelas secara spesifik.

Selain evaluasi secara numerik, analisis kinerja model juga dilakukan menggunakan *confusion matrix* untuk mengidentifikasi pola kesalahan klasifikasi yang terjadi. Analisis ini membantu dalam memahami karakteristik kesalahan model pada masing-masing kelas serta menjadi dasar dalam interpretasi hasil pada tahap pembahasan.

3.8 Perbandingan Kinerja dan Efisiensi Model

Perbandingan kinerja dan efisiensi model dilakukan untuk memberikan justifikasi yang lebih komprehensif terhadap pemilihan arsitektur *MobileNetV2* sebagai model utama dalam penelitian ini. Selain menilai kemampuan model dalam menghasilkan prediksi yang akurat, aspek efisiensi komputasi juga menjadi pertimbangan penting, terutama dalam konteks penerapan sistem klasifikasi citra pada lingkungan dengan keterbatasan sumber daya. Oleh karena itu, *MobileNetV2* dibandingkan dengan arsitektur Convolutional Neural Network lain yang memiliki kompleksitas lebih tinggi, seperti *ResNet50* dan *EfficientNetB0*, yang dikenal

mampu menghasilkan akurasi tinggi namun membutuhkan sumber daya komputasi yang lebih besar.

Proses perbandingan dilakukan dengan menggunakan dataset, skema pra-pemrosesan, serta konfigurasi pelatihan yang sama untuk masing-masing model. Pendekatan ini bertujuan untuk memastikan bahwa perbedaan hasil yang diperoleh benar-benar disebabkan oleh karakteristik arsitektur model, bukan oleh faktor eksternal seperti perbedaan data atau parameter pelatihan. Dengan demikian, hasil perbandingan yang dihasilkan dapat dinilai secara objektif dan adil.

Evaluasi perbandingan model tidak hanya difokuskan pada nilai akurasi klasifikasi pada data uji, tetapi juga mencakup aspek efisiensi yang meliputi jumlah parameter, ukuran model, serta waktu inferensi. Jumlah parameter digunakan sebagai indikator kompleksitas model dan kebutuhan memori, sedangkan ukuran model merepresentasikan kebutuhan penyimpanan dan kemudahan proses *deployment*. Waktu inferensi diukur untuk menggambarkan kecepatan model dalam memproses satu citra masukan, yang menjadi faktor penting dalam implementasi sistem pada kondisi nyata atau sistem yang membutuhkan respons cepat.

Pengukuran waktu inferensi dilakukan dengan menjalankan proses prediksi pada citra uji secara berulang dan menghitung nilai rata-rata waktu yang dibutuhkan untuk menghasilkan satu hasil prediksi. Pendekatan ini digunakan untuk memperoleh estimasi waktu inferensi yang lebih stabil dan representatif terhadap penggunaan sistem secara aktual. Hasil pengukuran selanjutnya dianalisis untuk mengidentifikasi *trade-off* antara kinerja klasifikasi dan efisiensi komputasi pada masing-masing arsitektur.

3.9 Uji Coba Sistem

Uji coba sistem dilakukan untuk mengamati kinerja model dalam memprediksi kelas tingkat kematangan biji kopi pada citra individual. Pada tahap ini, model digunakan untuk memprediksi kelas citra masukan (*input*) serta menghasilkan nilai kepercayaan (*confidence score*) terhadap hasil prediksi tersebut. Hasil uji coba kemudian divisualisasikan untuk memudahkan interpretasi kinerja model secara kualitatif.

Metodologi yang dijelaskan dalam bab ini diterapkan secara konsisten pada seluruh skenario pengujian yang dibahas pada bab hasil dan pembahasan. Dengan pendekatan tersebut, perbedaan kinerja yang muncul pada setiap skenario pengujian dapat dianalisis secara objektif berdasarkan metodologi yang sama.

BAB IV

HASIL DAN PEMBAHASAN


4.1 Kasus Pertama

Hasil pengujian yang dilakukan menggunakan data uji menunjukkan bahwa model yang dikonfigurasi pada skenario ini mampu mencapai tingkat akurasi yang tergolong tinggi dalam melakukan klasifikasi tingkat kematangan roasting biji kopi. Nilai akurasi tersebut mengindikasikan bahwa sebagian besar citra uji berhasil diklasifikasikan sesuai dengan kelas yang sebenarnya, sehingga model telah memiliki kemampuan dasar yang baik dalam mengenali pola visual pada citra biji kopi.

Namun demikian, nilai *loss* yang diperoleh pada tahap pengujian masih relatif lebih besar apabila dibandingkan dengan nilai *loss* pada kasus-kasus selanjutnya. Kondisi ini mengindikasikan bahwa meskipun prediksi model sudah cukup akurat, tingkat kesalahan prediksi yang dihasilkan masih belum sepenuhnya minimal. Dengan kata lain, model belum secara optimal mempelajari representasi fitur visual yang paling relevan untuk membedakan seluruh kelas tingkat kematangan roasting secara konsisten, khususnya pada kelas-kelas yang memiliki kemiripan karakteristik visual.

Meskipun terdapat keterbatasan tersebut, hasil pengujian tetap menunjukkan bahwa model telah mampu membedakan kelas tingkat kematangan roasting dengan baik, terutama pada kelas *green*. Kelas *green* memiliki karakteristik visual yang sangat berbeda dibandingkan kelas lainnya, seperti warna yang lebih terang dan belum mengalami perubahan akibat proses roasting. Perbedaan visual yang jelas ini memudahkan model dalam mengenali dan mengklasifikasikan citra pada kelas tersebut dengan tingkat ketepatan yang sangat tinggi. Temuan ini menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam menangkap perbedaan visual yang kontras, meskipun masih memerlukan peningkatan lebih lanjut untuk membedakan kelas-kelas dengan perbedaan visual yang lebih halus.

4.1.1 Hasil Pelatihan Model




Gambar 4.1 Grafik Akurasi dan Loss Pelatihan

Berdasarkan grafik akurasi dan *loss* selama proses pelatihan, model menunjukkan tren pembelajaran yang stabil. Nilai akurasi pada data latih mengalami peningkatan secara bertahap seiring bertambahnya jumlah *epoch*, yang menandakan bahwa model mampu mempelajari pola visual pada citra biji kopi dengan baik. Akurasi pada data validasi juga menunjukkan peningkatan yang signifikan dan cenderung lebih tinggi dibandingkan akurasi data latih. Kondisi ini mengindikasikan bahwa model memiliki kemampuan generalisasi yang cukup baik terhadap data yang tidak terlibat secara langsung dalam proses pelatihan.

Nilai *loss* pada data latih dan data validasi menunjukkan tren penurunan yang konsisten sepanjang proses pelatihan. Penurunan nilai *loss* tersebut menandakan bahwa kesalahan prediksi model semakin berkurang seiring dengan berlangsungnya proses pembelajaran. Selain itu, tidak terlihat adanya lonjakan nilai *loss* yang signifikan pada data validasi, sehingga dapat disimpulkan bahwa model tidak mengalami *overfitting* yang berlebihan pada konfigurasi pengujian kasus pertama.


Secara keseluruhan, hasil pelatihan menunjukkan bahwa kombinasi arsitektur *MobileNetV2*, penerapan augmentasi data ringan, serta penggunaan *dropout* sebesar 0,3 mampu menghasilkan proses pelatihan yang stabil dan konvergen. Konfigurasi ini memberikan dasar yang baik untuk dilakukan pengujian pada skenario selanjutnya dengan variasi parameter yang berbeda.

4.1.2 Hasil Evaluasi Model



Gambar 4.2 Hasil Evaluasi Akurasi dan Loss Pengujian

Evaluasi model dilakukan menggunakan data uji (*testing set*) yang tidak terlibat dalam proses pelatihan maupun validasi. Berdasarkan hasil pengujian, model pada kasus pertama menghasilkan nilai akurasi sebesar 93,75% dengan nilai *loss* pengujian sebesar 0,2146. Nilai akurasi yang tinggi tersebut menunjukkan bahwa sebagian besar citra biji kopi pada data uji berhasil diklasifikasikan secara tepat sesuai dengan tingkat kematangan *roasting* yang sebenarnya.




Gambar 4.3 Hasil Precision, Reccall, dan F1-Score

Selain akurasi, evaluasi kinerja model juga dilakukan menggunakan metrik *precision*, *recall*, dan *F1-score*. Hasil evaluasi menunjukkan bahwa nilai *precision*, *recall*, dan *F1-score* berada pada kisaran 93% hingga 94%. Hasil tersebut mengindikasikan bahwa model memiliki keseimbangan yang baik antara ketepatan prediksi dan kemampuan dalam mengenali seluruh data pada masing-masing kelas.

Nilai *F1-score* yang tinggi menunjukkan bahwa model mampu mempertahankan kinerja yang konsisten pada seluruh kelas tingkat kematangan *roasting*, serta tidak mengalami penurunan performa yang signifikan pada kelas tertentu.

4.1.3 Analisis Confusion Matrix




Gambar 4.4 Hasil Confusion Matrix Counts dan Normalized

Confusion matrix digunakan untuk menganalisis lebih lanjut pola kesalahan klasifikasi yang terjadi pada data uji. Berdasarkan hasil analisis *confusion matrix*, kelas *green* menunjukkan kinerja klasifikasi yang sangat baik dengan tingkat ketepatan mencapai 100%, di mana seluruh citra *green bean* berhasil diklasifikasikan dengan benar. Hal ini disebabkan oleh perbedaan karakteristik visual yang cukup jelas antara biji kopi mentah dan biji kopi yang telah melalui proses *roasting*.

Kelas *light* juga menunjukkan tingkat klasifikasi yang tinggi, dengan sebagian besar citra pada kedua kelas tersebut berhasil diprediksi secara tepat. Kesalahan klasifikasi yang terjadi pada kedua kelas ini relatif kecil dan tidak signifikan. Sementara itu, kesalahan klasifikasi paling banyak terjadi pada kelas *medium*, yang tertukar dengan kelas *light* atau *dark*. Kondisi ini dapat dipahami karena karakteristik visual biji kopi *medium roast* berada di antara *light roast* dan *dark roast*, sehingga memiliki kemiripan warna dan tekstur permukaan.

Hasil analisis *confusion matrix* menunjukkan bahwa kesalahan klasifikasi yang terjadi lebih banyak disebabkan oleh kemiripan visual antar kelas yang berdekatan secara tingkat kematangan *roasting*, bukan karena ketidakmampuan model dalam mempelajari pola visual secara umum.

4.1.4 Hasil Klasifikasi



Gambar 4.5 Hasil Klasifikasi

Hasil visualisasi klasifikasi citra pada data uji menunjukkan bahwa model mampu menghasilkan prediksi yang sesuai dengan label asli pada setiap contoh citra yang diuji. Nilai tingkat kepercayaan (*confidence score*) yang dihasilkan oleh model bervariasi, mulai dari sekitar 68% hingga lebih dari 98%, bergantung pada tingkat kematangan *roasting* serta kejelasan karakteristik visual pada citra.

Citra biji kopi pada kelas *green* menunjukkan nilai *confidence* tertinggi karena memiliki karakteristik visual yang sangat berbeda dibandingkan dengan kelas lainnya. Sebaliknya, nilai *confidence* yang relatif lebih rendah banyak ditemukan pada kelas *medium*. Hal ini kembali menegaskan bahwa kelas *medium roast* memiliki tingkat kesulitan klasifikasi yang lebih tinggi akibat kemiripan visualnya dengan kelas *light roast* dan *dark roast*.


4.2 Kasus Kedua

Hasil pengujian pada skenario ini menunjukkan adanya peningkatan nilai akurasi yang jelas apabila dibandingkan dengan hasil yang diperoleh pada kasus pertama. Peningkatan akurasi tersebut terjadi bersamaan dengan penurunan nilai *loss* yang cukup signifikan, yang menandakan bahwa kesalahan prediksi model terhadap data uji semakin berkurang. Kondisi ini menunjukkan bahwa model tidak hanya mampu menghasilkan prediksi yang lebih tepat, tetapi juga semakin konsisten dalam mempelajari hubungan antara fitur visual citra biji kopi dan kelas tingkat kematangan roasting yang bersesuaian.

Penurunan nilai *loss* mengindikasikan bahwa model berhasil memanfaatkan tambahan variasi data latih yang diperoleh melalui peningkatan proporsi data latih serta penerapan augmentasi data dengan intensitas yang lebih tinggi. Dengan variasi citra masukan yang lebih beragam, model memiliki kesempatan untuk mempelajari karakteristik visual biji kopi dari berbagai sudut pandang dan kondisi, sehingga kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya menjadi lebih baik.

Selain itu, peningkatan nilai *precision*, *recall*, dan *F1-score* yang terlihat secara konsisten pada seluruh kelas menunjukkan bahwa model tidak hanya mengalami peningkatan akurasi secara keseluruhan, tetapi juga mampu menjaga keseimbangan kinerja pada masing-masing kelas tingkat kematangan roasting. Peningkatan *precision* menunjukkan bahwa prediksi yang dihasilkan model semakin tepat, sementara peningkatan *recall* menandakan bahwa model semakin mampu mengenali seluruh data pada setiap kelas. Nilai *F1-score* yang meningkat mengonfirmasi bahwa terdapat keseimbangan yang baik antara ketepatan dan kelengkapan prediksi, sehingga kinerja klasifikasi model pada skenario ini dapat dinilai lebih stabil dan andal dibandingkan dengan kasus pertama.

4.2.1 Hasil Pelatihan Model




Gambar 4.6 Grafik Akurasi dan Loss Pelatihan

Berdasarkan grafik akurasi dan *loss* selama proses pelatihan, model pada kasus kedua menunjukkan pola pembelajaran yang sangat stabil. Nilai akurasi pada data latih meningkat secara bertahap hingga mencapai nilai yang tinggi dan mendekati akurasi data validasi. Akurasi pada data validasi juga menunjukkan tren peningkatan yang konsisten serta relatif sejajar dengan akurasi data latih, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik.

Nilai *loss* pada data latih dan data validasi mengalami penurunan yang signifikan sejak awal pelatihan hingga mendekati akhir proses pelatihan. Meskipun terdapat fluktuasi kecil pada beberapa *epoch*, tren keseluruhan menunjukkan bahwa proses pembelajaran berlangsung secara konvergen. Tidak terlihat adanya divergensi yang mencolok antara nilai *loss* data latih dan data validasi, sehingga dapat disimpulkan bahwa peningkatan kompleksitas model pada kasus kedua tidak menyebabkan terjadinya *overfitting* yang berlebihan.


Hasil ini menunjukkan bahwa kombinasi penerapan augmentasi data yang lebih agresif, penggunaan nilai *dropout* yang lebih besar, serta jumlah *epoch* pelatihan yang lebih banyak mampu menghasilkan proses pelatihan yang lebih matang dan stabil.

4.2.2 Hasil Evaluasi Model



Gambar 4.7 Hasil Evaluasi Akurasi dan Loss Test

Evaluasi model pada kasus kedua dilakukan menggunakan data uji (*testing set*) yang sama sekali tidak terlibat dalam proses pelatihan maupun validasi. Berdasarkan hasil pengujian, model menghasilkan nilai akurasi sebesar 95,63% dengan nilai *loss* pengujian sebesar 0,0900. Peningkatan nilai akurasi serta penurunan nilai *loss* dibandingkan dengan kasus pertama menunjukkan bahwa konfigurasi yang diterapkan pada kasus kedua memberikan dampak positif terhadap kinerja model dalam mengklasifikasikan tingkat kematangan *roasting* biji kopi.




Gambar 4.8 Hasil Evaluasi Precision, Recall, dan F1-Score

Selain akurasi, hasil evaluasi pada kasus kedua menunjukkan bahwa nilai *precision*, *recall*, dan *F1-score* berada pada kisaran 95% hingga 96%. Hasil tersebut mengindikasikan bahwa model memiliki tingkat ketepatan prediksi yang tinggi sekaligus mampu mengenali hampir seluruh data pada masing-masing kelas tingkat kematangan *roasting*.

Nilai *F1-score* yang tinggi menunjukkan bahwa keseimbangan antara *precision* dan *recall* dapat dipertahankan dengan baik pada seluruh kelas, sehingga model menunjukkan kinerja yang konsisten dan andal dalam melakukan klasifikasi.

4.2.3 Analisis Confusion Matrix



Gambar 4.9 Hasil Confusion Matrix Counts dan Normalized

Analisis confusion matrix pada kasus kedua menunjukkan peningkatan performa klasifikasi pada hampir seluruh kelas dibandingkan kasus pertama. Kelas green kembali menunjukkan performa sempurna dengan tingkat klasifikasi mencapai 100%, yang menandakan bahwa model sangat mampu membedakan biji kopi mentah dari biji kopi yang telah disangrai.

Kelas dark dan medium menunjukkan tingkat ketepatan klasifikasi yang sangat tinggi, dengan jumlah kesalahan prediksi yang sangat kecil. Kelas light masih menunjukkan beberapa kesalahan klasifikasi, terutama tertukar dengan kelas medium. Namun, jumlah kesalahan tersebut lebih sedikit dibandingkan kasus pertama, yang menunjukkan bahwa peningkatan augmentasi dan jumlah epoch membantu model dalam membedakan kelas-kelas dengan karakteristik visual yang berdekatan.

Secara keseluruhan, confusion matrix pada kasus kedua menunjukkan distribusi prediksi yang lebih terfokus pada diagonal utama, yang menandakan peningkatan ketepatan klasifikasi secara menyeluruh.

4.2.4 Hasil Klasifikasi



Gambar 4.10 Hasil Klasifikasi

Hasil visualisasi klasifikasi citra pada data uji menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan dengan benar oleh model. Nilai tingkat kepercayaan (*confidence score*) yang dihasilkan cenderung lebih tinggi dibandingkan dengan kasus pertama, terutama pada kelas *green* dan *medium*. Hal ini menunjukkan peningkatan tingkat keyakinan model terhadap prediksi yang diberikan.

Meskipun demikian, beberapa kesalahan prediksi masih ditemukan pada citra yang memiliki karakteristik visual ambigu, seperti citra biji kopi *dark roast* yang diprediksi sebagai *medium roast*. Temuan ini menunjukkan bahwa meskipun kinerja model mengalami peningkatan, batas visual antara kelas-kelas tertentu yang berdekatan secara tingkat kematangan *roasting* masih menjadi tantangan dalam proses klasifikasi citra biji kopi.

4.3 Kasus Ketiga


Hasil pengujian pada skenario ini menunjukkan bahwa konfigurasi pelatihan yang diterapkan mampu menghasilkan kinerja klasifikasi terbaik dibandingkan seluruh skenario pengujian yang dilakukan dalam penelitian ini. Nilai akurasi yang diperoleh merupakan yang tertinggi di antara ketiga kasus, sementara nilai *loss* yang dihasilkan berada pada tingkat

paling rendah. Kondisi ini menunjukkan bahwa model tidak hanya mampu menghasilkan prediksi yang sangat tepat, tetapi juga memiliki tingkat kesalahan prediksi yang sangat minimal terhadap data uji.

Selain itu, nilai *precision*, *recall*, dan *F1-score* pada kasus ketiga berada pada tingkat yang sangat tinggi dan menunjukkan keseimbangan yang baik pada seluruh kelas tingkat kematangan roasting biji kopi. Tingginya nilai *precision* mengindikasikan bahwa sebagian besar prediksi yang dihasilkan oleh model bersifat tepat, sedangkan nilai *recall* yang tinggi menunjukkan bahwa model mampu mengenali hampir seluruh data pada setiap kelas secara konsisten. Nilai *F1-score* yang tinggi dan seimbang mengonfirmasi bahwa tidak terdapat dominasi kinerja pada kelas tertentu, sehingga model memiliki kemampuan generalisasi yang sangat baik.

Kinerja yang optimal pada kasus ketiga menunjukkan bahwa pemilihan konfigurasi pelatihan yang seimbang, meliputi pembagian dataset yang proporsional, intensitas augmentasi data yang moderat, kompleksitas arsitektur model yang sesuai, serta durasi pelatihan yang cukup, berperan penting dalam meningkatkan performa klasifikasi. Dengan konfigurasi tersebut, model mampu mempelajari representasi fitur visual secara efektif tanpa mengalami dampak negatif dari kompleksitas yang berlebihan, sehingga mampu melakukan klasifikasi tingkat kematangan roasting biji kopi secara akurat dan konsisten.

4.3.1 Hasil Pelatihan Model




Gambar 4.11 Grafik Akurasi dan Loss Pelatihan

Berdasarkan grafik akurasi pelatihan dan validasi, model pada kasus ketiga menunjukkan pola pembelajaran yang sangat stabil. Nilai akurasi pada data latih meningkat secara konsisten sejak awal pelatihan dan mencapai nilai yang tinggi mendekati akhir *epoch*. Akurasi pada data validasi juga menunjukkan nilai yang tinggi serta relatif sejajar dengan

akurasi data latih, yang mengindikasikan bahwa model mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya.


Nilai *loss* pada data latih dan data validasi mengalami penurunan yang signifikan pada fase awal pelatihan, kemudian cenderung stabil pada *epoch-epoch* selanjutnya. Tidak terlihat adanya divergensi yang mencolok antara nilai *loss* data latih dan data validasi, sehingga dapat disimpulkan bahwa model tidak mengalami *overfitting* yang signifikan. Stabilitas ini menunjukkan bahwa konfigurasi *dropout* dan augmentasi data yang digunakan pada kasus ketiga berada pada tingkat yang optimal.

4.3.2 Hasil Evaluasi Model



Gambar 4.12 Hasil Evaluasi Akurasi dan Loss Pengujian


Evaluasi model pada kasus ketiga dilakukan menggunakan data uji (*testing set*) yang sepenuhnya terpisah dari proses pelatihan dan validasi. Berdasarkan hasil pengujian, model menghasilkan nilai akurasi sebesar 98,75% dengan nilai *loss* pengujian sebesar 0,0372. Nilai akurasi tersebut merupakan yang tertinggi dibandingkan seluruh kasus yang telah diuji sebelumnya, yang menunjukkan bahwa konfigurasi pada kasus ketiga mampu memberikan kinerja klasifikasi yang sangat optimal.



Gambar 4.13 Hasil Precision, Recall, dan F1-Score

Selain akurasi, hasil evaluasi juga menunjukkan bahwa nilai *precision*, *recall*, dan *F1-score* pada kasus ketiga berada pada kisaran 98% hingga 99%. Hal ini mengindikasikan bahwa model tidak hanya mampu menghasilkan prediksi dengan tingkat ketepatan yang sangat tinggi, tetapi juga konsisten dalam mengenali seluruh data pada masing-masing kelas tingkat kematangan *roasting*. Nilai-nilai metrik tersebut menunjukkan keseimbangan kinerja yang sangat baik pada seluruh kelas.

4.3.3 Analisis Confusion Matrix



Gambar 4.14 Confusion Matrix Counts dan Normalized

Analisis *confusion matrix* pada kasus ketiga menunjukkan hasil yang sangat baik. Kelas *dark*, *medium*, dan *green* berhasil diklasifikasikan dengan tingkat ketepatan mencapai 100%, tanpa adanya kesalahan prediksi pada ketiga kelas tersebut. Kelas *light* menunjukkan

kinerja yang sedikit lebih rendah dibandingkan kelas lainnya, dengan satu kesalahan klasifikasi yang tertukar dengan kelas *medium*. Meskipun demikian, secara keseluruhan tingkat kesalahan pada kelas *light* masih tergolong sangat kecil.

Distribusi nilai pada *confusion matrix* yang hampir sepenuhnya terkonsentrasi pada diagonal utama menunjukkan bahwa model memiliki kemampuan diskriminasi yang sangat kuat terhadap perbedaan karakteristik visual antar tingkat kematangan *roasting* biji kopi.

4.3.4 Hasil Klasifikasi



Gambar 4.15 Hasil Klasifikasi

Visualisasi hasil klasifikasi citra pada data uji menunjukkan bahwa model mampu menghasilkan prediksi yang sangat akurat dengan tingkat kepercayaan (*confidence score*) yang sangat tinggi. Hampir seluruh citra uji menghasilkan nilai *confidence* di atas 99%, bahkan mencapai 100% pada kelas *green*. Temuan ini menunjukkan bahwa model tidak hanya mampu memberikan prediksi yang benar, tetapi juga memiliki tingkat keyakinan yang sangat kuat terhadap hasil klasifikasi yang dihasilkan.

Pada kelas *light*, meskipun nilai *confidence* yang dihasilkan cenderung sedikit lebih rendah dibandingkan dengan kelas lainnya, model tetap mampu mengklasifikasikan citra secara tepat. Hal ini mengindikasikan bahwa model telah berhasil mempelajari fitur-fitur visual halus yang membedakan kelas *light* dari kelas lainnya secara efektif.

4.4 Perbandingan Hasil Klasifikasi

Tabel 4.1 Perbandingan Hasil Klasifikasi

Parameter	Akurasi Test	Loss Test	Precision	Recall	F1- Score	Tingkat Confidence
Kasus 1	93,75%	0,2146	93%	93%	93%	Sedang
Kasus 2	95,63%	0,0900	96%	95%	95%	Tinggi
Kasus 3	98,75%	0,0372	98%	98%	98%	Tinggi

Berdasarkan tabel perbandingan hasil klasifikasi, dapat diamati adanya peningkatan kinerja model secara bertahap dari kasus pertama hingga kasus ketiga. Perubahan kinerja tersebut mencerminkan pengaruh langsung dari perbedaan konfigurasi pelatihan yang diterapkan pada setiap kasus, terutama pada strategi pra-pemrosesan data dan intensitas augmentasi yang digunakan. Pendekatan bertahap ini memungkinkan analisis yang lebih jelas terhadap pengaruh setiap konfigurasi terhadap performa model.

Pada kasus pertama, model menghasilkan kinerja yang cukup baik dan berfungsi sebagai acuan awal atau baseline dalam penelitian ini. Meskipun nilai akurasi yang diperoleh sudah tergolong tinggi, nilai loss masih relatif lebih besar dibandingkan dengan kasus-kasus selanjutnya. Kondisi ini menunjukkan bahwa model belum sepenuhnya mempelajari representasi fitur visual secara optimal. Kesalahan klasifikasi yang muncul terutama terjadi pada kelas medium, yang memiliki karakteristik visual yang berada di antara kelas light dan dark, sehingga lebih sulit dibedakan pada tahap awal pembelajaran.

Kasus kedua menunjukkan adanya peningkatan kinerja yang lebih stabil dibandingkan dengan kasus pertama. Peningkatan nilai akurasi yang diikuti dengan penurunan nilai loss mengindikasikan bahwa penambahan variasi data latih melalui augmentasi dengan intensitas menengah mampu memperkaya distribusi data masukan yang diterima model. Dengan variasi data yang lebih representatif, model menjadi lebih mampu membedakan karakteristik visual antar kelas, meskipun masih terdapat sejumlah kecil kesalahan klasifikasi, khususnya pada kelas light yang memiliki kemiripan visual dengan kelas medium.

Pada kasus ketiga, model mencapai performa klasifikasi yang paling stabil dan konsisten dibandingkan dengan skenario sebelumnya. Nilai akurasi dan metrik evaluasi lainnya menunjukkan peningkatan yang seimbang, disertai dengan nilai loss yang lebih rendah dan

stabil. Hasil ini menunjukkan bahwa strategi augmentasi data yang diterapkan secara terkontrol mampu meningkatkan kemampuan generalisasi model tanpa mengorbankan validitas data. Penurunan tingkat kesalahan klasifikasi pada kelas-kelas dengan kemiripan visual tinggi menunjukkan bahwa model mampu mempelajari representasi fitur visual secara efektif.


Akurasi tinggi yang diperoleh dalam penelitian ini bersifat relatif terhadap karakteristik permasalahan yang dihadapi. Model diuji pada skenario klasifikasi multikelas dengan empat tingkat kematangan roasting biji kopi yang memiliki kemiripan visual tinggi antar kelas berdekatan, khususnya pada transisi antara *light roast* dan *medium roast*. Selain itu, dataset yang digunakan memiliki jumlah citra yang terbatas dengan distribusi kelas yang seimbang. Dalam konteks tersebut, penggunaan arsitektur CNN ringan berbasis MobileNetV2 menunjukkan bahwa model mampu menangkap perbedaan visual yang bersifat subtil secara efektif tanpa memerlukan arsitektur dengan kompleksitas yang tinggi.

Secara keseluruhan, tabel perbandingan hasil klasifikasi menunjukkan bahwa strategi pelatihan yang seimbang, seperti yang diterapkan pada kasus ketiga, lebih efektif dibandingkan pendekatan yang hanya berfokus pada peningkatan variasi data atau kompleksitas model secara berlebihan. Temuan ini menegaskan bahwa pemilihan konfigurasi pelatihan yang tepat dan realistis memiliki peran yang sangat penting dalam menentukan keberhasilan sistem klasifikasi tingkat kematangan *roasting* biji kopi berbasis Convolutional Neural Network.

4.5 EfficientNetB0

EfficientNetB0 digunakan dalam penelitian ini sebagai model pembanding karena arsitektur ini dikenal mampu memberikan keseimbangan yang baik antara kinerja klasifikasi dan efisiensi komputasi. Dengan pendekatan *compound scaling*, EfficientNetB0 mampu mengoptimalkan kedalaman, lebar, dan resolusi jaringan secara bersamaan, sehingga menghasilkan performa yang kompetitif tanpa meningkatkan kompleksitas model secara berlebihan. Pemilihan EfficientNetB0 bertujuan untuk mengevaluasi sejauh mana arsitektur dengan desain efisiensi modern dapat meningkatkan kinerja klasifikasi tingkat kematangan roasting biji kopi jika dibandingkan dengan MobileNetV2 dan arsitektur CNN konvensional lainnya.

4.5.1 Hasil Pelatihan Model




Gambar 4.16 Grafik Akurasi dan Loss Pelatihan

Berdasarkan grafik akurasi dan loss pelatihan, model EfficientNetB0 menunjukkan proses konvergensi yang cepat dan stabil. Nilai akurasi data latih dan data validasi meningkat secara signifikan pada epoch awal dan kemudian cenderung stabil pada nilai yang tinggi. Perbedaan yang relatif kecil antara kurva akurasi data latih dan validasi mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting secara signifikan.

Grafik loss menunjukkan penurunan nilai loss data latih dan data validasi secara konsisten seiring bertambahnya jumlah epoch. Meskipun terdapat fluktuasi kecil pada loss data latih pada epoch akhir, nilai loss validasi tetap stabil, yang menunjukkan bahwa proses pelatihan berjalan dengan baik. Secara keseluruhan, EfficientNetB0 mampu mencapai performa klasifikasi yang tinggi dengan stabilitas pelatihan yang baik, namun dengan kebutuhan komputasi yang lebih besar dibandingkan MobileNetV2.


4.5.2 Hasil Evaluasi Model



Gambar 4.17 Hasil Evaluasi Akurasi dan Loss Pengujian

Berdasarkan visualisasi metrik evaluasi pada data uji, model EfficientNetB0 menghasilkan nilai akurasi pengujian sebesar 94,38% dengan nilai loss sebesar 0,1289. Nilai akurasi yang tinggi menunjukkan bahwa model mampu melakukan klasifikasi tingkat kematangan *roasting* biji kopi dengan tingkat ketepatan yang baik pada data yang tidak terlibat dalam proses pelatihan.

Sementara itu, nilai *loss* yang relatif rendah mengindikasikan bahwa kesalahan prediksi model berada pada tingkat yang kecil dan proses pembelajaran telah berlangsung secara efektif. Hasil ini menunjukkan bahwa model EfficientNetB0 memiliki kemampuan generalisasi yang baik terhadap data uji dan mampu mempertahankan performa klasifikasi yang stabil.




Gambar 4.18 Hasil Precision, Recall, dan F1-Score

Model EfficientNetB0 memperoleh nilai *precision* sebesar 95,22%, *recall* sebesar 94,38%, dan *F1-score* sebesar 94,44% pada data uji. Nilai *precision* dan *recall* yang tinggi menunjukkan bahwa model mampu menghasilkan prediksi yang akurat serta mengenali sebagian besar sampel pada setiap kelas.

Nilai *F1-score* yang tinggi mengindikasikan keseimbangan yang baik antara *precision* dan *recall*, sehingga model memiliki performa klasifikasi yang stabil. Secara keseluruhan, hasil ini menunjukkan bahwa EfficientNetB0 memiliki kinerja yang baik, meskipun dengan kebutuhan komputasi yang lebih besar dibandingkan MobileNetV2.

4.5.3 Analisis Confusion Matrix



Gambar 4.19 Hasil Confusion Matrix Counts dan Normalized

Berdasarkan confusion matrix, model EfficientNetB0 menunjukkan kemampuan klasifikasi yang sangat baik pada sebagian besar kelas tingkat kematangan roasting biji kopi. Kelas *medium* dan *green* berhasil diklasifikasikan secara sempurna, dengan seluruh sampel pada masing-masing kelas diprediksi dengan benar. Hal ini menunjukkan bahwa karakteristik visual kedua kelas tersebut dapat dipelajari secara konsisten oleh model.

Pada kelas *dark*, sebagian besar sampel berhasil diklasifikasikan dengan benar, namun masih terdapat sejumlah kecil kesalahan klasifikasi yang diprediksi sebagai kelas *medium*. Kesalahan ini mengindikasikan adanya kemiripan visual antara dark roast dan medium roast, terutama pada biji kopi dengan warna yang tidak sepenuhnya gelap. Sementara itu, pada kelas *light*, sebagian besar sampel juga berhasil dikenali dengan baik, meskipun masih terdapat kesalahan klasifikasi yang cenderung mengarah ke kelas *medium* dan *green*.

Hasil confusion matrix ter-normalisasi memperlihatkan bahwa tingkat akurasi per kelas relatif tinggi, dengan nilai tertinggi pada kelas *medium* dan *green*. Pola kesalahan yang muncul terutama terjadi pada kelas-kelas yang memiliki karakteristik visual berdekatan, yang sejalan dengan hasil evaluasi dan pembahasan sebelumnya. Secara keseluruhan, hasil ini menunjukkan bahwa EfficientNetB0 memiliki kemampuan diskriminasi kelas yang baik, namun masih menghadapi tantangan pada kelas dengan kemiripan visual tinggi.

4.5.4 Hasil Klasifikasi



Gambar 4.20 Hasil Klasifikasi


Pengujian kualitatif pada data testing menunjukkan bahwa model mampu mengklasifikasikan citra biji kopi dengan tingkat ketepatan yang tinggi pada seluruh kelas. Pada citra dengan label asli *dark*, *medium*, *light*, dan *green*, model menghasilkan prediksi yang sesuai dengan label sebenarnya dengan nilai *confidence* yang tinggi, masing-masing mencapai 99,28%, 95,70%, 90,54%, dan 99,92%. Hasil ini menunjukkan bahwa model mampu mengenali perbedaan visual utama antar tingkat kematangan roasting biji kopi secara konsisten.

Nilai *confidence* yang tinggi pada seluruh kelas mengindikasikan bahwa fitur visual seperti warna dominan, tekstur permukaan, dan karakteristik fisik biji kopi telah dipelajari dengan baik oleh model. Hasil pengujian ini memperkuat temuan evaluasi kuantitatif sebelumnya bahwa model memiliki performa klasifikasi yang stabil dan mampu memberikan prediksi yang meyakinkan pada data uji yang memiliki karakteristik serupa dengan data pelatihan.

4.6 ResNet50

ResNet50 digunakan dalam penelitian ini sebagai model pembanding karena arsitektur ini merupakan salah satu *deep convolutional neural network* yang telah terbukti mampu menghasilkan performa klasifikasi yang tinggi pada berbagai permasalahan pengolahan citra. Dengan mekanisme *residual learning*, ResNet50 mampu mengatasi permasalahan degradasi kinerja pada jaringan yang dalam, sehingga efektif dalam mengekstraksi fitur visual yang kompleks. Penggunaan ResNet50 bertujuan untuk mengevaluasi perbedaan kinerja antara arsitektur CNN berukuran besar dengan model yang lebih ringan, khususnya dalam konteks trade-off antara akurasi dan efisiensi komputasi.

4.6.1 Hasil Pelatihan Model




Gambar 4.21 Grafik Akurasi dan Loss Pelatihan

Berdasarkan grafik akurasi pelatihan, model ResNet50 menunjukkan peningkatan akurasi yang sangat cepat pada epoch awal dan kemudian stabil pada nilai yang sangat tinggi. Akurasi data latih dan data validasi sama-sama mendekati 100% pada akhir pelatihan, dengan selisih yang relatif kecil di antara keduanya. Hal ini menunjukkan bahwa arsitektur ResNet50 mampu mempelajari representasi fitur visual secara sangat efektif.

Grafik *loss* menunjukkan penurunan yang konsisten dan signifikan seiring bertambahnya jumlah epoch. Nilai *loss* data validasi yang terus menurun dan tetap rendah mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik serta tidak mengalami *overfitting* yang berarti. Secara keseluruhan, hasil ini menunjukkan bahwa ResNet50 memiliki kapasitas pembelajaran yang sangat kuat, meskipun dengan kebutuhan komputasi yang lebih besar dibandingkan arsitektur yang lebih ringan seperti MobileNetV2.


4.6.2 Hasil Evaluasi Model



Gambar 4.22 Hasil Akurasi dan Loss Pengujian

Berdasarkan hasil evaluasi pada data uji, model ResNet50 memperoleh nilai akurasi sebesar 99,37% dengan nilai *loss* sebesar 0,0132. Nilai akurasi yang sangat tinggi menunjukkan bahwa model mampu mengklasifikasikan tingkat kematangan roasting biji kopi dengan tingkat ketepatan yang hampir sempurna pada data yang tidak terlibat dalam proses pelatihan.

Nilai *loss* yang sangat rendah mengindikasikan bahwa kesalahan prediksi model berada pada tingkat yang minimal dan proses pembelajaran berlangsung secara sangat efektif. Hasil ini menunjukkan bahwa ResNet50 memiliki kapasitas representasi fitur yang sangat kuat, meskipun dengan kebutuhan komputasi dan kompleksitas model yang lebih besar dibandingkan arsitektur yang lebih ringan.




Gambar 4.23 Hasil Precision, Recall, dan F1-Score

Berdasarkan hasil evaluasi pada data uji, model ResNet50 memperoleh nilai *precision* sebesar 99,39%, *recall* sebesar 99,38%, dan *F1-score* sebesar 99,37%. Nilai yang sangat tinggi pada ketiga metrik tersebut menunjukkan bahwa model mampu menghasilkan prediksi yang sangat akurat sekaligus mengenali hampir seluruh sampel pada setiap kelas tingkat kematangan roasting biji kopi.

Keseimbangan antara nilai *precision* dan *recall* yang hampir identik tercermin pada nilai *F1-score* yang juga sangat tinggi. Hasil ini mengindikasikan bahwa ResNet50 memiliki kemampuan klasifikasi yang sangat kuat dan konsisten, meskipun diperoleh dengan kompleksitas arsitektur dan kebutuhan komputasi yang lebih besar dibandingkan model yang lebih ringan.

4.6.3 Analisis Confusion Matrix




Gambar 4.24 Hasil Confusion Matrix Counts dan Normalized

Berdasarkan *confusion matrix*, model ResNet50 menunjukkan performa klasifikasi yang hampir sempurna pada seluruh kelas tingkat kematangan roasting biji kopi. Kelas medium, light, dan green berhasil diklasifikasikan secara sempurna tanpa kesalahan prediksi. Sementara itu, pada kelas dark terdapat satu sampel yang diprediksi sebagai medium, sehingga tingkat kesalahan pada kelas ini sangat kecil.

Hasil *confusion matrix* ter-normalisasi menunjukkan bahwa tingkat akurasi per kelas mendekati 100%, dengan nilai 1,00 pada kelas medium, light, dan green, serta 0,97 pada kelas dark. Pola kesalahan yang sangat minim ini menunjukkan bahwa ResNet50 memiliki kemampuan diskriminasi fitur yang sangat kuat dan mampu membedakan perbedaan visual antar kelas secara konsisten. Namun demikian, capaian ini diperoleh dengan kompleksitas arsitektur dan kebutuhan komputasi yang lebih tinggi dibandingkan model yang lebih ringan.

4.6.4 Hasil Klasifikasi



Gambar 4.25 Hasil Klasifikasi

Pengujian kualitatif pada data testing menunjukkan bahwa model ResNet50 mampu mengklasifikasikan seluruh citra biji kopi dengan sangat akurat. Pada citra dengan label asli dark, medium, light, dan green, model menghasilkan prediksi yang sesuai dengan label sebenarnya dengan nilai *confidence* yang sangat tinggi, masing-masing sebesar 99,99%, 100,00%, 100,00%, dan 100,00%. Hasil ini menunjukkan bahwa model memiliki kemampuan diskriminasi fitur visual yang sangat kuat.

Nilai *confidence* yang mendekati sempurna pada seluruh kelas mengindikasikan bahwa model mampu mengenali perbedaan warna, tekstur, dan karakteristik fisik biji kopi secara konsisten. Temuan ini sejalan dengan hasil evaluasi kuantitatif sebelumnya, yang menunjukkan bahwa ResNet50 memiliki performa klasifikasi yang sangat tinggi pada data uji, meskipun diperoleh dengan kompleksitas arsitektur dan kebutuhan komputasi yang lebih besar dibandingkan model yang lebih ringan.

4.7 Perbandingan MobileNetV2 Dengan Arsitektur Lain

Tabel 4.2 Perbandingan Performa Model

Model	Akurasi Test	Loss Test	Precision	Recall	F1-Score	Tingkat Confidence	Stalabilitas Model
MobileNetV2	98,75%	0,0372	98%	98%	98%	Tinggi	Stabil dan efisien
EfficientNet B0	94,38%	0,1289	95%	94%	94%	Tinggi	Stabil, fluktuasi kecil
ResNet50	99,37%	0,0132	99%	99%	99%	Tinggi	Sangat stabil

Berdasarkan tabel perbandingan kinerja model, dapat diamati bahwa ketiga arsitektur menunjukkan performa klasifikasi yang sangat baik pada tugas klasifikasi tingkat kematangan roasting biji kopi. ResNet50 memperoleh nilai akurasi tertinggi sebesar 99,37% dengan nilai *loss* terendah yaitu 0,0132. Nilai *precision*, *recall*, dan *F1-score* yang masing-masing mencapai 99% menunjukkan bahwa model ini memiliki kemampuan diskriminasi fitur yang sangat kuat dan konsisten pada seluruh kelas. Selain itu, stabilitas model dinilai sangat baik dengan proses pelatihan yang sangat stabil dan konvergen.

MobileNetV2, sebagai model dengan kompleksitas lebih ringan, menunjukkan performa yang tetap kompetitif dengan akurasi 98,75% dan nilai *loss* sebesar 0,0372. Nilai *precision*, *recall*, dan *F1-score* yang mencapai 98% menunjukkan bahwa model ini mampu mempertahankan kinerja yang tinggi meskipun dengan jumlah parameter yang lebih sedikit dibandingkan ResNet50. Tingkat *confidence* yang tinggi serta stabilitas pelatihan yang konvergen menunjukkan bahwa MobileNetV2 memiliki keseimbangan yang baik antara akurasi dan efisiensi.

EfficientNetB0 memperoleh akurasi sebesar 94,38% dengan nilai *loss* 0,1289. Meskipun performanya sedikit lebih rendah dibandingkan dua model lainnya, nilai *precision*, *recall*, dan *F1-score* yang berada pada kisaran 94–95% tetap menunjukkan kemampuan klasifikasi yang baik. Model ini tergolong stabil dengan fluktuasi kecil selama pelatihan, serta menghasilkan tingkat *confidence* yang tinggi pada pengujian.

Secara keseluruhan, tabel tersebut menunjukkan adanya *trade-off* antara kompleksitas arsitektur dan performa. ResNet50 memberikan performa tertinggi namun dengan kompleksitas yang besar, MobileNetV2 menawarkan keseimbangan antara akurasi dan efisiensi, sedangkan EfficientNetB0 berada di tengah dengan kinerja yang baik namun sedikit di bawah dua model lainnya. Temuan ini mendukung pemilihan MobileNetV2 sebagai model

utama ketika mempertimbangkan keseimbangan antara performa dan efisiensi komputasi.

Tabel 4.3 Perbandingan Efisiensi Model

Model	Waktu Inferensi	Jumlah Parameter	Ukuran Model
MobileNetV2	70 - 80 mili detik	2,422,980	10.86 MB
EfficientNetB0	80 - 90 mili detik	4,214,567	38.24 MB
ResNet50	1 - 1.2 detik	23,851,012	216.22 MB

Berdasarkan tabel perbandingan efisiensi model, terlihat perbedaan yang signifikan pada aspek waktu inferensi, jumlah parameter, dan ukuran model antara MobileNetV2, EfficientNetB0, dan ResNet50. MobileNetV2 memiliki waktu inferensi paling cepat, yaitu sekitar 70–80 milidetik per gambar, dengan jumlah parameter sebesar 2.422.980 dan ukuran model 10,86 MB. Nilai ini menunjukkan bahwa MobileNetV2 merupakan arsitektur yang paling ringan dan efisien dari sisi komputasi serta kebutuhan penyimpanan.

EfficientNetB0 memiliki waktu inferensi sedikit lebih lambat, yaitu 80–90 milidetik, dengan jumlah parameter 4.214.567 dan ukuran model 38,24 MB. Meskipun masih tergolong efisien dibandingkan model besar, kompleksitasnya lebih tinggi dibandingkan MobileNetV2. Hal ini menunjukkan bahwa peningkatan kapasitas representasi fitur pada EfficientNetB0 berdampak pada peningkatan kebutuhan sumber daya.

ResNet50 menunjukkan perbedaan yang paling mencolok, dengan waktu inferensi 1–1,2 detik per gambar, jumlah parameter 23.851.012, dan ukuran model 216,22 MB. Kompleksitas arsitektur yang jauh lebih besar menyebabkan kebutuhan komputasi dan penyimpanan meningkat secara signifikan. Meskipun model ini menghasilkan performa klasifikasi tertinggi, biaya komputasi yang dibutuhkan juga paling besar.

Secara keseluruhan, tabel ini menunjukkan adanya hubungan langsung antara kompleksitas arsitektur dan efisiensi komputasi. MobileNetV2 menawarkan efisiensi tertinggi dengan performa yang tetap kompetitif, EfficientNetB0 berada pada tingkat menengah, sedangkan ResNet50 memberikan performa maksimal dengan konsekuensi kebutuhan sumber daya yang jauh lebih besar. Temuan ini memperkuat argumen bahwa pemilihan model tidak hanya didasarkan pada akurasi, tetapi juga pada pertimbangan efisiensi dan potensi implementasi di lingkungan dengan keterbatasan sumber daya.

4.8 Percobaan Pengujian Klasifikasi Nyata

Pada tahap selanjutnya, dilakukan percobaan pengujian klasifikasi menggunakan citra biji kopi yang diperoleh langsung dari kondisi nyata di lapangan. Citra diambil menggunakan kamera *smartphone* dengan latar belakang sederhana dan pencahayaan alami tanpa pengaturan khusus, sehingga merepresentasikan kondisi pengambilan gambar yang lebih realistis dibandingkan dataset pelatihan. Pengujian ini bertujuan untuk mengevaluasi kemampuan generalisasi model MobileNetV2 ketika dihadapkan pada citra yang benar-benar baru dan tidak terkurasi.

Pengujian dilakukan terhadap empat citra biji kopi yang masing-masing merepresentasikan tingkat kematangan roasting yang berbeda, yaitu green, light, medium, dan dark. Setiap citra diklasifikasikan secara individual menggunakan model dengan konfigurasi terbaik yang telah diperoleh pada pengujian sebelumnya. Model menghasilkan prediksi kelas beserta nilai tingkat kepercayaan (*confidence score*) sebagai indikator keyakinan model terhadap hasil klasifikasi.



Gambar 4.26 Hasil Klasifikasi Gambar Biji Kopi Nyata Kelas Green

Berdasarkan hasil pengujian, citra biji kopi pertama diprediksi sebagai kelas *green* dengan nilai *confidence* sebesar 77,44%. Nilai ini menunjukkan bahwa model mampu mengenali karakteristik visual *green bean*, seperti warna biji yang relatif pucat dan belum mengalami proses *roasting*. Namun, tingkat *confidence* yang lebih rendah dibandingkan kelas lain mengindikasikan bahwa perbedaan visual antara *green bean* dan *light roast* masih memiliki potensi ambiguitas, terutama ketika pencahayaan mempengaruhi persepsi warna pada citra.



Gambar 4.27 Hasil Klasifikasi Gambar Biji Kopi Nyata Kelas Light

Pada citra kedua, model memprediksi kelas *light roast* dengan nilai *confidence* sebesar 95,81%. Nilai *confidence* yang tinggi ini menunjukkan bahwa model mampu mengenali ciri visual khas *light roast* dengan sangat baik, seperti warna coklat muda yang relatif seragam dan tekstur permukaan biji yang masih cukup halus. Hasil ini mengindikasikan bahwa representasi fitur visual untuk kelas *light* telah dipelajari secara efektif oleh model, meskipun pada evaluasi kuantitatif sebelumnya kelas ini masih menunjukkan tingkat ambiguitas tertentu.



Gambar 4.28 Hasil Klasifikasi Gambar Biji Kopi Nyata Kelas Medium

Citra ketiga diprediksi sebagai kelas *medium roast* dengan nilai *confidence* sebesar 85,92%. Hasil ini menunjukkan bahwa model mampu membedakan karakteristik visual *medium roast*, yang berada di antara *light* dan *dark roast*, dengan tingkat keyakinan yang cukup

tinggi. Nilai *confidence* yang sedikit lebih rendah dibandingkan kelas *dark* menunjukkan bahwa *medium roast* tetap menjadi kelas yang menantang akibat kemiripan visualnya dengan kelas lain, namun model masih mampu menghasilkan prediksi yang konsisten pada kondisi citra nyata.



Gambar 4.29 Hasil Klasifikasi Gambar Biji Kopi Nyata Kelas Dark

Pada citra keempat, model memprediksi kelas *dark roast* dengan nilai *confidence* tertinggi, yaitu 99,20%. Hasil ini menunjukkan bahwa model sangat yakin dalam mengenali karakteristik visual *dark roast*, seperti warna biji yang gelap, permukaan yang lebih berminyak, dan tekstur yang lebih kasar akibat proses *roasting* tingkat tinggi. Tingginya nilai *confidence* pada kelas ini konsisten dengan hasil evaluasi sebelumnya, di mana kelas *dark* cenderung memiliki tingkat kesalahan klasifikasi yang paling rendah.

Secara keseluruhan, hasil percobaan pengujian klasifikasi nyata menunjukkan bahwa model MobileNetV2 mampu mempertahankan kinerja klasifikasi yang baik pada citra dunia nyata, meskipun dilatih menggunakan dataset terkurasi. Variasi nilai *confidence* antar kelas mencerminkan tingkat kesulitan klasifikasi yang berbeda-beda, terutama pada kelas-kelas dengan kemiripan visual tinggi seperti *light* dan *medium*. Temuan ini menguatkan hasil evaluasi kuantitatif sebelumnya serta menunjukkan bahwa model memiliki potensi untuk diterapkan pada kondisi nyata, dengan catatan bahwa peningkatan variasi data pelatihan dan pengujian dapat lebih lanjut meningkatkan *robustnes* dan konsistensi prediksi model.

4.9 Percobaan Pengujian Klasifikasi Lanjutan

Pada tahap akhir, dilakukan pengujian lanjutan menggunakan citra biji kopi nyata dengan tingkat kompleksitas visual yang lebih tinggi dibandingkan pengujian sebelumnya. Pengujian ini bertujuan untuk mengevaluasi konsistensi dan stabilitas prediksi model MobileNetV2 ketika dihadapkan pada citra yang memuat banyak biji kopi dalam satu gambar serta variasi tingkat kematangan *roasting* yang berbeda.



Gambar 4.30 Hasil Klasifikasi Gambar Banyak Biji Kopi

Pada pengujian pertama, digunakan citra yang menampilkan beberapa biji kopi dengan tingkat kematangan yang relatif seragam. Berdasarkan hasil klasifikasi, model memprediksi citra tersebut sebagai kelas *light roast* dengan nilai tingkat kepercayaan sebesar 95,63%. Nilai *confidence* yang tinggi menunjukkan bahwa model mampu mengenali karakteristik visual dominan pada citra, seperti warna cokelat muda yang relatif homogen dan tekstur permukaan biji kopi yang serupa. Hasil ini mengindikasikan bahwa meskipun jumlah objek dalam citra lebih dari satu, model tetap mampu mempertahankan prediksi yang konsisten selama karakteristik visual utama masih didominasi oleh satu kelas tertentu.



Gambar 4.31 Hasil Klasifikasi Gambar Biji Kopi Banyak Kelas

Pengujian selanjutnya dilakukan menggunakan citra yang menampilkan beberapa kelompok biji kopi dengan tingkat kematangan *roasting* yang berbeda dalam satu gambar. Pada citra ini terdapat variasi visual yang cukup signifikan, mulai dari biji kopi berwarna terang hingga biji kopi berwarna sangat gelap. Berdasarkan hasil klasifikasi, model memprediksi citra tersebut sebagai kelas *dark roast* dengan nilai tingkat kepercayaan sebesar 58,20%. Nilai confidence yang relatif lebih rendah menunjukkan bahwa model berada dalam kondisi ketidakpastian prediksi akibat tidak adanya satu kelas yang benar-benar dominan secara visual.

Prediksi kelas dark pada citra multi-kelas ini menunjukkan bahwa model cenderung memilih kelas dengan karakteristik visual yang paling kontras dan menonjol, seperti warna biji yang lebih gelap dan tekstur permukaan yang lebih kasar. Namun demikian, keberadaan biji kopi dengan tingkat kematangan yang lebih rendah dalam jumlah yang cukup signifikan menyebabkan representasi fitur visual menjadi saling tumpang tindih, sehingga menurunkan tingkat keyakinan model dalam menentukan satu kelas yang paling tepat.

Hasil pengujian lanjutan ini menunjukkan bahwa model MobileNetV2 memiliki kemampuan generalisasi yang cukup baik pada citra nyata dengan banyak objek, terutama ketika tingkat kematangan roasting relatif seragam. Namun, ketika dihadapkan pada citra dengan variasi kelas yang bercampur, tingkat confidence model cenderung menurun. Temuan ini konsisten dengan hasil evaluasi sebelumnya yang menunjukkan bahwa kelas-kelas dengan kemiripan visual tinggi serta citra dengan distribusi kelas yang tidak homogen merupakan kondisi yang paling menantang bagi model.

Secara keseluruhan, pengujian lanjutan pada kondisi nyata memperkuat temuan bahwa model MobileNetV2 mampu memberikan prediksi yang stabil pada citra dengan dominasi satu kelas, namun masih memiliki keterbatasan dalam menangani citra multi-kelas dalam satu gambar. Hasil ini memberikan dasar yang kuat untuk pengembangan lanjutan, seperti penambahan variasi data pelatihan dengan banyak objek, penerapan pendekatan deteksi objek, atau strategi klasifikasi berbasis segmentasi agar model lebih adaptif terhadap kondisi nyata di lapangan.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan *Convolutional Neural Network* berbasis *MobileNetV2* mampu mengklasifikasikan tingkat kematangan *roasting* biji kopi ke dalam empat kelas, yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*, dengan tingkat akurasi yang sangat tinggi. Hasil pengujian menunjukkan bahwa model dapat bekerja secara konsisten pada dataset citra biji kopi multikelas yang memiliki perbedaan visual tidak selalu kontras.

Penelitian ini menunjukkan bahwa arsitektur CNN ringan seperti *MobileNetV2* efektif dalam menangani permasalahan klasifikasi citra dengan kompleksitas objek yang relatif sederhana, tetapi memiliki tantangan visual yang bersifat subtil antar kelas berdekatan. Secara khusus, model mampu mengenali perbedaan visual pada fase transisi tingkat kematangan *roasting*, meskipun kesalahan klasifikasi masih lebih sering terjadi pada kelas yang memiliki kemiripan visual tinggi, terutama antara *light roast* dan *medium roast*. Temuan ini mengonfirmasi bahwa tantangan utama klasifikasi tidak terletak pada pengenalan objek, melainkan pada diskriminasi fitur visual halus.

Hasil eksperimen dengan berbagai konfigurasi pelatihan menunjukkan bahwa peningkatan kompleksitas model, intensitas augmentasi data, dan durasi pelatihan tidak selalu menghasilkan peningkatan kinerja klasifikasi yang signifikan. Pada skenario dengan konfigurasi ekstrem, model menunjukkan indikasi saturasi performa (*performance saturation*), di mana akurasi dan metrik evaluasi lainnya tidak meningkat secara sebanding dengan kompleksitas yang ditambahkan. Sebaliknya, konfigurasi pelatihan yang seimbang terbukti menghasilkan kinerja klasifikasi terbaik dengan stabilitas yang lebih baik.

Dengan demikian, penelitian ini menyimpulkan bahwa pemilihan arsitektur CNN ringan yang tepat serta perancangan konfigurasi pelatihan yang proporsional merupakan faktor kunci dalam klasifikasi tingkat kematangan *roasting* biji kopi berbasis citra. Pendekatan ini mampu mencapai keseimbangan antara akurasi klasifikasi yang tinggi dan efisiensi komputasi, sehingga berpotensi untuk diterapkan pada sistem pemantauan mutu kopi berbasis citra secara praktis dan berkelanjutan.

5.2 Saran

Berdasarkan hasil penelitian dan kesimpulan yang diperoleh, terdapat beberapa saran yang dapat dijadikan pertimbangan untuk pengembangan penelitian selanjutnya:

Penelitian selanjutnya disarankan untuk menggunakan dataset dengan variasi kondisi pencahayaan, latar belakang, dan jenis kamera yang lebih beragam agar kemampuan generalisasi model terhadap kondisi dunia nyata dapat dievaluasi secara lebih komprehensif.

Untuk mengatasi tantangan klasifikasi antar kelas yang berdekatan secara visual, khususnya antara *light roast* dan *medium roast*, penelitian lanjutan dapat mengombinasikan pendekatan klasifikasi citra dengan fitur tambahan, seperti analisis warna kuantitatif atau integrasi data non-visual.

Penelitian selanjutnya dapat mengeksplorasi arsitektur CNN ringan lainnya atau melakukan perbandingan efisiensi yang lebih mendalam antara beberapa arsitektur ringan, sehingga diperoleh pemahaman yang lebih luas mengenai trade-off antara akurasi dan kompleksitas komputasi.

Pengujian model pada lingkungan implementasi nyata, seperti sistem *real-time* atau perangkat dengan keterbatasan sumber daya, disarankan untuk menilai kelayakan penerapan model dalam konteks industri kopi secara langsung.

Penelitian ini masih terbatas pada klasifikasi tingkat kematangan *roasting* berdasarkan citra dua dimensi. Oleh karena itu, pengembangan selanjutnya dapat mempertimbangkan penggunaan data multimodal atau pendekatan tiga dimensi untuk meningkatkan ketepatan klasifikasi pada kondisi visual yang sangat ambigu.

Dengan adanya saran-saran tersebut, diharapkan penelitian ini dapat menjadi landasan yang kuat bagi pengembangan sistem klasifikasi citra berbasis *deep learning* yang lebih akurat, efisien, dan aplikatif di masa mendatang.

DAFTAR PUSTAKA

- Ardiyansah, A., Prasetyo, L. B., & Wibowo, A. (2023). Rice variety identification system based on drone images using MobileNetV2 transfer learning. *Indonesian Journal of Agronomy*, 51(2), 123–131.
- Astuti, R. P., Nugraha, A. L., & Hidayat, R. (2022). Vegetation classification algorithm using convolutional neural network (ResNet50) for vegetation mapping in Bandung district area. *Infotel*, 14(2), 89–97. <https://doi.org/10.20895/infotel.v14i2.756>
- Dacipta, P. N., Rahman, F., & Prabowo, D. A. (2022). Sistem klasifikasi limbah menggunakan metode convolutional neural network berbasis web service. *Jurnal Teknologi Informasi*, 10(1), 45–53.
- Elvin, E., Saputra, R., & Wijaya, H. (2021). Klasifikasi citra ikan menggunakan convolutional neural network. *JIKSI (Jurnal Ilmiah Koneksi Sistem Informasi)*, 10(1), 15–23. <https://doi.org/10.24912/jiksi.v10i1.17827>
- Febrianto, W., & Nugroho, A. (2025). Perbandingan VGG16 dan MobileNetV2 untuk klasifikasi tingkat kematangan buah apel. *Jurnal Sistem Informasi dan Komputasi*, 4(1), 33–41.
- Ghofur, M. A., & Ulum, A. B. (2025). Analisis perbandingan kinerja model ResNet50 dan EfficientNet-B0 dalam klasifikasi kerusakan jalan. *Jurnal Media Informatika*, 6(5), 211–220.
- Hendarawan, I. E. (2023). Klasifikasi retak ban kendaraan menggunakan arsitektur ResNet50. *Science, Technology and Nursing Journal*, 9(1), 77–85. <https://doi.org/10.33372/stn.v9i1.902>
- Kurniawan, M. B., Putra, D. R., & Lestari, S. (2025). Perbandingan kinerja ResNet50, VGG16, dan MobileNetV2 untuk klasifikasi tumor otak berbasis citra MRI. *Jurnal Informatika Medis Indonesia*, 3(2), 101–110.
- Michael, A., Prasetyo, E., & Wibowo, A. (2023). Kombinasi pretrained model dan random forest pada klasifikasi bakso mengandung boraks dan non-boraks berbasis citra. *Teknika*, 12(1), 56–64. <https://doi.org/10.34148/teknika.v12i1.591>
- Nigel, N., & Rahmat, B. (2024). Klasifikasi citra penyakit kanker mulut menggunakan arsitektur ResNet50. *Jurnal Informatika dan Rekayasa Elektronik*, 7(1), 1–9. <https://doi.org/10.36595/jire.v7i1.1186>

- Oktafanda, E., & Siregar, R. (2022). Klasifikasi citra kualitas bibit kelapa sawit menggunakan convolutional neural network. *Jurnal Informatika Komputer*, 8(2), 95–104. <https://doi.org/10.35959/jik.v8i2.179>
- Santoso, I., Nugraha, R., & Fadli, M. (2025). Comparison of ResNet50, EfficientNet, and VGG16 for medical image classification. *Journal of Artificial Intelligence and Computation*, 5(1), 21–30.
- Satria, M. R. (2022). Image captioning menggunakan metode ResNet50 dan long short-term memory. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(4), 721–728. <https://doi.org/10.25126/jtiik.2020763651>
- Sujaini, H., & Putra, A. (2019). Klasifikasi citra alat musik tradisional menggunakan metode k-nearest neighbor, random forest, dan support vector machine. *Jurnal Sistem Informasi Bisnis*, 9(2), 185–191. <https://doi.org/10.21456/vol9iss2pp185-191>
- Suryaman, S. A., & Hidayat, T. (2021). Klasifikasi cuaca menggunakan metode VGG16 dan k-nearest neighbor. *Jurnal Penelitian Teknologi Informasi*, 6(2), 66–74.
- Tanuwijaya, E., & Roseanne, A. (2021). Modifikasi arsitektur VGG16 untuk klasifikasi citra digital rempah-rempah Indonesia. *MATRIK: Jurnal Matematika dan Riset Informatika*, 21(1), 1–8. <https://doi.org/10.30812/matrik.v21i1.1492>
- Vincen, V., & Hartono, D. (2022). Brahmi script classification using convolutional neural network based on VGG16 architecture. *Prosiding Seminar Nasional Informatika*, 4(1), 88–94.
- Wijaya, W., & Kurniawan, D. (2022). Klasifikasi monkeypox menggunakan ekstraksi fitur GLCM dan algoritma random forest. *Jurnal Sistem Cerdas*, 5(2), 143–150.
- Wulandari, S. A., Nugroho, A., & Prasetyo, E. (2023). DjunkGo: A mobile application for trash classification with VGG16 algorithm. *GMPI Conference Series*, 2, 175–182. <https://doi.org/10.53889/gmpics.v2.175>
- Zaki, S. Z. M., Pranata, Y., & Rahman, A. (2020). Classification of tomato leaf diseases using MobileNetV2. *IAES International Journal of Artificial Intelligence*, 9(2), 290–296. <https://doi.org/10.11591/ijai.v9.i2.pp290-296>

LAMPIRAN

Lampiran ini disusun sebagai bagian pendukung dari laporan skripsi yang berfungsi untuk melengkapi dan memperjelas uraian yang telah disampaikan pada bab-bab sebelumnya. Seluruh data, dokumen, dan hasil pendukung yang disajikan dalam lampiran ini digunakan sebagai bukti dan referensi tambahan yang menunjang proses penelitian, analisis, serta kesimpulan yang diperoleh.

Adapun lampiran dalam laporan skripsi ini meliputi diagram alur penelitian, contoh dataset citra biji kopi, hasil pelatihan model, grafik evaluasi, confusion matrix, serta dokumentasi lain yang relevan dengan proses klasifikasi tingkat kematangan *roasting* biji kopi menggunakan metode *Convolutional Neural Network* berbasis *MobileNetV2*.