

**IMPLEMENTASI *CONVOLUTIONAL NEURAL NETWORK* BERBASIS
ARSITEKTUR *EFFICIENTNET-B0* UNTUK KLASIFIKASI VARIETAS
BUAH DURIAN**

(Skripsi)

**Oleh
MUHAMMAD RAFI RIZANDA
NPM 2115061098**



**FAKULTAS TEKNIK
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

**IMPLEMENTASI *CONVOLUTIONAL NEURAL NETWORK* BERBASIS
ARSITEKTUR *EFFICIENTNET-B0* UNTUK KLASIFIKASI VARIETAS
BUAH DURIAN**

Oleh

MUHAMMAD RAFI RIZANDA

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai
Gelar Sarjana Teknik**

Pada

**Jurusan Teknik Elektro
Program Studi S1 Teknik Informatika
Fakultas Teknik Universitas Lampung**



**FAKULTAS TEKNIK
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2025

ABSTRAK

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK BERBASIS ARSITEKTUR *EFFICIENTNET-B0* UNTUK KLASIFIKASI VARIETAS BUAH DURIAN

Oleh

MUHAMMAD RAFI RIZANDA

Durian merupakan salah satu komoditas unggulan Indonesia dengan produksi dan nilai ekonomis yang terus meningkat dari tahun ke tahun. Berdasarkan data BPS periode 2021–2024, terjadi tren kenaikan signifikan pada jumlah produksi durian, yang berdampak langsung pada tingginya permintaan pasar. Namun, identifikasi varietas durian hingga saat ini masih dilakukan secara manual dan membutuhkan keahlian khusus, sehingga rawan terjadi kesalahan yang dapat memengaruhi kualitas dan stabilitas harga di pasar. Untuk mengatasi permasalahan tersebut, penelitian ini mengimplementasikan Convolutional Neural Network (CNN) berbasis arsitektur *Efficientnet-b0* dalam klasifikasi varietas durian. *Dataset* penelitian terdiri atas tujuh varietas durian, yaitu Musang King, D24/Sultan, Golden Phoenix, Sumatra Super, Medan, Bengkulu, dan Kota Agung. Data diperoleh dari sumber publik Kaggle dan pengambilan langsung di toko buah durian di Bandar Lampung. Proses penelitian meliputi preprocessing citra berupa resize ke 224×224 piksel, normalisasi, augmentasi, pembagian *Dataset*, perancangan model *Efficientnet-b0*, pelatihan model, hyperparameter tuning, hingga evaluasi. *Efficientnet-b0* dipilih karena efisiensinya dengan 5,3 juta parameter dan dukungan pretrained weights dari ImageNet. Hasil penelitian menunjukkan bahwa model *Efficientnet-b0* dengan transfer learning, augmentasi data, dan tanpa *Fine Tuning* mampu mencapai akurasi pelatihan 99,67% serta validasi 100%. Setelah dilakukan hyperparameter tuning dengan konfigurasi *Dense* layer 128 neuron, 20 *Epoch*, *Learning Rate* 0,001, dan *Batch Size* 16, performa model meningkat dengan akurasi pelatihan 99,95% dan validasi 99,29% dengan nilai *Loss* rendah. Temuan ini membuktikan bahwa *Efficientnet-b0* efektif dan efisien untuk mendukung pengembangan aplikasi pengenalan varietas durian berbasis citra digital.

Kata kunci : durian, *Efficientnet-b0*, hyperparameter

ABSTRACT

IMPLEMENTATION OF CONVOLUTIONAL NEURAL NETWORK BASED ON EFFICIENTNET-B0 ARCHITECTURE FOR DURIAN VARIETY CLASSIFICATION

By

MUHAMMAD RAFI RIZANDA

Durian is one of Indonesia's leading commodities with production and economic value that continue to increase each year. Based on BPS data from 2021–2024, there has been a significant upward trend in durian production, directly impacting the growing market demand. However, the identification of durian varieties is still carried out manually and requires specific expertise, making it prone to errors that may affect product quality and market price stability. To address this issue, this study implements a Convolutional Neural Network (CNN) based on the Efficientnet-b0 architecture for durian variety classification. The Dataset consists of seven varieties—Musang King, D24/Sultan, Golden Phoenix, Sumatra Super, Medan, Bengkulu, and Kota Agung—collected from public Kaggle sources and directly from durian fruit stores in Bandar Lampung. The research process includes image preprocessing (resize to 224×224 pixels, normalization, augmentation), Dataset splitting, Efficientnet-b0 model design, training, hyperparameter tuning, and evaluation. Efficientnet-b0 was selected for its efficiency with 5.3 million parameters and pretrained ImageNet weights. The results show that the model using transfer learning, augmented data, and without fine-tuning achieved 99.67% training accuracy and 100% validation accuracy. After hyperparameter tuning with 128 Dense neurons, 20 Epochs, a 0.001 Learning Rate, and a Batch Size of 16, the model's performance improved with 99.95% training accuracy and 99.29% validation accuracy with low Loss values. These findings demonstrate that Efficientnet-b0 is highly effective and efficient in supporting the development of a digital image-based durian variety recognition application.

Keywords: durian, Efficientnet-b0, hyperparameter

Judul Skripsi

**: IMPLEMENTASI CONVOLUTIONAL NEURAL
NETWORK BERBASIS ARSITEKTUR
EFFICIENTNET-B0 UNTUK KLASIFIKASI
VARIETAS BUAH DURIAN**

Nama Mahasiswa

: Muhammad Rafi Rizanda

Nomor Pokok Mahasiswa

: 2115061098

Program Studi

: Teknik Informatika

Jurusan

: Teknik Elektro

Fakultas

: Teknik



1. Komisi Pembimbing

Pembimbing Utama

Pembimbing Pendamping

**Yessi Mulyani, S.T., M.T.
NIP. 197312262000122001**

**Puput Budi Wintoro, S.Kom., M.T.I
NIP. 198410312019031004**


2. Mengetahui

**Ketua Jurusan
Teknik Elektro**

**Ketua Program Studi
Teknik Informatika**

**Herlinawati, S.T., M.T.
NIP. 197103141999032001**

**Yessi Mulyani, S.T., M.T.
NIP. 197312262000122001**

MENGESAHKAN**1. Tim Penguji****Ketua****: Yessi Mulyani, S.T., M.T.****Sekretaris****: Puput Budi Wintoro, S.Kom., M.T.I****Penguji****: Dr.Eng. Ir. Mardiana, S.T., M.T., IPM.****2. Dekan Fakultas Teknik****Dr. Eng. Ir. Helmy Fitriawan, S.T., M.Sc. ✓****NIP. 197509282001121002****Tanggal Lulus Ujian Skripsi****: 20 Agustus 2025**

SURAT PERNYATAAN

Dengan ini saya menyatakan bahwa skripsi berjudul “Implementasi *Convolutional Neural Network* Berbasis Arsitektur *Efficientnet-b0* Untuk Klasifikasi Varietas Buah Durian” sepenuhnya merupakan hasil karya saya sendiri. Apabila dikemudian hari terbukti pernyataan ini tidak benar, saya siap menerima sanksi sesuai dengan ketentuan hukum yang berlaku.

Bandarlampung, 20 Agustus 2025

Penulis,



Muhammad Rafi Rizanda

NPM 2115061098

RIWAYAT HIDUP



Penulis dilahirkan di Jakarta Timur, pada tanggal 16 Desember 2003 sebagai anak kedua dari pasangan Bapak Sjafrizal dan Ibu Winda Saplita. Penulis menyelesaikan pendidikan di Taman Kanak-Kanak (TK) Al-Ikhlas 86 pada Tahun 2009, Sekolah Dasar (SD) Islam Terpadu Al-Ikhlas 86 Jakasetia pada tahun 2015, Sekolah Menengah Pertama (SMP) Islam Darussalam Cikunir pada tahun 2018, dan Sekolah Menengah Atas (SMA) Negeri 2 Kota Bekasi dengan jurusan Ilmu Pengetahuan Alam (IPA) pada tahun 2021. Penulis tercatat sebagai mahasiswa Fakultas Teknik Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN) pada tahun 2021. Selama menjadi mahasiswa, peneliti mendapatkan beasiswa bank indonesia pada tahun 2023 dan 2024 berkat prestasinya di perkuliahan dengan nilai yang baik dan aktif mengikuti organisasi sosial. Selain itu, selama menjadi mahasiswa penulis aktif mengikuti berbagai kegiatan organisasi baik di tingkat lokal maupun nasional, serta magang antara lain sebagai berikut:

1. Anggota Himpunan Mahasiswa Teknik Elektro (Hiimatro) Universitas Lampung (2022 dan 2023)
2. Anggota *Partnership Development of Local Project* di AIESEC in Universitas Lampung tahun 2022
3. *Team Leader of Business Development* di AIESEC in Universitas Lampung tahun 2023
4. *Local Head of Business Development* di AIESEC in Universitas Lampung tahun 2024
5. Anggota Generasi Baru Indonesia (GENBI) Universitas Lampung tahun 2023 dan 2024
6. Magang di Kementerian Komunikasi dan Informasi Republik Indonesia (2024)
7. MSIB *Batch 7 Awardee* : Magang sebagai Marketing Data Analyst Alfamart tahun 2024

MOTTO

"Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya."

(QS. Al-Baqarah: 286)

*"Kesuksesan sejati datang ketika kamu bisa melihat nilai dalam perjalanan,
bukan hanya hasil akhirnya"*

(The Pursuit of Happyness)

"There is no easy journey; every step comes with its own challenges."

(Penulis)

PERSEMBAHAN

Segala puji syukur kepada Allah SWT berkat karunia, kesehatan, rahmat serta hidayah yang telah diberikan, shalawat teriring salam kepada Nabi Muhammad SAW, suri tauladan Akhlaqul Kharimah yang kita nantikan syafa'at-nya di hari akhir kelak. Dengan segala kerendahan hati, saya persembahkan skripsi ini kepada:

Kedua Orang Tua Tercinta,

Ayah Sjafrizal dan Ibu Winda Saplita

Yang selalu memberikan dukungan, pendidikan, bimbingan, dan doa dalam setiap keadaan. Terima kasih atas segala kasih sayang yang telah diberikan, sehingga saya dapat tumbuh menjadi pribadi yang baik dan memiliki semangat untuk meraih cita-cita. Semoga saya kelak dapat terus menjadi anak yang membanggakan serta menjadi pribadi yang bermanfaat bagi lingkungan sekitar.

SANWACANA

Alhamdulillahirabbil'alamin, segala puji bagi *Allah Subhanahu Wa Ta'ala*, Rabb semesta alam, Yang Maha Pengasih lagi Maha Penyayang. Shalawat dan salam semoga senantiasa tercurah kepada Baginda *Rasulullah Muhammad shallallahu 'alaihi wa sallam*, beserta keluarga, sahabat, dan seluruh pengikutnya yang setia mengikuti petunjuk-Nya. *Aamiin*. Atas izin dan ridha-Nya, penulis dapat menyelesaikan penulisan skripsi yang berjudul “Implementasi Convolutional Neural Network Berbasis Arsitektur *Efficientnet-b0* Untuk Klasifikasi Varietas Buah Durian” sebagai salah satu syarat untuk memperoleh gelar Sarjana Teknik pada Fakultas Teknik Universitas Lampung. Penyusunan skripsi ini tidak terlepas dari bantuan, bimbingan, saran, dan dukungan dari berbagai pihak. Oleh karena itu, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Kedua orang tua dan keluarga yang senantiasa memberikan doa, dukungan, dan nasihat kepada penulis sepanjang masa perkuliahan;
2. Bapak Dr. Eng. Helmy Fitriawan, S.T., M.Sc., selaku Dekan Fakultas Hukum Universitas Lampung;
3. Ibu Herlinawati, S.T., M.T., selaku Ketua Jurusan Teknik Elektro Universitas Lampung;
4. Ibu Yessi Mulyani, S.T., M.T., selaku Ketua Program Studi Teknik Informatika Fakultas Teknik Universitas Lampung dan selaku Dosen Pembimbing I yang telah banyak membimbing penulis dan memberikan ilmu selama menempuh pendidikan di Fakultas Teknik Universitas Lampung;
5. Bapak Puput Budi Wintoro, S.Kom., M.T.I, selaku Dosen Pembimbing II terima kasih telah meluangkan waktu untuk membimbing dan memberikan saran kepada penulis dalam kesempurnaan penulisan skripsi ini dan selaku

Dosen Pembimbing Akademik yang telah membantu atas arahan yang telah diberikan selama penulis menempuh pendidikan di Fakultas Teknik Universitas Lampung.

6. Ibu Dr. Eng. Ir. Mardiana, S.T., M.T., IPM, selaku Dosen Penguji yang telah memberikan koreksi, masukan, dan kritikan yang membangun demi sempurnanya skripsi ini
7. Seluruh dosen dan karyawan/ti Fakultas Teknik Universitas Lampung khususnya Program Studi Teknik Informatika, terima kasih atas ilmu yang bermanfaat bagi penulis dan bantuan administratif yang diberikan kepada penulis selama menempuh pendidikan di Fakultas Teknik Universitas Lampung.
8. Kakak dan Adik saya tersayang, Nabila Hasna Rizanda dan Naura Shaquilla Rizanda yang selalu mendukung saya;
9. Almamater tercinta, Fakultas Teknik Universitas Lampung;
10. Sahabat-sahabatku, EB Samil (Jek, Adel, Ica, Yapi, Dea, Ais, dan Dane) yang telah menemani dan mewarnai perjalanan penulis selama menempuh pendidikan di Fakultas Teknik Universitas Lampung.
11. Sahabat-sahabatku, Muhkito, Faiz, Dede, Ridho, Vezan, Adil, Hazel, Milano, Farhat, Alvin, Pandu, Andre, Ridho Ramadhan, Panca, Marsel, Rama, Dimas, Nyoman, Sandi, Abdul, dan Ganang yang selalu memberikan semangat dan dukungan kepada penulis;
12. Rekan-rekan organisasi AIESEC in Unila terutama (Mishelle, Embun, Cia, Dewinda, Alicia, Radit, Endriko, Zaky, Tiara, Jasmine, Iqbal, Uwen, Sanca, Sheryn), serta seluruh rekan-rekan *External Relations 2023*, *Local Project 2022*, dan *External Relations 2021* yang telah memberikan banyak pelajaran dan pengalaman berharga ketika berorganisasi selama masa perkuliahan;
13. Farhat Febrianto, Arbian Alex Pratama, dan Muchammad Raja Haikal Fiaugustian sebagai rekan satu tim dalam penelitian yang telah bekerja sama dan saling mendukung dalam penyelesaian penelitian;
14. Pihak-pihak yang tidak dapat disebutkan satu persatu yang telah memberikan dukungan kepada penulis dalam penyusunan skripsi ini;

Semoga *Allah Subhanahu Wa Ta'ala*, memberikan balasan yang baik atas jasa dan kebaikan yang telah diberikan kepada penulis. Akhir kata, penulis menyadari masih terdapat kekurangan dalam penulisan skripsi ini, akan tetapi penulis berharap semoga skripsi ini dapat berguna dan bermanfaat bagi semua pihak khususnya bagi pengembangan ilmu hukum pada umumnya.

Bandarlampung, 20 Agustus 2025

Penulis,

Muhammad Rafi Rizanda

NPM. 2115061098

DAFTAR ISI

	Halaman
ABSTRAK	ii
PERSEMBAHAN	viii
SANWACANA	ix
DAFTAR ISI	xii
DAFTAR GAMBAR	xvi
DAFTAR TABEL	xix
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian	5
1.5 Batasan Masalah.....	6
1.6 Sistematika Penulisan Skripsi / Tugas Akhir	6
II. TINJAUAN PUSTAKA.....	8
2.1 Durian.....	8
2.2 <i>Artificial intelligence</i>	9
2.3 <i>Machine Learning</i>	10
2.4 <i>Deep Learning</i>	11
2.5 <i>Image classification</i>	12
2.6 <i>Convolutional Neural Network</i>	12

2.6.1	<i>Pooling layer</i>	13
2.6.2	<i>Fully connected layer</i>	14
2.7	<i>Efficientnet-b0</i>	15
2.8	<i>Hyperparameter Tuning</i>	16
2.8.1	<i>Adam Optimizer</i>	17
2.8.2	<i>Epoch</i>	18
2.8.3	<i>Batch Size</i>	18
2.8.4	<i>Dropout</i>	18
2.8.5	<i>Learning Rate</i>	19
2.9	<i>Fine Tuning</i>	19
2.10	<i>Confusion Matrix</i>	20
2.11	<i>Python</i>	20
2.12	<i>Tensorflow</i>	21
2.13	<i>Transfer learning</i>	22
2.14	<i>Augmentasi Data</i>	23
2.15	<i>Penelitian Terkait</i>	23
III.	METODOLOGI PENELITIAN	30
3.1	<i>Waktu dan Tempat</i>	30
3.2	<i>Jadwal penelitian</i>	30
3.3	<i>Alat dan Bahan Penelitian</i>	31
3.4	<i>Tahapan Penelitian</i>	33
3.4.1	<i>Identifikasi Masalah</i>	33
3.4.2	<i>Studi Literatur</i>	34
3.4.3	<i>Merumuskan Masalah dan Tujuan</i>	34
3.4.4	<i>Pengumpulan Dataset Jenis Durian</i>	35
3.4.5	<i>Preprocessing data</i>	39

3.4.6	Perancangan Arsitektur <i>Efficientnet-b0</i>	41
3.4.7	Pelatihan Model	43
3.4.7	Percobaan <i>Hyperparameter Tuning</i>	44
3.4.8	Evaluasi Model.....	44
IV.	HASIL DAN PEMBAHASAN	46
4.1	Pengumpulan <i>Dataset</i> Jenis Durian	46
4.2	<i>Preprocessing Dataset</i>	47
4.2.1	<i>Resize</i> dan <i>Rescale</i>	49
4.2.2	Augmentasi Data.....	49
4.2.3	Pembagian <i>Dataset</i>	51
4.2.4	Pemuatan Data	54
4.3	Perancangan Arsitektur <i>Efficientnet-b0</i>	55
4.4	Pelatihan Model	57
4.4.1	Proses <i>Transfer learning</i>	58
4.4.2	Hasil Pelatihan Awal <i>Dataset</i> Sebelum <i>Dataset</i> di Augmentasi	58
4.4.3	Hasil Pelatihan Awal Setelah <i>Dataset</i> di Augmentasi	59
4.4.4	Perbandingan Hasil Pelatihan Sebelum dan Sesudah Augmentasi ...	60
4.4.5	Pelatihan Setelah <i>Fine Tuning</i>	62
4.4.6	Pelatihan Tanpa <i>Fine Tuning</i>	63
4.4.7	Perbandingan Hasil Pelatihan Sebelum dan Sesudah <i>Fine Tuning</i> ...	63
4.4.8	Konfigurasi <i>Fully Connected Layer</i>	64
4.4.9	Konfigurasi <i>Batch Size</i>	68
4.4.10	Konfigurasi <i>Learning Rate</i>	71
4.4.11	Konfigurasi Jumlah <i>Epoch</i>	73
4.5	Evaluasi Model.....	76
4.5.1	Hasil Uji Arsitektur	76

4.6	Pengujian Model	102
4.6.1	Pengujian Model Menggunakan Buah Durian Golden Phoenix	104
4.6.2	Pengujian Model Menggunakan Buah Durian Musang King	104
4.6.3	Pengujian Model Menggunakan Buah Durian Medan	105
4.6.4	Pengujian Model Menggunakan Buah Durian D24/Sultan	105
4.6.5	Pengujian Model Menggunakan Buah Durian Sumatra Super	106
4.6.6	Pengujian Model Menggunakan Buah Durian Bengkulu	107
4.6.7	Pengujian Model Menggunakan Buah Durian Kota Agung	107
4.6.8	Pengujian Model Menggunakan Buah Durian Kucing Tidur (Tidak dikenal)	108
V.	SIMPULAN DAN SARAN	109
	DAFTAR PUSTAKA	110
	LAMPIRAN	115

DAFTAR GAMBAR

	Halaman
Gambar 1. 1 Pertumbuhan Produksi buah Durian dari tahun 2021-2024	1
Gambar 1. 2 Data BPS 5 Produksi Buah tertinggi di Indonesia	2
Gambar 1. 3 Harga Jual rata-rata Durian (Kw) dengan komoditas lain [5]	2
Gambar 2. 1 Buah Durian	8
Gambar 2. 2 <i>Human-Agent Interaction</i>	9
Gambar 2. 3 <i>Classification of the most widely used Machine Learning algorithms</i> [16].....	10
Gambar 2. 4 <i>Deep Learning model flow showing feature extraction and model</i> <i>prediction</i> [15].....	11
Gambar 2. 5 <i>General architecture of Convolutional Neural Network</i> [20]	13
Gambar 2. 6 <i>Max Pool : Type of pooling layer</i>	14
Gambar 2. 7 <i>Illustration Image of Fully connected layer</i> [22]	15
Gambar 2. 8 <i>The Efficientnet-b0 Architecture</i>	16
Gambar 2. 9 <i>Hyperparameter Tuning Process</i>	17
Gambar 2. 10 <i>Transfer learning</i>	22
Gambar 3. 1 Tahapan Penelitian	33
Gambar 3. 2 <i>Dataset 7 Varietas Durian</i>	35
Gambar 3. 3 Durian Musang King	36
Gambar 3. 4 Durian D24/Sultan.....	37
Gambar 3. 5 Durian Golden phoenix	37
Gambar 3. 6 Durian Sumatra Super	38
Gambar 3. 7 Durian Medan.....	38
Gambar 3. 8 Durian Bengkulu	39
Gambar 3. 9 Durian Kota Agung	39

Gambar 3. 10 Arsitektur <i>Efficientnet-b0</i>	41
Gambar 4. 1 Alur <i>Preprocessing Dataset</i>	48
Gambar 4. 2 Augmentasi Data	51
Gambar 4. 3 Pelatihan Sebelum Augmentasi Data	59
Gambar 4. 4 Pelatihan Setelah Augmentasi Data.....	60
Gambar 4. 5 Perbandingan Grafik Pelatihan Sebelum dan Sesudah Augmentasi Data	61
Gambar 4. 6 Hasil Pelatihan Setelah <i>Fine Tuning</i>	62
Gambar 4. 7 Hasil Pelatihan Tanpa <i>Fine Tuning</i>	63
Gambar 4. 8 Grafik Akurasi dan <i>Loss</i> Satu Lapisan <i>Dense</i> dengan 64 Neuron....	65
Gambar 4. 9 Grafik Akurasi dan <i>Loss</i> Satu Lapisan <i>Dense</i> dengan 128 Neuron..	65
Gambar 4. 10 Grafik Akurasi dan <i>Loss</i> Satu Lapisan <i>Dense</i> dengan 256 Neuron	65
Gambar 4. 11 Grafik Akurasi dan <i>Loss</i> Dua Lapisan <i>Dense</i> dengan 64 dan 128 Neuron.....	66
Gambar 4. 12 Grafik Akurasi dan <i>Loss</i> Tiga Lapisan <i>Dense</i> dengan 64, 128 dan 256 Neuron.....	66
Gambar 4. 13 Diagram Batang Perbandingan Jumlah <i>Dense</i> layer	67
Gambar 4. 14 Grafik Akurasi dan <i>Loss Batch Size</i> 16	68
Gambar 4. 15 Grafik Akurasi dan <i>Loss Batch Size</i> 32	69
Gambar 4. 16 Grafik Akurasi dan <i>Loss Batch Size</i> 64	69
Gambar 4. 17 Diagram Batang Perbandingan <i>Batch Size</i>	70
Gambar 4. 18 Grafik Akurasi dan <i>Loss Learning Rate</i> 0.01	71
Gambar 4. 19 Grafik Akurasi dan <i>Loss Learning Rate</i> 0.001	71
Gambar 4. 20 Grafik Akurasi dan <i>Loss Learning Rate</i> 0.0001	71
Gambar 4. 21 Diagram Batang Perbandingan <i>Learning Rate</i>	72
Gambar 4. 22 Grafik Akurasi dan <i>Loss 10 Epoch</i>	73
Gambar 4. 23 Grafik Akurasi dan <i>Loss 20 Epoch</i>	73
Gambar 4. 24 Grafik Akurasi dan <i>Loss 30 Epoch</i>	74
Gambar 4. 25 Grafik Akurasi dan <i>Loss 40 Epoch</i>	74
Gambar 4. 26 Diagram Batang Perbandingan Jumlah <i>Epoch</i>	75
Gambar 4. 27 <i>Confusion Matrix</i> Satu Lapisan <i>Dense</i> dengan 64 Neuron	77
Gambar 4. 28 <i>Confusion Matrix</i> Satu Lapisan <i>Dense</i> dengan 128 Neuron	78

Gambar 4. 29 <i>Confusion Matrix</i> Satu Lapisan <i>Dense</i> dengan 256 Neuron	80
Gambar 4. 30 <i>Confusion Matrix</i> Dua Lapisan <i>Dense</i> dengan 64 & 128 Neuron..	81
Gambar 4. 31 <i>Confusion Matrix</i> Tiga Lapisan <i>Dense</i> dengan 64, 128, & 256 Neuron	82
Gambar 4. 32 Perbandingan Metrik Evaluasi Hasil Uji Arsitektur.....	83
Gambar 4. 33 <i>Confusion Matrix</i> <i>Batch Size</i> 16.....	85
Gambar 4. 34 <i>Confusion Matrix</i> <i>Batch Size</i> 32.....	86
Gambar 4. 35 <i>Confusion Matrix</i> <i>Batch Size</i> 64.....	88
Gambar 4. 36 Perbandingan Metrik Evaluasi Hasil Uji <i>Batch Size</i>	89
Gambar 4. 37 <i>Confusion Matrix</i> <i>Learning Rate</i> 0,01.....	90
Gambar 4. 38 <i>Confusion Matrix</i> <i>Learning Rate</i> 0,001.....	92
Gambar 4. 39 <i>Confusion Matrix</i> <i>Learning Rate</i> 0,0001.....	93
Gambar 4. 40 Perbandingan Metrik Evaluasi Hasil Uji <i>Learning Rate</i>	94
Gambar 4. 41 <i>Confusion Matrix</i> <i>Epoch</i> 10	96
Gambar 4. 42 <i>Confusion Matrix</i> <i>Epoch</i> 20	97
Gambar 4. 43 <i>Confusion Matrix</i> <i>Epoch</i> 30	99
Gambar 4. 44 <i>Confusion Matrix</i> <i>Epoch</i> 40	100
Gambar 4. 45 Perbandingan Metrik Evaluasi Hasil Uji Jumlah <i>Epoch</i>	101
Gambar 4. 46 Hasil Pengujian Model Menggunakan Gambar Durian <i>Golden Phoenix</i>	104
Gambar 4. 47 Hasil Pengujian Model Menggunakan Gambar Durian Musang <i>King</i>	104
Gambar 4. 48 Hasil Pengujian Model Menggunakan Gambar Durian Medan ...	105
Gambar 4. 49 Hasil Pengujian Model Menggunakan Gambar Durian D24/Sultan	105
Gambar 4. 50 Hasil Pengujian Model Menggunakan Gambar Durian Sumatra Super	106
Gambar 4. 51 Hasil Pengujian Model Menggunakan Gambar Durian Bengkulu	107
Gambar 4. 52 Hasil Pengujian Model Menggunakan Gambar Durian Kota Agung	107
Gambar 4. 53 Hasil Pengujian Model Menggunakan Gambar Durian Kucing Tidur (Tidak dikenal)	108

DAFTAR TABEL


	Halaman
Tabel 2. 1 Penelitian Terkait.....	29
Tabel 3. 1 Jadwal Penelitian.....	30
Tabel 3. 2 Alat dan Bahan Penelitian	31
Tabel 4. 1 Informasi Data.....	47
Tabel 4. 2 Augmentasi Data	50
Tabel 4. 3 Tabel Distribusi <i>Dataset</i> Setelah Augmentasi	52
Tabel 4. 4 Jumlah <i>Dataset</i> sebelum di Augmentasi	53
Tabel 4. 5 Jumlah <i>Dataset</i> setelah di Augmentasi.....	53
Tabel 4. 6 Arsitektur <i>Summary Efficientnet-b0</i>	55
Tabel 4. 7 Arsitektur <i>Summary Efficientnet-b0</i> dengan Output 7 Kelas	56
Tabel 4. 8 Hasil Pelatihan Sebelum Augmentasi Data	59
Tabel 4. 9 Hasil Pelatihan Setelah Augmentasi Data	60
Tabel 4. 10 Perbandingan Augmentasi.....	61
Tabel 4. 11 Perbandingan <i>Fine Tuning</i>	64
Tabel 4. 12 Tabel Perbandingan Konfigurasi <i>Dense</i> layer	68
Tabel 4. 13 Perbandingan Konfigurasi <i>Batch Size</i>	70
Tabel 4. 14 Perbandingan Konfigurasi <i>Learning Rate</i>	72
Tabel 4. 15 Perbandingan Konfigurasi Jumlah <i>Epoch</i>	75
Tabel 4. 16 Metrik Evaluasi Satu Lapisan <i>Dense</i> dengan 64 Neuron.....	77
Tabel 4. 17 Metrik Evaluasi Satu Lapisan <i>Dense</i> dengan 128 Neuron.....	79
Tabel 4. 18 Metriks Evaluasi Satu Lapisan <i>Dense</i> dengan 256 Neuron	79
Tabel 4. 19 Metrik Evaluasi Dua Lapisan <i>Dense</i> dengan 64 & 128 Neuron	81
Tabel 4. 20 Metrik Evaluasi Tiga Lapisan <i>Dense</i> dengan 64, 128, & 256 Neuron.....	83
Tabel 4. 21 Analisis Perbandingan Metrik Evaluasi Hasil Uji Arsitektur.....	84
Tabel 4. 22 Metrik Evaluasi <i>Batch Size</i> 16	85
Tabel 4. 23 Metrik Evaluasi <i>Batch Size</i> 32	87

Tabel 4. 24 Metrik Evaluasi <i>Batch Size</i> 64	87
Tabel 4. 25 Perbandingan Hasil Uji <i>Batch Size</i>	89
Tabel 4. 26 Metrik Evaluasi <i>Learning Rate</i> 0,01	91
Tabel 4. 27 Metrik Evaluasi <i>Learning Rate</i> 0,001	91
Tabel 4. 28 Metriks Evaluasi <i>Learning Rate</i> 0,0001.....	93
Tabel 4. 29 Perbandingan Hasil Uji <i>Learning Rate</i>	95
Tabel 4. 30 Metriks Evaluasi <i>Epoch</i> 10	96
Tabel 4. 31 Metrik Evaluasi <i>Epoch</i> 20	98
Tabel 4. 32 Metrik Evaluasi <i>Epoch</i> 30	98
Tabel 4. 33 Metrik Evaluasi <i>Epoch</i> 40	100
Tabel 4. 34 Perbandingan Hasil Uji Jumlah <i>Epoch</i>	101

I. PENDAHULUAN


1.1 Latar Belakang

Durian atau disebut dalam bahasa latin yaitu *Durio zibethinus Murr* merupakan salah satu jenis buah tropis yang tergolong dalam famili *Bombacaceae* yang memiliki nilai ekonomis tinggi [1]. Berdasarkan data yang dirilis oleh badan pusat statistik, produksi durian di indonesia mengalami peningkatan yang konsisten dari tahun ke tahun. Pada tahun 2020, total produksi durian tercatat sebesar 1.133.194 ton. Jumlah tersebut meningkat menjadi 1.352.957 ton pada tahun 2021, kemudian naik menjadi 1.582.171 ton pada tahun 2022. Tren kenaikan ini berlanjut pada tahun 2023 dengan total produksi sebesar 1.852.045 ton, dan pada tahun 2024 mencapai sekitar 1.961.486 ton. Berdasarkan gambar 1.1 yang menunjukkan adanya pertumbuhan signifikan dalam sektor produksi durian selama lima tahun terakhir [2].




Gambar 1. 1 Pertumbuhan produksi buah durian dari tahun 2021-2024

Bahkan, berdasarkan gambar 1.2 data BPS di indonesia tahun 2021-2024, terlihat buah durian masuk dalam 5 teratas buah dengan produksi terbanyak di indonesia.



Gambar 1. 2 Data BPS 5 produksi buah tertinggi di Indonesia tahun 2021-2024

Selain itu, berdasarkan gambar 1.3 durian merupakan salah satu komoditas pertanian yang memiliki nilai ekonomi tinggi dan popularitas yang terus meningkat di pasar lokal maupun internasional. Tingginya permintaan terhadap durian, terutama untuk varietas unggulan, telah mendorong kenaikan harga yang signifikan, sehingga memotivasi masyarakat, termasuk petani, untuk mengembangkan budidaya durian secara lebih intensif [3]. Tidak hanya itu, durian juga dimanfaatkan sebagai daya tarik agrowisata, seperti yang terlihat pada wisata durian H. Haqu'i di Lampung selatan. Agrowisata ini menunjukkan bahwa durian mampu bersaing dengan objek wisata buah lainnya seperti Taman buah Mekarsari (Bogor), Agrowisata bukit Strawberry (Bandung), dan wisata buah di Pesawaran (Lampung) [4].



Gambar 1. 3 Harga jual rata-rata durian (Kw) dengan komoditas lain [5]

Fenomena ini tidak hanya memperluas peluang ekonomi, tetapi juga memunculkan berbagai tantangan, khususnya dalam hal praktik pasar yang tidak sehat, seperti manipulasi harga dan kualitas produk, yang dilakukan oleh oknum pelaku usaha yang tidak bertanggung jawab. Berdasarkan observasi di kota Pagar Alam, proses identifikasi varietas durian masih dilakukan secara manual dan memerlukan keahlian khusus [6]. Ketidakakuratan dalam klasifikasi varietas dapat berdampak pada penurunan kepercayaan konsumen dan ketidakstabilan harga di pasar. Tidak jarang ditemukan kasus manipulasi, seperti penjual yang menyatakan durian biasa sebagai varietas unggulan seperti musang king, padahal tidak demikian [7]. Hal ini bisa terjadi karena konsumen tidak familiar dan kurang memiliki pengetahuan tentang jenis-jenis durian.

Untuk mengatasi permasalahan tersebut, dibutuhkan metode klasifikasi yang akurat dan efisien. Salah satu pendekatan yang menjanjikan adalah penggunaan teknologi pengolahan citra digital (*image processing*) dan pembelajaran mesin (*Machine Learning*), khususnya dengan memanfaatkan arsitektur *Convolutional Neural Network* (CNN). CNN telah terbukti unggul dalam tugas klasifikasi citra karena kemampuannya mengenali pola visual seperti bentuk, warna, dan tekstur secara hierarkis. Beberapa studi mengenai klasifikasi citra menggunakan *deep Learning* termasuk CNN, untuk klasifikasi buah [8]. CNN telah terbukti lebih unggul dibanding arsitektur *deep Learning* lainnya dalam klasifikasi citra karena CNN memiliki urutan lapisan yang terstruktur, mulai dari lapisan *input* hingga lapisan *output*, mencerminkan proses pembelajaran fitur secara hierarkis dalam *Convolutional Neural Network* (CNN).

Salah satu model CNN yang terbukti efisien dalam klasifikasi buah adalah *Efficientnet-b0*, yang merupakan bagian dari keluarga *Efficientnet*. Model ini dikenal memiliki keseimbangan antara akurasi tinggi dan efisiensi komputasi. Dengan hanya 5,3 juta parameter dan 0,39 miliar FLOPs, *Efficientnet-b0* cocok diterapkan pada perangkat dengan sumber daya terbatas. Keluarga model *Efficientnet* dikenal memiliki efisiensi dan akurasi yang sangat baik dengan pendekatan penskalaan yang sistematis terhadap kedalaman, lebar, dan resolusi jaringan [9]. Dalam pengujian menggunakan *Dataset Fruits-360*, model ini mampu mencapai akurasi lebih dari 99,9%, melampaui *ConvNet* yang hanya memperoleh

94,52%. Kemampuannya dalam mengenali fitur visual seperti bentuk, warna, dan tekstur menjadikannya ideal untuk klasifikasi buah berdasarkan citra eksternal. Selain itu, *Efficientnet-b0* mendukung *Transfer learning* dengan bobot pra-latih dari *ImageNet*, yang mempercepat pelatihan terutama saat data berlabel terbatas. Dengan waktu inferensi hanya sekitar 0,07 detik per citra, model ini juga sangat sesuai untuk aplikasi *real-time* [10].

Dalam perbandingan dengan beberapa arsitektur seperti *ResNet50V2*, *InceptionV3*, *InceptionResNetV2*, *VGG16*, *VGG19*, dan *MobileNetV2*, yang menilai kinerja menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score*. Berdasarkan percobaan menggunakan tambahan *optimizer* Adam, model *Efficientnet* menghasilkan akurasi rata-rata tertinggi hingga 99%, diikuti dengan penggunaan model *VGG 16* dan *ResNet V2 50* yang mencapai akurasi 98% dan 97% [11].

Dengan mengimplementasikan teknologi ini, penelitian ini bertujuan untuk mengimplementasikan arsitektur *Efficientnet-b0* untuk melakukan klasifikasi citra buah durian berdasarkan karakteristik varietas yang diamati dari bentuk luarnya dengan membangun model pengenalan varietas durian. Model ini diharapkan mampu memberikan akurasi tinggi dalam membedakan varietas yang memiliki kemiripan visual, sehingga dapat meminimalisasi kesalahan identifikasi yang sering terjadi pada metode manual.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, maka rumusan masalah dalam penelitian ini adalah:

1. Bagaimana membuat sistem kecerdasan buatan (*Deep Learning* Model CNN berbasis Arsitektur *Efficientnet-b0*) dalam mengklasifikasikan varietas buah durian?
2. Bagaimana performa dari model *Convolutional Neural Network* (CNN) berbasis arsitektur *Efficientnet-b0* dalam mengklasifikasikan varietas buah durian?

3. Bagaimana pengaruh konfigurasi arsitektur *Efficientnet-b0* dan pengaturan *hyperparameter* pelatihan dalam menghasilkan performa terbaik dalam mengklasifikasikan varietas buah durian?

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Mengembangkan model klasifikasi buah durian menggunakan model *Convolutional Neural Network* (CNN) berbasis arsitektur *Efficientnet-b0* untuk mengklasifikasikan citra buah durian.
2. Menganalisis dan mengevaluasi performa model *Efficientnet-b0* dalam mengklasifikasikan berbagai varietas buah durian.
3. Menganalisis dan mengevaluasi konfigurasi *hyperparameter* yang paling optimal berdasarkan hasil proses *tuning* sehingga dapat meningkatkan akurasi dan kinerja model *Efficientnet-b0* pada tugas klasifikasi.
4. Sebagai tahap awal dalam mengembangkan aplikasi pengenalan varietas buah durian

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah sebagai berikut:

1. Menambah literatur dan wawasan ilmiah dalam bidang *Computer vision* dan *Deep Learning*, khususnya terkait penerapan *Efficientnet* untuk klasifikasi objek pada sektor pertanian khususnya pada buah durian.
2. Menjadi referensi dan dasar pengembangan penelitian lebih lanjut dalam bidang klasifikasi durian berbasis *computer vision*.

1.5 Batasan Masalah

Adapun Batasan masalah dari penelitian ini adalah sebagai berikut:

1. Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) *EfficientnetB0*, dan tidak membandingkan hasil dengan metode lain.
2. Penelitian ini mengimplementasikan model klasifikasi CNN *EfficientnetB0* dengan mengevaluasi hasil performa dan tidak mencakup tahap *deployment* sistem.
3. *Dataset* yang digunakan dalam penelitian ini mencakup 7 Varietas Buah Durian, dan tidak mencakup semua Varietas Durian

1.6 Sistematika Penulisan Skripsi / Tugas Akhir

Adapun sistematika penulisan laporan skripsi ini terdiri dari beberapa bab sebagai berikut:

BAB I : PENDAHULUAN

Berisi latar belakang masalah, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, dan sistematika penulisan laporan.

BAB II : TINJAUAN PUSTAKA

Bab ini menguraikan landasan teori dan penelitian terdahulu yang mendukung penelitian. Tinjauan pustaka mencakup penjelasan tentang tanaman durian dan jenis-jenisnya di Indonesia, konsep dasar *computer vision* dan *deep Learning*, arsitektur CNN, konsep *Transfer learning*, serta penjelasan mendetail mengenai arsitektur *Efficientnet*. Pada bab ini juga dipaparkan penelitian-penelitian sebelumnya yang relevan dalam bidang klasifikasi citra buah menggunakan *deep Learning*.

BAB III : METODOLOGI PENELITIAN

Bab ini menjelaskan metode dan tahapan-tahapan yang digunakan dalam penelitian. Di dalamnya mencakup gambaran umum diagram alir penelitian, teknik pengumpulan *Dataset* citra durian, proses pra-pemrosesan data, pemilihan dan *fine-tuning* model *Efficientnet-b0*, tahapan pelatihan model, serta metode evaluasi kinerja model menggunakan metrik seperti akurasi, precision, *recall*, dan *F1-score*.

BAB IV : HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil implementasi model, termasuk deskripsi *Dataset*, proses pelatihan model, hasil evaluasi performa, serta analisis kinerja model *Efficientnet-b0* dalam mengklasifikasikan jenis-jenis durian. Pada bab ini ditampilkan juga visualisasi hasil, seperti *Confusion Matrix*, learning curve, serta pembahasan hasil pengujian model berdasarkan data validasi dan data uji.

BAB V : KESIMPULAN DAN SARAN

Bab ini memuat kesimpulan yang diambil dari hasil penelitian, menjawab rumusan masalah yang telah disusun sebelumnya. Selain itu, bab ini juga memberikan saran-saran untuk pengembangan lebih lanjut, seperti peningkatan *Dataset*, atau eksplorasi model lain.

II. TINJAUAN PUSTAKA

2.1 Durian

Durian (*Durio zibethinus*) adalah buah asli Asia Tenggara yang terkenal dan populer, dikenal sebagai "Raja Buah". Buah ini dianggap sangat lezat dan memiliki harga yang cukup mahal di pasar luar negeri. Buah durian umumnya dikonsumsi dalam keadaan segar, tetapi juga dapat diolah menjadi berbagai produk turunan. Wilayah persebarannya meliputi Semenanjung Melayu, Indonesia, dan Pulau Kalimantan. Durian adalah pohon buah tropis yang termasuk dalam ordo Malvales dan famili Bombacaceae. Dalam famili ini terdapat 51 marga, salah satunya adalah genus *Durio* yang memiliki sekitar 28 spesies. Spesies yang paling umum dan memiliki nilai ekonomi tinggi adalah *Durio zibethinus* Murr. Nama umum "durian" berasal dari kata Melayu "duri" yang berarti duri atau tajam, sedangkan nama spesies "zibethinus" berasal dari kata Italia *zibetto* yang berarti beraroma tajam [12].




Gambar 2. 1 Buah Durian Musang King [13]

2.2 *Artificial intelligence*

Kecerdasan Buatan (*Artificial intelligence/AI*) adalah teknologi yang memungkinkan mesin untuk meniru cara berpikir, belajar, dan bertindak seperti manusia, yang dalam beberapa tahun terakhir telah berperan penting dalam kemajuan sosial-ekonomi. AI mencakup dua aspek utama, yaitu *artificial* (buatan), yang merujuk pada simulasi lingkungan pembelajaran, dan *intelligence* (kecerdasan), yang berkaitan dengan kemampuan analitis dan pengambilan keputusan cerdas layaknya manusia [14].

AI terdiri dari empat komponen utama, yaitu *searching*, *reasoning*, *planning*, dan *learning* [15]. *Searching* adalah proses pencarian solusi terbaik dengan mengeksplorasi berbagai kemungkinan jalur dan menggabungkannya secara optimal, contohnya melalui algoritma *Breadth-First Search* (BFS) dan *Depth-First Search* (DFS). *Reasoning* merujuk pada kemampuan AI untuk membuat kesimpulan berdasarkan fakta yang tersedia, melalui proses penalaran logis. *Planning* menggambarkan kemampuan AI dalam merancang langkah-langkah strategis guna mencapai tujuan tertentu dengan tindakan yang efisien dan terstruktur. Sementara itu, *learning* adalah kemampuan AI untuk memecahkan masalah melalui analisis data dari pengalaman sebelumnya tanpa membutuhkan pemrograman langsung.




Gambar 2. 2 Human-Agent Interaction

2.3 Machine Learning

Machine Learning (ML) atau pembelajaran mesin merupakan salah satu cabang dari kecerdasan buatan (AI) yang berfokus pada kemampuan sistem untuk mempelajari pola dari data secara otomatis, tanpa perlu diprogram secara berulang oleh manusia [15]. Secara umum, *Machine Learning* dibagi menjadi tiga jenis utama: (1) *Supervised learning*, (2) *Unsupervised learning*, dan (3) *Reinforcement learning*. *Supervised learning* adalah metode di mana model dilatih menggunakan data yang sudah diberi label untuk memprediksi label pada data baru. Prosesnya dilakukan secara bertahap; model akan belajar dari *Dataset*, membuat prediksi, lalu memperbaiki parameternya secara berulang agar hasil prediksinya semakin akurat [16].

Unsupervised learning, di sisi lain, bekerja dengan data yang tidak memiliki label. Model ini bertujuan untuk mengelompokkan data berdasarkan kesamaan fitur atau pola yang ditemukan secara mandiri tanpa arahan awal. Pendekatan ini sangat berguna untuk menggali informasi tersembunyi dalam data, dan dalam beberapa kasus, *unsupervised learning* justru dapat menyelesaikan masalah yang lebih kompleks dibandingkan *supervised learning*.

Terakhir, *reinforcement learning* adalah pendekatan di mana algoritma belajar melalui proses trial and error dengan melakukan berbagai tindakan yang bertujuan memaksimalkan hasil dalam kondisi tertentu [16].




Gambar 2. 3 Classification of the most widely used Machine Learning algorithms [17]

2.4 Deep Learning

Deep Learning merupakan bagian dari *Machine Learning* yang terinspirasi dari cara kerja otak manusia, yang terdiri dari miliaran neuron [18]. *Deep Learning* memanfaatkan algoritma yang dikenal sebagai *Artificial neural network* (ANN). Istilah ‘*deep*’ merujuk pada banyaknya lapisan (*layers*) yang ada dalam jaringan tersebut. Jika jumlah lapisan tidak ditentukan, sistem secara otomatis akan menyesuaikan bobot (*weights*) melalui fungsi optimasi agar kinerja model optimal. Setiap lapisan tersusun atas sejumlah neuron yang saling terhubung. Karena meniru cara kerja otak manusia, *Deep Learning* juga membutuhkan data dalam jumlah besar untuk mencapai tingkat akurasi yang lebih baik.

Meskipun *Deep Learning* berkembang dari *Machine Learning*, keduanya memiliki beberapa perbedaan mendasar. Salah satu perbedaan utamanya adalah bahwa *Deep Learning* memerlukan data dalam jumlah yang jauh lebih besar, dan tidak memerlukan proses ekstraksi fitur secara manual sebelum model dijalankan. Dengan kata lain, *Deep Learning* mampu secara otomatis mengekstraksi fitur-fitur penting dari data yang kemudian diproses lebih lanjut untuk tugas klasifikasi. Konsep *Deep Learning* ini dapat dilihat secara lebih jelas pada Gambar dibawah.



Gambar 2. 4 *Deep Learning model flow showing feature extraction and model prediction* [16]


2.5 *Image classification*

Fruit image classification merupakan salah satu aplikasi penting dalam bidang *computer vision* dan *image processing* yang memberikan manfaat besar bagi sektor pertanian dan industri ritel pangan. *Image classification* mempunyai kemampuan mengenali berbagai jenis buah secara akurat meskipun terdapat variasi ukuran, warna, kondisi pencahayaan, serta mendeteksi buah yang rusak atau terkena penyakit. Seiring meningkatnya kebutuhan akan sistem klasifikasi otomatis yang akurat, efisien, dan adaptif terhadap kondisi gambar yang beragam, berbagai pendekatan telah dikembangkan oleh peneliti sebelumnya.

Gill dan Khehra (2022) mengembangkan sebuah model klasifikasi citra buah berbasis *deep Learning* dengan mengintegrasikan arsitektur *Convolutional Neural Network* (CNN), *Recurrent Neural Network* (RNN), dan *Long Short-Term Memory* (LSTM). Model ini dirancang untuk mengatasi tantangan utama dalam klasifikasi citra buah seperti variasi bentuk, warna, ukuran, pencahayaan, serta adanya buah yang rusak atau terserang penyakit [19].

2.6 *Convolutional Neural Network*

Dalam bidang *deep Learning*, *Convolutional Neural Network* (CNN) telah mendapatkan pengakuan yang luas karena kemampuannya dalam mengekstraksi fitur secara otomatis dan mendalam, serta beradaptasi terhadap perubahan kecil pada citra secara efektif [20]. Sejumlah penelitian menyebutkan bahwa CNN sangat cocok digunakan untuk klasifikasi citra spektral karena kemampuannya dalam mempelajari fitur-fitur diskriminatif secara otomatis langsung dari data masukan, tanpa perlu proses rekayasa fitur secara manual. CNN mampu menangkap pola dan hubungan yang kompleks dalam citra spektral, sehingga menghasilkan hasil klasifikasi yang akurat. Dalam penelitian yang dilakukan oleh Xie et al. (2022) [20], CNN digunakan secara luas untuk klasifikasi tumor otak menggunakan citra MRI. Mereka menemukan bahwa CNN secara konsisten menunjukkan performa klasifikasi yang tinggi, dengan akurasi berkisar antara 91,63% hingga 100% dalam membedakan jenis tumor seperti glioma, meningioma, dan tumor hipofisis.




Gambar 2. 5 General *architecture of Convolutional Neural Network* [21]

2.6.1 *Pooling layer*

Convolutional Neural Network (CNN) merupakan arsitektur jaringan saraf buatan yang di dalamnya terdapat *pooling layer* yang biasanya ditempatkan setelah *convolutional layer*. *Pooling layer* dalam arsitektur CNN digunakan untuk mengurangi dimensi spasial (lebar dan tinggi) dari *feature map* tanpa menghilangkan informasi penting yang terkandung di dalamnya. Proses ini dilakukan dengan menggeser *filter* dua dimensi pada setiap saluran (*channel*) dari *feature map*, lalu merangkum informasi di area yang tercakup oleh *filter* tersebut [22].


Terdapat dua jenis *pooling* yaitu *max pooling* dan *average pooling*. *Max pooling* digunakan untuk mengembalikan nilai maksimum dari bagian gambar yang dicakup oleh kernel. *Max pooling* juga berfungsi sebagai peredam kebisingan (*noise*) dan juga melakukan *de-noising* bersamaan dengan pengurangan dimensi. *Average pooling* mengembalikan rata-rata semua nilai dari bagian gambar yang dicakup oleh kernel. *Average pooling* hanya melakukan pengurangan dimensi sebagai mekanisme peredam kebisingan (*noise*).



Gambar 2. 6 *Max Pool : Type of pooling layer*

2.6.2 *Fully connected layer*

Fully connected layer merupakan komponen penting dalam arsitektur jaringan saraf tiruan dan juga menjadi salah satu komponen penting yang berperan dalam proses klasifikasi [10]. Lapisan ini terdiri dari neuron-neuron yang terhubung secara penuh dengan seluruh neuron pada lapisan sebelumnya. Fungsinya menyerupai perceptron konvensional, yaitu menggabungkan semua *input* dari lapisan sebelumnya untuk menghasilkan prediksi akhir berupa kelas keluaran. Struktur CNN secara umum terdiri dari beberapa dimensi utama yang mempengaruhi kinerjanya, antara lain resolusi (R), lebar (*width*/W), kedalaman (*depth*/D), dan ukuran *filter* (F). Resolusi mengacu pada ukuran *feature map* atau peta fitur, lebar menunjukkan jumlah kanal atau *filter* yang digunakan, kedalaman menunjukkan jumlah lapisan konvolusi dalam jaringan, dan ukuran *filter* menunjukkan besar kecilnya kernel konvolusi yang diterapkan pada tiap lapisan.




Gambar 2. 7 *Illustration Image of Fully connected layer [23]*

2.7 *Efficientnet-b0*

Berdasarkan pengamatan bahwa akurasi dan efisiensi model dapat ditingkatkan dengan menyeimbangkan ketiga dimensi jaringan, maka dikembangkanlah *Efficientnet*, sebuah arsitektur yang mengoptimalkan performa CNN melalui scaling tiga dimensi sekaligus, yaitu lebar (*width*), kedalaman (*depth*), dan resolusi (*resolution*) [10]. Proses scaling ini dilakukan menggunakan koefisien penskalaan tetap yang telah ditentukan berdasarkan batasan tertentu. Konfigurasi *Efficientnet* yang paling ringkas adalah *Efficientnet-b0*, yang terdiri dari 18 lapisan konvolusi ($D = 18$). Setiap lapisan menggunakan kernel berukuran 3×3 atau 5×5 . Citra *input* memiliki tiga kanal warna (R, G, B) dengan resolusi 224×224 piksel. Pada tahap awal, resolusi citra akan dikurangi guna mengecilkan ukuran *feature map*, namun jumlah *filter* (lebar jaringan) akan ditambah secara bertahap untuk meningkatkan

akurasi. Dalam praktik umum, kernel yang sering digunakan adalah berukuran 3×3 , 5×5 , atau 7×7 [24]. Penggunaan kernel yang lebih besar memiliki potensi untuk meningkatkan akurasi serta efisiensi model. Kernel besar mampu menangkap pola resolusi tinggi, sementara kernel kecil lebih baik dalam mengenali pola detail pada resolusi rendah.




Gambar 2. 8 The *Efficientnet-b0* Architecture

2.8 Hyperparameter Tuning

Dalam pengembangan model *deep Learning*, salah satu aspek krusial yang menentukan performa model adalah proses *tuning hyperparameter*. penyetelan *hyperparameter* merupakan salah satu kebutuhan umum algoritma ML. Penyetelan *hyperparameter* menyesuaikan arsitektur model untuk meningkatkan proses pelatihannya [25]. Proses *tuning hyperparameter* bertujuan untuk menemukan kombinasi nilai optimal yang menghasilkan performa terbaik pada data validasi atau data uji. Pemilihan *hyperparameter* yang tepat sangat penting karena dapat mempengaruhi kinerja, kecepatan pelatihan, dan kemampuan generalisasi model. Optimasi *hyperparameter tuning* diterapkan dengan pemilihan parameter seperti

optimizer(Adam, RMSprop, dan SGD), *Learning Rate*(0.01, 0.001, dan 0.0001), *Batch Size*(16, 32, dan 64), dan jumlah neuron(64, 128, dan 256).



Gambar 2. 9 *Hyperparameter Tuning Process*

2.8.1 Adam *Optimizer*

Adam (singkatan dari *Adaptive Momentum*) adalah *optimizer* yang saat ini paling banyak digunakan. *Optimizer* ini dibangun di atas metode RMSProp, tetapi Adam memiliki tambahan berupa mekanisme koreksi bias. Perlu diketahui bahwa koreksi bias ini bukan berkaitan dengan *bias* pada *layer* jaringan, melainkan digunakan untuk memperbaiki nilai *cache* dan *momentum* yang awalnya bernilai nol [26]. Koreksi ini membantu menyesuaikan nilai-nilai tersebut agar lebih akurat di langkah-langkah awal pelatihan, sebelum nilainya mulai stabil. *Optimizer* merupakan komponen penting yang berperan dalam menyempurnakan parameter-parameter jaringan saraf selama proses pelatihan. Fungsi utamanya adalah untuk meminimalkan nilai error atau fungsi kerugian (*Loss function*) dari model, sehingga performa prediksi dapat meningkat.

2.8.2 *Epoch*

Epoch dalam *Machine Learning* berarti satu lintasan lengkap dari kumpulan data pelatihan melalui algoritma. *Epoch* merupakan salah satu *hyperparameter* penting dalam *deep Learning* yang menggambarkan seberapa sering keseluruhan data pelatihan digunakan sepenuhnya oleh model selama proses pembelajaran. Dalam satu *Epoch*, seluruh data dilibatkan dalam proses forward dan backward propagation sebanyak satu kali. Menentukan jumlah *Epoch* yang sesuai sangatlah krusial, karena jika jumlahnya terlalu sedikit, model berisiko mengalami *underfitting* atau tidak mampu belajar secara maksimal. Sebaliknya, jika jumlah *Epoch* terlalu banyak, model dapat mengalami *overfitting*, yaitu terlalu menyesuaikan diri dengan data pelatihan dan kurang mampu menggeneralisasi data baru [26].

2.8.3 *Batch Size*

Batch Size adalah salah satu *hyperparameter* dalam *deep Learning* yang menentukan jumlah data pelatihan yang diproses sekaligus dalam satu iterasi sebelum parameter model diperbarui. Dengan kata lain, *Batch Size* mengatur seberapa banyak sampel yang dikirim ke jaringan saraf untuk melakukan perhitungan gradien dan pembaruan bobot. Pemilihan *Batch Size* yang tepat melalui proses *tuning* dapat membantu meningkatkan efisiensi pelatihan dan kinerja model [26].

2.8.4 *Dropout*

Dropout adalah metode regularisasi pada jaringan neural yang bekerja dengan cara menonaktifkan (mengabaikan) sejumlah neuron secara acak selama proses pelatihan. Tujuannya adalah untuk mencegah model terlalu bergantung pada neuron tertentu, mengurangi *overfitting*, dan mendorong neuron untuk belajar secara independen (menghindari *co-adoption*). Dengan *dropout*, model dipaksa menggunakan kombinasi neuron yang berbeda di setiap *Epoch*, sehingga dapat

belajar representasi data yang lebih kuat dan generalisasi yang lebih baik. Jumlah neuron yang dinonaktifkan diatur menggunakan *hyperparameter dropout rate* [26].

2.8.5 *Learning Rate*

Learning Rate merupakan *hyperparameter* krusial dalam pelatihan model *deep Learning* yang mengatur seberapa besar perubahan bobot dilakukan pada setiap langkah optimasi. Jika nilainya terlalu tinggi, model bisa gagal mencapai hasil optimal karena melompati titik minimum, sedangkan jika terlalu rendah, proses pelatihan menjadi lambat dan berisiko berhenti pada solusi yang kurang baik. Oleh sebab itu, penyesuaian *Learning Rate* secara tepat sangat penting agar model dapat belajar secara efektif dan menghasilkan performa yang baik [26].

2.9 *Fine Tuning*

Fine Tuning merupakan salah satu teknik dalam pembelajaran mesin yang digunakan untuk menyesuaikan model yang sudah dilatih sebelumnya (*pre-trained model*) agar dapat menangani masalah atau *Dataset* yang lebih spesifik. Proses ini sangat berguna ketika data pelatihan yang tersedia terbatas, namun model yang dilatih sebelumnya sudah memiliki pemahaman dasar yang cukup baik tentang berbagai fitur umum dalam data [27]. Langkah pertama yang dilakukan adalah memilih model yang telah dilatih sebelumnya menggunakan *Dataset* besar dan beragam, seperti *Efficientnet* untuk klasifikasi gambar. Setelah itu, *layer-layer* awal pada model biasanya dibekukan (*freeze*), karena *layer* ini berfungsi untuk mengenali fitur dasar seperti tepi gambar atau kata umum. Dengan membekukan *layer* ini, beban komputasi berkurang dan pelatihan lebih efisien. Selanjutnya, hanya *layer-layer* akhir yang dilatih ulang agar bisa menyesuaikan dengan karakteristik tugas baru, misalnya klasifikasi sentimen atau deteksi objek. Proses *fine-tuning* juga dilakukan dengan menggunakan *Learning Rate* yang kecil, agar bobot model yang sudah dilatih sebelumnya tidak berubah secara drastis dan tetap mempertahankan pengetahuan yang telah dipelajari. Setelah proses pelatihan, performa model dievaluasi, dan jika hasilnya belum optimal, penyesuaian lebih lanjut dapat dilakukan seperti membuka lebih banyak *layer* untuk dilatih, mengubah

Learning Rate, atau menerapkan teknik lain hingga model mencapai performa terbaik [28].

2.10 *Confusion Matrix*

Confusion Matrix adalah sebuah tabel yang digunakan untuk mengevaluasi performa model klasifikasi dengan menunjukkan perbandingan antara hasil prediksi model dan label sebenarnya. Tabel ini menampilkan jumlah prediksi yang benar dan salah untuk setiap kelas, yang terdiri dari empat komponen utama: *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). *Confusion Matrix* biasanya digunakan setelah model selesai dilatih, dan dapat ditemukan pada tahap evaluasi model, khususnya ketika mengukur kinerja klasifikasi secara lebih detail daripada hanya menggunakan akurasi saja [29].

2.11 *Python*

Python adalah Bahasa pemrograman tingkat tinggi yang dibuat oleh Guido van Rossum pada tahun 1991. *Python* adalah Interpreter yang memiliki kemampuan exception handling serta agar sintaksnya yang mudah dipahami. *Python* menggunakan indentasi untuk membedakan blok kode, tidak seperti bahasa pemrograman lain yang menggunakan simbol sebagai pembeda blok kode. Secara desain pun *Python* dibuat agar mudah dipahami, salah satunya yaitu tidak diwajibkan untuk menggunakan semicolon(;) [30]. Pengadopsian dynamic typing, yaitu variable yang ingin dibuat tidak diketahui tipe datanya sampai ia dipanggil untuk pertama kali atau dieksekusi, tidak perlu untuk mendeklarasikan variable dan memungkinkan perubahan tipe data dalam proses eksekusi program. *Python* adalah bahasa pemrograman tingkat tinggi yang sangat populer di kalangan para peneliti dan praktisi dalam bidang *data science*, *Machine Learning*, dan *deep Learning*.

Dalam konteks *deep Learning*, *Python* menjadi pilihan utama karena kemudahan integrasinya dengan pustaka-pustaka *Machine Learning* lainnya seperti *Tensorflow*, *PyTorch*, dan *Keras*. Dengan menggunakan *Python*, para peneliti dapat membangun

model-model kompleks dengan lebih cepat, mengoptimalkan performa model, serta melakukan eksperimen dengan berbagai algoritma *deep Learning*. Selain itu, *Python* juga mendukung integrasi dengan berbagai perangkat keras dan pustaka komputasi lainnya, sehingga memungkinkan penggunaan sumber daya yang lebih besar untuk pelatihan model dengan *Dataset* besar, seperti menggunakan GPU (*Graphics Processing Unit*) atau TPU (*Tensor Processing Unit*) untuk meningkatkan kecepatan pelatihan model.


2.12 *Tensorflow*

Tensorflow adalah pustaka *open-source* yang dikembangkan oleh Google untuk mendukung pengembangan dan pelatihan model *Machine Learning* dan *deep Learning*. *Tensorflow* pertama kali diperkenalkan pada tahun 2015 dan dengan cepat menjadi salah satu pustaka yang paling banyak digunakan di seluruh dunia, baik oleh peneliti, pengembang, maupun perusahaan besar. Salah satu keunggulan utama *Tensorflow* adalah kemampuannya untuk melakukan komputasi terdistribusi, yang memungkinkan pelatihan model pada *Dataset* besar secara efisien dengan menggunakan GPU dan TPU. *Tensorflow* juga mendukung berbagai platform, mulai dari perangkat desktop hingga perangkat mobile, sehingga model yang telah dilatih dapat dengan mudah di-deploy ke berbagai aplikasi.

Dalam praktiknya, *Tensorflow* sering dipakai pada neural network untuk melakukan berbagai hal, seperti pengenalan gambar, pengenalan suara, dan natural language processing (NLP). Kode yang ada di *library* bisa ditambahkan ke aplikasi apa pun agar aplikasi tersebut dapat menerapkan berbagai macam tugas. Jenis teknologi ini mempercepat dan mempermudah developer dalam menerapkan model *Machine Learning* karena bisa membantu proses perolehan data, penyajian prediksi dalam skala besar, sekaligus penyempurnaan hasil. Untuk membangun aplikasi dan *framework*-nya, *Tensorflow* menggunakan bahasa pemrograman Python sebagai front-end API. *Python* berfungsi untuk perhitungan numerik dan aliran data yang membuat *Machine Learning* lebih cepat dan mudah dipahami [31].

2.13 Transfer learning

Transfer learning merupakan teknik yang banyak digunakan dalam *Machine Learning* untuk mengatasi tantangan kebutuhan data dalam jumlah besar. Teknik ini memanfaatkan pengetahuan atau fitur-fitur yang telah dipelajari dari suatu tugas dan mengaplikasikannya pada domain atau permasalahan yang berbeda. Pendekatan ini memberikan berbagai manfaat, seperti memanfaatkan bobot dari model yang sudah dilatih dengan data serupa untuk digunakan pada data kita sendiri. Pendekatan ini juga bermanfaat untuk keperluan seperti visualisasi model, mendeteksi neuron yang tidak aktif, atau menggabungkan bobot dari beberapa model seperti dalam *reinforcement learning* [26]. Dengan menggunakan model yang telah dilatih sebelumnya (*pre-trained model*), kita dapat memanfaatkan hasil pelatihan yang telah dilakukan secara menyeluruh untuk tugas yang berbeda, seperti klasifikasi gambar. Hal ini menjadikan proses pengembangan model lebih efisien dan tepat guna.



Gambar 2. 10 Transfer learning

2.14 Augmentasi Data

Dalam kondisi terbatasnya jumlah data pelatihan, salah satu solusi yang dapat digunakan adalah teknik *data augmentation*. Augmentasi data merupakan proses memperluas jumlah data pelatihan dengan cara memodifikasi data yang sudah ada tanpa mengubah label atau makna dari data tersebut. Teknik ini sangat umum digunakan pada pengolahan citra (*image processing*). Sebagai ilustrasi, misalkan tujuan dari model adalah untuk mendeteksi Jenis buah Durian. Idealnya, model dilatih dengan gambar durian dari berbagai sudut dan kondisi. Namun, jika ketersediaan gambar terbatas, kita dapat melakukan augmentasi terhadap gambar yang sudah ada, seperti dengan memutar (*rotate*), memotong sebagian gambar (*crop*), atau melakukan transformasi lainnya. Hasil dari proses augmentasi ini kemudian dianggap sebagai sampel data baru yang valid, sehingga dapat meningkatkan jumlah data pelatihan dan membantu model dalam melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya [26].

2.15 Penelitian Terkait

Penelitian ini tidak lepas dari penelitian yang sudah dilakukan, sehingga penelitian yang dilakukan memiliki persamaan dan perbedaan objek yang diteliti. Ringkasan dari penelitian dapat dilihat dibawah ini:

1. Penelitian ini dilakukan oleh Diana Diana, Tri Basuki Kurniawan, Deshinta Arrova Dewi, Mashal Kasem Alqudah, Musab Kasim Alqudah, Mohd Zaki Zakari, dan Eyna Fahera Binti Eddie Fuad dalam makalah berjudul “*Convolutional Neural Network Based Deep Learning Model for Accurate Classification of Durian Types*” bertujuan untuk mengembangkan prototipe sistem klasifikasi durian berbasis *deep Learning* dengan memanfaatkan model *Convolutional Neural Network* (CNN). Sistem ini dirancang untuk mengenali dan mengklasifikasikan tiga jenis durian populer, yaitu Musang King, Black Thorn, dan D24. *Dataset* yang digunakan terdiri dari 1.372 gambar durian, yang melalui proses *preprocessing* seperti resizing dan *data augmentation*. Dua arsitektur CNN yang digunakan adalah VGG-16 dan Xception. Hasil pengujian

menunjukkan bahwa model VGG-16 menghasilkan akurasi sebesar 56,64%, sedangkan Xception mencapai akurasi yang jauh lebih tinggi, yaitu 92%. Penelitian ini menegaskan potensi penggunaan *deep Learning* untuk meningkatkan akurasi pengenalan durian, yang dapat membantu mengurangi penipuan dalam transaksi jual beli durian dan meningkatkan transparansi di industri durian. Prototipe yang dikembangkan memanfaatkan antarmuka Gradio untuk memudahkan pengguna mengunggah gambar durian dan mendapatkan prediksi secara *real-time*, membuka peluang untuk penerapan lebih lanjut dalam sistem kontrol kualitas dan grading buah secara otomatis [32].

2. Penelitian ini dilakukan oleh Linh T. Duong, Phuong T. Nguyen, Claudio Di Sipio, dan Davide Di Ruscio dalam makalah berjudul “*Automated Fruit Recognition Using Efficientnet and MixNet*” mengusulkan sistem klasifikasi buah otomatis yang memanfaatkan dua arsitektur *deep Learning* terbaru, yakni *Efficientnet* dan MixNet, untuk meningkatkan akurasi dan efisiensi dalam pengenalan buah. Studi ini didorong oleh kebutuhan pertanian modern terhadap teknologi pengolahan citra yang mampu melakukan identifikasi cepat dan akurat, terutama dalam skenario seperti panen otomatis dan pengelolaan stok buah di supermarket. Menggunakan *Dataset Fruits-360* yang terdiri dari 48.905 gambar pelatihan dan 16.421 gambar pengujian, penelitian ini membandingkan performa *Efficientnet* dan MixNet dengan baseline ConvNet. Hasilnya menunjukkan bahwa *Efficientnet-B5* dan MixNet-Small mencapai akurasi hingga 99,98%, jauh lebih baik daripada ConvNet yang hanya mencapai 94,5%. Penelitian ini juga menekankan pentingnya *Transfer learning* untuk meningkatkan akurasi serta membuktikan bahwa model-model ini dapat diimplementasikan secara efisien di perangkat dengan sumber daya terbatas, seperti laptop atau smartphone. Studi ini merekomendasikan penggunaan *Efficientnet* dan MixNet sebagai solusi praktis dan efektif untuk klasifikasi buah secara *real-time* [10].
3. Penelitian ini dilakukan oleh Bam Bahadur Sinha dan R. Dhanalakshmi dalam makalah berjudul “*A Multi-Fused Convolutional Neural Network Model for Fruit Image classification*”. Penelitian ini mengusulkan model klasifikasi gambar buah dengan pendekatan multi-fused CNN yang menggabungkan tiga

arsitektur *deep Learning*, yaitu *Efficientnet-b0*, MobileNetV2, dan ResNet50V2. Tujuan utama dari model ini adalah untuk meningkatkan akurasi klasifikasi serta mengurangi risiko *overfitting* dengan memanfaatkan kekuatan dari masing-masing arsitektur. Model diuji pada *Dataset Fruit-360* dengan 24 dan 131 kelas buah, dan berhasil mencapai akurasi hingga 99,32% untuk 24 kelas serta 97,15% untuk 131 kelas, dengan *precision*, *recall*, dan *F1-score* di atas 99%. Arsitektur *Efficientnet-b0* berperan penting sebagai fondasi efisien dalam sistem gabungan ini, yang memperkuat relevansi penelitian ini terhadap tugas klasifikasi multi-kelas buah seperti klasifikasi jenis buah durian. Penelitian ini juga menunjukkan bahwa pendekatan *Transfer learning* dengan *fine-tuning* dan teknik freezing lapisan mampu meningkatkan kemampuan generalisasi model. Meskipun pendekatan ini cukup kompleks dari sisi komputasi, hasil yang diperoleh menunjukkan bahwa metode multi-fused ini sangat potensial untuk diterapkan dalam sistem pengenalan buah otomatis berbasis citra [9].

4. Penelitian ini dilakukan oleh Mohammed Almomen, Majed Al-Saeed, dan Hafiz Farooq Ahmad dalam makalah berjudul “*Date Fruit Classification Based on Surface Quality Using Convolutional Neural Network Models*”. Penelitian ini berfokus pada pengembangan sistem otomatis berbasis CNN untuk mengklasifikasikan kualitas permukaan buah kurma pada tahap pascapanen guna mengurangi limbah produksi akibat kesalahan klasifikasi manual. *Dataset* yang digunakan terdiri dari dua kelas utama, yaitu buah kurma dengan kualitas permukaan baik dan buruk, masing-masing mencakup 550 sampel. Penelitian ini menggunakan arsitektur *Efficientnet-b0* dan *Efficientnet-B1* yang dilatih menggunakan pendekatan *Transfer learning* dengan bobot pralatih dari *ImageNet*. Sistem klasifikasi dikembangkan melalui tiga modul utama, yaitu: (1) deteksi objek menggunakan algoritma berbasis pengolahan citra (tanpa RCNN), (2) ekstraksi fitur visual menggunakan CNN, dan (3) klasifikasi menggunakan *fully connected layer*. Hasil evaluasi menunjukkan bahwa model *Efficientnet-b0* mampu mengklasifikasikan kurma berdasarkan kualitas permukaannya dengan akurasi sebesar 96%, sedangkan *Efficientnet-B1* mencapai akurasi 97%. Penelitian ini menyimpulkan bahwa arsitektur CNN, khususnya *Efficientnet*, sangat efektif dalam mengotomatisasi proses klasifikasi buah berbasis citra

visual, meskipun masih terdapat keterbatasan pada ukuran *Dataset* dan variasi sudut pengambilan gambar [33].

5. Penelitian ini dilakukan oleh Ümit Atila, Murat Uçar, Kemal Akyol, dan Emine Uçar dalam makalah berjudul “*Plant Leaf Disease Classification Using Efficientnet Deep Learning Model*”. Penelitian ini bertujuan mengklasifikasikan penyakit daun tanaman menggunakan arsitektur *deep Learning Efficientnet* dan membandingkan kinerjanya dengan beberapa model CNN terkini seperti AlexNet, VGG16, ResNet50, dan Inception V3. *Dataset* yang digunakan adalah PlantVillage, yang mencakup 39 kelas dan lebih dari 55.000 gambar daun tanaman sehat maupun yang terinfeksi, serta versi *Dataset* yang telah diaugmentasi hingga mencapai 61.000 gambar. Semua model dilatih dengan pendekatan *Transfer learning* dan *fine-tuning* menggunakan bobot pralatih dari *ImageNet*. Hasil eksperimen menunjukkan bahwa model *Efficientnet-B5* memberikan akurasi terbaik sebesar 99,91% dan presisi 98,42% pada *Dataset* asli, sementara *Efficientnet-B4* mencapai akurasi tertinggi sebesar 99,97% dan presisi 99,39% pada *Dataset* yang diaugmentasi. Penelitian ini menyimpulkan bahwa arsitektur *Efficientnet* sangat unggul dalam mendeteksi dan mengklasifikasikan penyakit daun tanaman dibandingkan model lain, bahkan ketika ukuran *input* citra dikurangi karena keterbatasan perangkat keras [29].
6. Penelitian ini dilakukan oleh Jun Wen dan Jing He dalam makalah berjudul “*Agricultural Development Driven by the Digital Economy: Improved Efficientnet Vegetable Quality Grading*”. Penelitian ini mengusulkan model klasifikasi kualitas sayuran berbasis citra menggunakan arsitektur CA-*Efficientnet*-CBAM, yang merupakan pengembangan dari *Efficientnet* dengan integrasi modul koordinat attention (CA) dan modul perhatian spasial-saluran (CBAM). *Dataset* yang dibangun terdiri dari 3.600 gambar enam jenis sayuran (selada, brokoli, tomat, bawang putih, pare, dan sawi putih), masing-masing dikategorikan menjadi tiga tingkat kualitas (spesial, pertama, dan kedua). Hasil pengujian menunjukkan bahwa model yang diusulkan mencapai akurasi klasifikasi tertinggi sebesar 95,12%, mengungguli model-model lain seperti VGGNet16, ResNet50, dan *DenseNet169*, sekaligus mengurangi jumlah parameter secara signifikan [34].

7. Penelitian ini dilakukan oleh Quoc-Hung Phan, Van-Tung Nguyen, Chi-Hsiang Lien, The-Phong Duong, Max Ti-Kuang Hou, dan Ngoc-Bich Le dalam makalah berjudul “*Classification of Tomato Fruit Using YOLOv5 and Convolutional Neural Network Models*”. Penelitian ini mengembangkan sistem klasifikasi tomat berdasarkan tingkat kematangan (ripe, immature, dan damaged) menggunakan empat arsitektur *deep Learning*, yaitu YOLOv5m, ResNet50, ResNet101, dan *Efficientnet-b0*, dengan pendekatan *Transfer learning* dan data *augmentation*. *Dataset* terdiri dari 1500 gambar untuk masing-masing kategori, diperoleh dari berbagai sudut dan waktu pengambilan untuk meningkatkan robustness model. Hasil eksperimen menunjukkan bahwa kombinasi YOLOv5m dan ResNet101 mencapai akurasi Top-1 tertinggi yaitu 99,7%, sementara model YOLOv5m-*Efficientnet-b0* mencatatkan waktu pelatihan tercepat (50 menit) dengan akurasi 99,3%. Pada tahap pengujian, *Efficientnet-b0* mencatat akurasi 98% dengan *F1-score* 0,99 untuk tomat matang, dan *recall* serta *precision* yang sedikit lebih rendah untuk kategori tomat rusak [35].
8. Penelitian ini dilakukan oleh Johan Muliadi Kerta, Abdul Haris Rangkuti, dan Jeremy Tantio dalam makalah berjudul “*Comparison of Deep Convolutional Neural Network Architectures for Fruit Categorization*”. Penelitian ini membandingkan tujuh arsitektur CNN populer, yaitu ResNet50V2, InceptionV3, InceptionResNetV2, VGG16, VGG19, MobileNetV2, dan *Efficientnet*, dalam tugas klasifikasi 23 jenis buah menggunakan *Dataset Fruits-360* yang terdiri dari 15.987 gambar buah apel, jeruk, dan tomat. Penelitian ini menggunakan dua jenis *optimizers*, yaitu Adam dan Adagrad, untuk mengevaluasi performa dari setiap model berdasarkan akurasi, presisi, *recall*, dan *F1-score*. Hasil eksperimen menunjukkan bahwa penggunaan Adam *optimizer* secara konsisten memberikan akurasi lebih tinggi dibanding Adagrad, dengan *Efficientnet* yang didukung oleh Adam mencapai akurasi antara 98–100% dan menjadi salah satu model dengan performa terbaik. Penelitian ini menyimpulkan bahwa kombinasi *Efficientnet* dengan *optimizer* yang tepat seperti Adam sangat efektif dalam meningkatkan akurasi dan efisiensi klasifikasi buah berbasis citra, sehingga hasil penelitian ini dapat menjadi rujukan penting dalam mendukung implementasi *Efficientnet-b0* untuk tugas klasifikasi jenis buah durian dalam penelitian ini [11].

9. Penelitian ini dilakukan oleh Francis Matheos Sarimole dan Achmad Syaeful dalam makalah berjudul “*Classification of Durian Types Using Feature Extraction Gray Level Co-Occurrence Matrix (GLCM) and K-Nearest Neighbors (KNN)*”. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi jenis buah durian berdasarkan tekstur citra menggunakan metode ekstraksi fitur GLCM dan algoritma klasifikasi K-Nearest Neighbors (KNN). *Dataset* yang digunakan berjumlah 1.600 gambar durian dari berbagai jenis seperti Montong, Musang King, Petruk, Matahari, dan lainnya, yang diambil dari *Dataset* “fruit-262” di Kaggle. Proses klasifikasi melibatkan tahapan *preprocessing* seperti cropping, grayscale, normalisasi ukuran gambar menjadi 100×100 piksel, serta konversi ke skala abu-abu. Fitur tekstur diekstraksi menggunakan GLCM dari empat sudut (0°, 45°, 90°, dan 135°), lalu diklasifikasikan dengan KNN menggunakan nilai K=3 dan metrik jarak Euclidean. Hasil pengujian menunjukkan bahwa sistem ini mampu mencapai akurasi klasifikasi sebesar 93%, dengan performa terbaik pada jenis durian Ajimah (96%) dan performa terendah pada jenis durian Matahari dan Petruk (90%). Penelitian ini menunjukkan bahwa pendekatan klasifikasi berbasis tekstur citra menggunakan GLCM dan KNN dapat memberikan hasil yang baik dalam mengidentifikasi jenis durian, serta memberikan wawasan awal yang berguna untuk pengembangan sistem klasifikasi berbasis *deep Learning* seperti *Efficientnet-b0* dalam penelitian ini [36].
10. Penelitian ini dilakukan oleh Sonjannah, Luthfi Kurniawan, dan Dede Suryana dalam makalah berjudul “*Strawberry Plant Diseases Classification Using CNN Based on MobileNetV2-Large and Efficientnet-b0 Architecture*.” Penelitian ini bertujuan untuk mengklasifikasikan penyakit pada tanaman stroberi menggunakan arsitektur *Convolutional Neural Network* (CNN), yaitu MobileNetV2-Large dan *Efficientnet-b0*, dengan menggunakan *Dataset* berisi gambar daun stroberi yang mengalami gejala penyakit seperti bercak daun dan jamur abu-abu. Penelitian ini mencakup tahap *preprocessing* citra, augmentasi data, pelatihan model, dan evaluasi kinerja menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*. Hasil pengujian menunjukkan bahwa model *Efficientnet-b0* mampu mencapai akurasi yang lebih tinggi dibandingkan MobileNetV2-

Large, yakni sebesar 99,16%, menunjukkan keunggulan arsitektur *Efficientnet* dalam tugas klasifikasi penyakit tanaman berbasis citra [37].

Tabel 2. 1 Penelitian Terkait

Penulis	Tahun	Judul	Kesimpulan
Diana Diana, Tri Basuki Kurniawan, [32] Deshinta Arrova [32] Dewi, Mashal Kasem Alqudah, Musab Kasim Alqudah, Mohd Zaki Zakari, Eyna Fahera Binti Eddie Fuad	2024	<i>Convolutional Neural Network Based Deep Learning Model for Accurate Classification of Durian Types</i>	Model CNN efektif (khususnya Xception) untuk klasifikasi durian dan berpotensi diterapkan dalam grading otomatis. VGG-16: akurasi 56,64%; Xception: akurasi 92%
Linh T. Duong, Phuong T. Nguyen, Claudio Di Sipio, Davide Di Ruscio [10]	2020	<i>Automated Fruit Recognition Using Efficientnet and MixNet</i>	<i>Efficientnet</i> dan MixNet sangat akurat dan efisien untuk klasifikasi buah <i>real-time</i> , cocok untuk perangkat dengan sumber daya terbatas. <i>Efficientnet</i> -B5 & MixNet-Small: akurasi 99,98%; ConvNet: 94,5%
Bam Bahadur Sinha, R. Dhanalakshmi [9]	2024	A Multi-Fused <i>Convolutional Neural Network</i> Model for Fruit <i>Image classification</i>	Model multi-fused efektif untuk klasifikasi multi-kelas, meskipun kompleks secara komputasi; cocok untuk sistem pengenalan buah otomatis. Gabungan <i>Efficientnet-b0</i> , MobileNetV2, ResNet50V2, Akurasi: 99,32% (24 kelas),

Penulis	Tahun	Judul	Kesimpulan
			97,15% (131 kelas); precision, recall, F1-score >99%
Mohammed Almomen, Majed Al-Saeed, Hafiz Farooq Ahmad [33]	2023	Date Fruit Classification Based on Surface Quality Using Convolutional Neural Network Models	<i>Efficientnet</i> efektif untuk klasifikasi visual kurma pascapanen, walaupun terbatas pada ukuran data dan variasi sudut gambar <i>Efficientnet-b0</i> akurasi 96%, <i>Efficientnet-B1</i> akurasi 97%
Ümit Atila, Murat Uçar, Kemal Akyol, Emine Uçar [29]	2021	Plant Leaf Disease Classification Using <i>Efficientnet</i> Deep Learning Model	<i>Efficientnet</i> sangat unggul dalam klasifikasi penyakit daun tanaman, bahkan dengan ukuran <i>input</i> lebih kecil <i>Efficientnet-B5</i> : akurasi 99,91%, presisi 98,42%; <i>Efficientnet-B4</i> : akurasi 99,97%, presisi 99,39% (augmentasi)
Jun Wen, Jing He [34]	2024	Agricultural Development Driven by the Digital Economy: Improved <i>Efficientnet</i> Vegetable Quality Grading	CA- <i>Efficientnet</i> -CBAM (<i>Efficientnet</i> + CBAM + Coordinate Attention) Model mengungguli VGG16, ResNet50, <i>DenseNet169</i> dengan parameter lebih ringan Akurasi tertinggi 95,12%
Quoc-Hung Phan, Van-Tung Nguyen [35]	2023	Classification of Tomato Fruit Using Yolov5 and Convolutional Neural Network Models	Kombinasi CNN dengan YOLO sangat efektif dan efisien untuk klasifikasi tingkat kematangan tomat. Kombinasi Yolov5m-ResNet101 akurasi 99,7%; Yolov5m- <i>Efficientnet-b0</i> tercepat (50 menit) dan akurasi

Penulis	Tahun	Judul	Kesimpulan
			99,3%; <i>Efficientnet-b0</i> akurasi 98% (<i>F1-score</i> 0,99)
Johan Muliadi Kerta, Abdul Haris Rangkuti, Jeremy Tantio [11]	2024	Comparison of <i>Deep Convolutional Neural Network Architectures</i> for Fruit Categorization	<i>Efficientnet</i> dengan Adam adalah kombinasi paling unggul dalam klasifikasi buah berbasis citra. <i>Efficientnet</i> + Adam: akurasi 98–100%
Frencis Matheos Sarimole, Achmad Syaeful [36]	2022	<i>Classification</i> of Durian Types Using Feature Extraction Gray Level Co-Occurrence Matrix (GLCM) and K-Nearest Neighbors (KNN)	GLCM + KNN efektif untuk klasifikasi awal durian, dapat dikembangkan ke model <i>deep Learning</i> . Akurasi 93%; durian Ajimah 96%, Matahari & Petruk 90%
Sonjannah, Luthfi Kurniawan, Dede Suryana [37]	2023	Strawberry Plant Diseases <i>Classification</i> Using CNN Based on MobileNetV2-Large and <i>Efficientnet-b0 Architecture</i>	<i>Efficientnet-b0</i> lebih unggul dibanding MobileNetV2-Large untuk klasifikasi penyakit daun stroberi. <i>Efficientnet-b0</i> akurasi 99,16%

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat

Penelitian dilakukan di laboratorium Teknik Komputer Unila dengan peralatan penelitian. Waktu penelitian dimulai dari bulan Maret 2025 sampai dengan bulan Agustus 2025.

3.2 Jadwal penelitian

Jadwal penelitian adalah sebagai berikut :

Tabel 3. 1 Jadwal Penelitian

No	Aktivitas	Maret 2025	April 2025	Mei 2025	Juni 2025	Juli 2025	Agustus 2025
1.	Identifikasi Masalah						
2.	Studi Literatur						
3.	Perumusan Masalah dan Tujuan						
4.	Pengumpulan <i>Dataset</i> Jenis Durian						
5.	<i>Preprocessing Dataset</i>						
6.	Perancangan dan Pelatihan Model						
7.	Evaluasi Model						
8.	Pembuatan Laporan						

3.3 Alat dan Bahan Penelitian


Alat dan bahan yang digunakan dalam penelitian ini disajikan secara lebih rinci pada tabel 3.2, yang memuat daftar perangkat keras, perangkat lunak, serta bahan pendukung lain yang berperan penting dalam menunjang pelaksanaan penelitian dari tahap awal hingga tahap akhir.

Tabel 3. 2 Alat dan Bahan Penelitian

No	Nama Bahan	Spesifikasi	Deskripsi
1.	Laptop Acer Swift X SFX14-41G	AMD Ryzen 5 5600U, RAM 16 GB, OS Windows 11	Perangkat keras yang digunakan dalam keseluruhan penelitian, yang mencakup setiap tahapan dari mulai data analisis, data <i>preprocessing</i> , data <i>modelling</i> , dan data <i>evaluation</i>
2.	Handphone Android Redmi Note 11 Pro 5G	Snapdragon 695, Android 11, RAM 8 GB	Perangkat Handphone yang digunakan untuk menguji coba model dalam aplikasi android dan pengambilan <i>Dataset</i> secara langsung
3.	Google Collab	Website	Perangkat Lunak yang digunakan untuk melakukan pemrograman model
4.	Google Drive	Aplikasi	Sebagai tempat penyimpanan untuk <i>Dataset</i> penelitian
5.	Github	Website	Perangkat lunak yang digunakan untuk mendokumentasikan code
6.	Notion	Aplikasi	Perangkat lunak yang dirancang untuk membantu Tim dalam mencatat, merencanakan, dan mengorganisasi proyek serta kolaborasi

7.	<i>Python</i>	3.8.10	Bahasa pemrograman utama dalam melakukan pengembangan model
8.	<i>Dataset</i> Jenis Buah Durian	Data yang akan digunakan untuk keperluan Penelitian	Data yang digunakan untuk bahan penelitian diambil dari <i>Dataset</i> https://www.kaggle.com/Datasets/edenbarua/Dataset dan foto yang diambil langsung di toko durian blehong, teluk betung dan way halim
9.	<i>Tensorflow.keras</i>	Aplikasi	Pustaka yang digunakan untuk menghitung matriks multidimensi dan pelatihan model <i>Efficientnet-b0</i>
10.	Matplotlib	Aplikasi	Perangkat lunak yang digunakan untuk proses modifikasi <i>Dataset</i> citra saat pengembangan model

3.4 Tahapan Penelitian



Gambar 3. 1 Tahapan Penelitian

3.4.1 Identifikasi Masalah

Tahap awal dalam penelitian ini adalah melakukan identifikasi masalah yang akan menjadi fondasi utama dalam keseluruhan proses penelitian. Proses identifikasi jenis durian saat ini masih banyak dilakukan secara manual berdasarkan pengamatan visual oleh petani atau pedagang. Metode ini sangat bergantung pada pengalaman individu, sehingga bersifat subjektif dan memiliki potensi terjadinya

kesalahan identifikasi. Salah satu masalah yang sering terjadi di lapangan adalah adanya manipulasi dalam pengklasifikasian durian, di mana durian lokal atau biasa diklaim sebagai varietas unggulan seperti musang king agar mendapatkan harga jual yang lebih tinggi. Hal ini tidak hanya merugikan konsumen, tetapi juga dapat menurunkan kepercayaan terhadap pasar durian.

3.4.2 Studi Literatur

Pada tahap selanjutnya penelitian, dilakukan studi literatur yang bertujuan untuk memahami konsep dasar serta pendekatan yang relevan dengan topik penelitian. Fokus utama studi ini adalah pada penerapan algoritma *Convolutional Neural Network* (CNN), khususnya arsitektur *Efficientnet-b0*, dalam proses klasifikasi citra buah. Literatur yang dikaji diambil dari sumber-sumber ilmiah terpercaya seperti jurnal dari Elsevier, IEEE, MDPI, dan Springer. Kajian dilakukan terhadap beberapa aspek penting, antara lain: prinsip kerja CNN, arsitektur *Efficientnet-b0*, konsep *Transfer learning*, serta studi-studi sebelumnya terkait klasifikasi citra buah menggunakan pendekatan *deep Learning*.

3.4.3 Merumuskan Masalah dan Tujuan

Berdasarkan hasil identifikasi dan studi literatur, permasalahan utama dalam penelitian ini adalah bagaimana membangun model klasifikasi citra buah durian berdasarkan jenisnya secara akurat menggunakan arsitektur *Efficientnet-b0*, serta bagaimana pengaruh konfigurasi *hyperparameter* terhadap performa model klasifikasi yang dihasilkan serta tujuan dari penelitian ini adalah membangun model klasifikasi citra buah durian berdasarkan jenis menggunakan arsitektur *Efficientnet-b0* serta menguji pengaruh konfigurasi *hyperparameter* terhadap akurasi dan performa klasifikasi model tersebut.

3.4.4 Pengumpulan *Dataset* Jenis Durian



Gambar 3. 2 *Dataset* 7 Varietas Durian

Dataset yang digunakan dalam penelitian ini bersifat terbatas, karena penelitian difokuskan pada beberapa varietas durian tertentu dengan tujuan memperoleh hasil akurasi yang optimal. *Dataset* yang digunakan merupakan gabungan dari dua sumber, yaitu *Dataset* publik yang tersedia di platform Kaggle pada tautan <https://www.kaggle.com/Datasets/edenbarua/Dataset>, serta data citra durian yang diperoleh secara langsung melalui pengambilan foto di toko buah Durian Blehong yang berlokasi di daerah Teluk dan Way halim. Adapun tujuh varietas durian yang digunakan dalam *Dataset* ini dapat dilihat pada gambar 3.2 dan meliputi: Durian

Sumatra Super, Durian Medan, Bengkulu, Kota Agung, Musang King, *Golden phoenix* dan D24(Sultan). Jumlah data awal yang didapat tidak seimbang karna jumlahnya yang berbeda beda. Pemilihan varietas ini juga didasarkan pada ketersediaan data, karakteristik visual yang berbeda-beda, merupakan varietas unggulan yang paling banyak diminati pasar dan dijual belikan pada musim tertentu di daerah bandar lampung.

3.4.4.1 Durian Musang King

Durian Musang King memiliki beberapa ciri khas yang membedakannya dari jenis durian lainnya seperti terlihat pada gambar 3.3. Duri pada kulitnya lebih pendek dan tebal, serta bentuk buahnya agak bulat. dengan tekstur yang lembut dan krim. Bentuknya oval dengan tangkai yang panjang. Kulitnya warna-warni, ada bagian yang berwarna kuning, coklat, hingga hijau [38].



Gambar 3. 3 Durian Musang King

3.4.4.2 Durian D24/Sultan

Ciri-ciri dari durian D24 bisa dilihat dari warna kulit yang hijau kekuningan cerah seperti terlihat pada gambar 3.4. fitur paling unik dari D24 dari bagian luarnya adalah bagian bawah yang agak cekung dan bulat pada area tempat sambungan kulit bertemu, hampir seperti pusar [39].



Gambar 3. 4 Durian D24/Sultan

3.4.4.3 Durian *Golden phoenix*

durian golden phoenix umumnya berukuran kecil hingga sedang yang tidak lebih dari 1,5 kg. Banyak di antaranya yang beratnya di bawah 1 kg. Dengan bentuk yang sebagian besar bulat dan sebagian agak oval seperti terlihat pada gambar 3.5. Kulit durian ini sebagian besar berwarna hijau pudar dan terang, dengan beberapa yang cenderung ke abu-abu/cokelat [40].



Gambar 3. 5 Durian *Golden phoenix*

3.4.4.4 Durian Sumatra Super

Durian Sumatra Super memiliki bentuk cenderung bulat lonjong dengan duri yang ramping, runcing, dan rapat seperti terlihat pada gambar 3.6. Warna kulit didominasi hijau muda pudar dengan sedikit gradasi kekuningan di beberapa area serta Tekstur kulitnya terlihat kering dengan duri yang menonjol tajam, memberikan kesan kokoh namun tetap simetris. (Toko Durian Z3, Way Halim)



Gambar 3. 6 Durian Sumatra Super

3.4.4.5 Durian Medan

Durian Medan memiliki ukuran yang tidak terlalu besar. Durian ini memiliki kulit luar berwarna hijau kekuningan dengan permukaan penuh duri yang tajam dan rapat [41] seperti terlihat pada gambar 3.7.



Gambar 3. 7 Durian Medan

3.4.4.6 Durian Bengkulu

Durian Bengkulu memiliki bentuk buahnya bulat seperti telur terbalik seperti terlihat pada gambar 3.8. durian Bengkulu memiliki kulit luar berwarna coklat kekuningan dengan sedikit semburat hijau. (Toko Durian Z3, Way Halim)



Gambar 3. 8 Durian Bengkulu

3.4.4.7 Durian Kota Agung

durian kota Agung memiliki kulit luar berwarna hijau kekuningan dengan sedikit nuansa kecokelatan pada ujung durinya seperti terlihat pada gambar 3.9. Duri berbentuk kerucut panjang dan runcing, tersusun rapat dan merata di seluruh permukaan kulit. (Toko Durian Z3, Way Halim)



Gambar 3. 9 Durian Kota Agung

3.4.5 *Preprocessing data*

Tahap *preprocessing* data dilakukan untuk menyiapkan citra ke dalam format yang sesuai dengan *input* model CNN, khususnya arsitektur *Efficientnet-b0*. Proses ini penting untuk memastikan kualitas dan konsistensi data sebelum digunakan dalam pelatihan dan evaluasi model. Adapun beberapa tahapan *preprocessing* yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Penyesuaian Ukuran Gambar (*Resize*)

Seluruh gambar durian dalam *Dataset* diubah ukurannya menjadi 224×224 piksel, sesuai dengan ukuran *input* yang disyaratkan oleh arsitektur *Efficientnet-b0*. Proses *resize* dilakukan menggunakan pustaka *OpenCV* dengan menerapkan metode interpolasi bilinear, yang menghitung rata-rata dari empat piksel tetangga terdekat. Metode ini dipilih karena mampu menjaga kualitas visual gambar setelah skala diubah, terutama dalam mempertahankan bentuk dan tekstur objek durian [36].

2. Normalisasi Nilai Piksel (*Rescale*)

Normalisasi dilakukan untuk mengubah rentang nilai piksel dari RGB (0–255) menjadi nilai *float32* dalam rentang [0, 1]. Hal ini bertujuan agar distribusi nilai *input* menjadi lebih stabil dan sesuai dengan standar *input* model *pretrained* seperti *Efficientnet*. Normalisasi juga membantu mempercepat konvergensi saat proses pelatihan model [36].

3. Augmentasi Data (*Data Augmentation*)


Dalam kondisi terbatasnya jumlah data pelatihan, salah satu solusi yang dapat digunakan adalah teknik data *augmentation*. Augmentasi data merupakan proses memperluas jumlah data pelatihan dengan cara memodifikasi data yang sudah ada tanpa mengubah label atau makna dari data tersebut. Penambahan data untuk data *augmentation* meliputi penskalaan ulang, rotasi, pergeseran horizontal dan vertikal, transformasi geser, *zoom* acak, dan pembalikan horizontal [32].

4. Pembagian *Dataset*

Tahap *Preprocessing data* mencakup pembagian *Dataset* menjadi tiga bagian, yaitu data pelatihan, data validasi, dan data pengujian. Data pelatihan digunakan untuk melatih model, data validasi digunakan untuk menyetel *hyperparameter*, sedangkan data pengujian digunakan untuk mengevaluasi performa model terhadap data yang belum pernah dilihat sebelumnya. Pada penelitian ini, pembagian *Dataset* dilakukan dengan rasio 70:10:20, yang berarti 70% data digunakan untuk pelatihan, 10% untuk validasi, dan 20% untuk pengujian [32].

3.4.6 Perancangan Arsitektur *Efficientnet-b0*

Efficientnet-b0 merupakan model *Convolutional Neural Network* (CNN) yang efisien dengan total parameter sekitar 5,3 juta. Model ini menggunakan ukuran *input* default $224 \times 224 \times 3$ dan tersedia dalam bentuk *pretrained weights* dari *ImageNet*. Arsitektur *Efficientnet-b0* dibangun menggunakan blok *MBConv* (*Mobile Inverted Bottleneck Convolution*) yang serupa dengan *MobileNetV2*, serta menggabungkan teknik *Depthwise Separable convolution* untuk efisiensi komputasi. Selain itu, model ini juga dilengkapi dengan *Squeeze-and-Excitation* (SE) *block* untuk memberi perhatian pada saluran (*channel attention*), serta menggunakan fungsi aktivasi *Swish* yang dalam beberapa implementasi Keras dapat digantikan dengan ReLU.



Gambar 3. 10 Arsitektur *Efficientnet-b0*

Pada Gambar 3.10 ditunjukkan tahapan arsitektur dari *Efficientnet-b0* yang dimulai dari *input image* berukuran $224 \times 224 \times 3$ yang kemudian melalui *stem layer* berupa konvolusi awal (Conv3×3) dengan 32 *filter*, *stride* 2, dan fungsi aktivasi *Swish*. Tahap ini bertujuan untuk mengekstraksi fitur dasar dari citra masukan sekaligus mengurangi resolusi spasialnya. Selanjutnya, data diproses melalui beberapa blok *MBConv* (*Mobile Inverted Bottleneck Convolution*) dengan konfigurasi kernel, jumlah *filter*, dan *stride* yang berbeda pada setiap tahap, disertai teknik *depthwise convolution* dan *Squeeze-and-Excitation* untuk meningkatkan efisiensi ekstraksi fitur.

Blok pertama adalah *MBConv1* dengan kernel 3×3, 16 *filter*, dan *stride* 1, diikuti oleh *MBConv6* berulang dengan variasi ukuran kernel (3×3 dan 5×5) serta jumlah *filter* yang meningkat secara bertahap dari 24 hingga 320. Peningkatan jumlah *filter* di setiap tahap disertai penurunan resolusi spasial melalui *stride* 2 pada awal blok baru, sehingga model mampu menangkap fitur dari tingkat detail rendah hingga tinggi. Setelah melalui seluruh tahapan *MBConv*, hasil ekstraksi fitur dikompresi melalui Conv1×1 dengan 1280 *filter* dan fungsi aktivasi *Swish* untuk mengintegrasikan seluruh informasi fitur yang telah diperoleh.

filter (atau kernel) pada *layer* konvolusi berfungsi untuk mengekstraksi fitur dari citra masukan dengan cara melakukan operasi konvolusi. *Filter* bergerak (*sliding*) melintasi citra masukan sesuai dengan nilai *stride*, dan setiap pergeseran menghitung hasil perkalian elemen demi elemen antara nilai piksel dan bobot *filter*, lalu menjumlahkannya untuk menghasilkan nilai piksel baru pada output *feature map*. Ukuran *filter*, jumlah *filter*, nilai *stride*, dan jenis *padding* akan mempengaruhi dimensi output yang dihasilkan. Pada contoh diatas, ukuran *input* adalah 112×112 piksel dengan *filter* 3×3, *stride* 1, dan *padding same*. *Padding* ini menambahkan piksel nol di tepi citra agar dimensi output sama dengan *input*. Dengan demikian, perhitungannya menjadi:

$$Output\ Size = \left\lceil \frac{Input\ Size - Filter\ Size + 2 \times Padding}{Stride} \right\rceil + 1$$

$$Output\ Size = \left\lceil \frac{112 - 3 + 2}{1} \right\rceil + 1 = \left\lceil \frac{111}{1} \right\rceil + 1 = 111 + 1 = 112$$

Sehingga dimensi spasial tetap 112×112 , namun jumlah channel berubah sesuai jumlah *filter*, misalnya menjadi 16. *Filter* inilah yang memungkinkan model menangkap berbagai pola pada citra, seperti tepi, tekstur, atau bentuk tertentu, yang selanjutnya akan digunakan untuk proses klasifikasi.

Tahap akhir terdiri dari *global average pooling* yang mengubah representasi fitur menjadi vektor satu dimensi, diikuti oleh lapisan *fully connected* dengan 1000 neuron yang pada penelitian ini akan disesuaikan dengan jumlah 7 neuron untuk klasifikasi 7 jenis durian, dan fungsi aktivasi *softmax* untuk menghasilkan probabilitas klasifikasi. Arsitektur *Efficientnet-b0* mengoptimalkan kinerja melalui kombinasi compound scaling pada kedalaman jaringan, lebar jaringan, dan resolusi citra, sehingga mencapai keseimbangan optimal antara akurasi dan efisiensi komputasi.

3.4.7 Pelatihan Model

Tahap pelatihan model merupakan inti dari proses pengembangan sistem klasifikasi varietas buah durian berbasis *Convolutional Neural Network* (CNN) dengan arsitektur *Efficientnet-b0*. Dalam penelitian ini, pelatihan dilakukan dengan pendekatan *Transfer learning*, yang memungkinkan pemanfaatan bobot (parameter) dari model yang telah dilatih sebelumnya menggunakan *Dataset* berskala besar, yaitu *ImageNet*. Pendekatan ini sangat efektif, terutama ketika jumlah data latih spesifik—seperti citra buah durian—masih terbatas.

Langkah awal dari pelatihan adalah memuat model *Efficientnet-b0* beserta bobot pralatih dari *ImageNet*. Bobot ini telah mewakili berbagai fitur umum dari citra alami, seperti tepi, warna, tekstur, dan pola, yang juga relevan dalam pengenalan citra buah. Selanjutnya, ditambahkan lapisan klasifikasi baru pada bagian akhir model, berupa satu atau lebih *Dense layer* dengan fungsi aktivasi *Softmax* yang disesuaikan untuk mengklasifikasikan citra menjadi tujuh kelas, yaitu Musang King, D24(Durian Sultan), *Golden phoenix*, Sumatra Super, Bengkulu, Kota Agung dan Medan. Penambahan lapisan ini diperlukan karena model *pretrained ImageNet* awalnya dikembangkan untuk klasifikasi 1.000 kelas objek umum, bukan

untuk varietas buah tertentu. Proses pelatihan dilakukan dengan *optimizer* Adam, yang merupakan algoritma optimasi adaptif dan populer digunakan dalam pelatihan jaringan saraf karena kemampuannya dalam mengatur laju pembelajaran secara dinamis. Sementara itu, fungsi *Loss* yang digunakan adalah *Categorical Crossentropy*, karena klasifikasi yang dilakukan bersifat multi-kelas dan saling eksklusif.

3.4.7 Percobaan *Hyperparameter Tuning*

Untuk memperoleh performa terbaik, pelatihan model dijalankan dengan melakukan eksplorasi dan penyesuaian terhadap sejumlah *hyperparameter* penting, seperti: *Learning Rate*, *Batch Size*, *Dense layer* dan Jumlah *Epoch*. Beberapa konfigurasi diuji dan dibandingkan berdasarkan performa terhadap data validasi. Penyesuaian *hyperparameter* dilakukan secara manual dengan pendekatan *grid search* sederhana, dan hasil terbaik akan dipilih berdasarkan kombinasi akurasi validasi tertinggi dan stabilitas *Loss* selama pelatihan. Seluruh proses pelatihan dilakukan menggunakan framework *Tensorflow Keras* yang mendukung integrasi dengan arsitektur *Efficientnet* secara langsung, serta memungkinkan pemanfaatan GPU untuk mempercepat proses komputasi.

3.4.8 Evaluasi Model

Evaluasi dilakukan menggunakan data uji yang belum pernah digunakan selama proses pelatihan maupun validasi, sehingga dapat memberikan gambaran sejauh mana kemampuan generalisasi model terhadap data baru. Pada tahap ini, model dievaluasi menggunakan beberapa metrik performa seperti akurasi, presisi, *recall*, dan *F1-score*. Selain itu, digunakan *Confusion Matrix* untuk melihat distribusi prediksi model terhadap setiap kelas durian, serta untuk mengidentifikasi potensi kesalahan klasifikasi antar kelas yang memiliki kemiripan visua, misalnya apabila model cenderung salah mengklasifikasikan varietas D24 sebagai Musang King, dan sebaliknya.

Evaluasi juga mencakup analisis visual terhadap kurva akurasi dan *Loss* selama proses pelatihan dan validasi. Grafik ini digunakan untuk mendeteksi potensi masalah seperti *overfitting*—di mana model terlalu “menghafal” data pelatihan dan gagal mengenali pola pada data baru—atau *underfitting*, ketika model belum belajar secara optimal. Kurva pelatihan dan validasi yang stabil dan mendekati menunjukkan proses pelatihan yang berhasil. Selain evaluasi model akhir, dilakukan juga *tuning hyperparameter* secara iteratif. Proses ini melibatkan perubahan nilai pada parameter seperti *Learning Rate*, *Batch Size*, dan *dropout rate*, serta pemilihan jumlah *Epoch* yang ideal. Setiap kombinasi diuji dan dievaluasi menggunakan data validasi, kemudian dipilih konfigurasi dengan hasil terbaik dari segi akurasi dan kestabilan.

V. SIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan dari hasil penelitian, terdapat beberapa kesimpulan, yaitu :

1. Model berhasil dikembangkan menggunakan arsitektur *Efficientnet-b0* dengan akurasi mencapai 99% dalam mengklasifikasikan varietas pada buah durian
2. Model *Efficientnet-b0* yang dikembangkan menunjukkan Performa tinggi untuk klasifikasi 7 varietas durian dengan menggunakan metode *Transfer learning* dari *ImageNet*, *Dataset* Dilakukan Augmentasi, dan Tanpa dilakukan *Fine Tuning* menghasilkan akurasi pelatihan mencapai 99.67%, validasi pelatihan mencapai 100%, akurasi *Loss* 0,1383, dan validasi *Loss* 0,1283. Analisis menunjukkan pelatihan tanpa menggunakan *Fine Tuning* lebih baik daripada menggunakan *Fine Tuning* yang mengakibatkan terjadinya *overfitting*.
3. Konfigurasi *hyperparameter* terbaik yang diperoleh melalui proses *tuning* terdiri dari *Dense layer* sejumlah 128 neuron, jumlah *Epoch* sebesar 20, *Learning Rate* sebesar 0.001, dan *Batch Size* sebesar 16. Dengan konfigurasi tersebut, model *Efficientnet-b0* mampu mencapai akurasi pelatihan sebesar 99.95% dan akurasi validasi sebesar 99.29%, dengan nilai *Loss* masing-masing 0.0699 dan 0.0805.

5.2 Saran

Saran untuk penelitian Tugas Akhir selanjutnya, yaitu :

1. Menambah Jumlah *Dataset* jenis durian lebih banyak untuk meningkatkan variasi *Dataset*
2. Mencoba membandingkan Arsitektur CNN lainnya dengan model yang digunakan saat ini.

DAFTAR PUSTAKA

- [1] N. Najira, E. Selviyanti, Y. Br. Tobing, K. Kasmawati, R. Sianturi, and A. B. Suwardi, "Diversitas Kultivar tanaman Durian (*Durio zabethinus Murr.*) Ditinjau dari Karakter Morfologi," *J. Biol. Trop.*, vol. 20, no. 2, pp. 185–193, May 2020, doi: 10.29303/jbt.v20i2.1871.
- [2] Badan Pusat Statistik, "Produksi Tanaman Buah-buahan dan Sayuran Tahunan Menurut Provinsi dan Jenis Tanaman, 2024." Accessed: May 05, 2025. [Online]. Available: www.bps.go.id
- [3] S. Thongkaew, C. Jatuporn, P. Sukprasert, P. Rueangrit, and S. Tongchure, "Factors affecting the durian production of farmers in the eastern region of Thailand," *Int. J. Agric. Ext.*, vol. 9, no. 2, pp. 285–293, Aug. 2021, doi: 10.33687/ijae.009.02.3617.
- [4] "Destinasi Agrowisata Favorit di Indonesia." [Online]. Available: https://www.traveloka.com/id-id/explore/destination/destinasi-agrowisata-favorit-di-indonesia-acc/299365?utm_source=chatgpt.com
- [5] "Rata-rata harga buah di kabupaten ngawi." [Online]. Available: <https://ngawikab.bps.go.id/id/statistics-table/2/MTczIzI=/rata-rata-harga-buah-buahan-di-kabupaten-ngawi.html>
- [6] A. Asminah, D. Setiadi, and T. Susanti, "Klasifikasi Jenis Buah Durian dengan Metode *K-Nearest Neighbor*," *BINA INSANI ICT J.*, vol. 10, no. 2, p. 176, Dec. 2023, doi: 10.51211/biict.v10i2.2656.
- [7] "Musim Berakhir : Bermunculan Musang King Palsu." [Online]. Available: <https://food.detik.com/info-kuliner/d-7581775/musim-durian-berakhir-bermunculan-musang-king-palsu>
- [8] *A Feature Learning Based Approach for Automated Fruit Yield Estimation.* [Online]. Available: https://link.springer.com/chapter/10.1007/978-3-319-07488-7_33#citeas

- [9] B. B. Sinha and R. Dhanalakshmi, “*A multi-fused Convolutional Neural Network model for fruit image classification*,” *Int. J. Cogn. Comput. Eng.*, vol. 5, pp. 416–424, 2024, doi: 10.1016/j.ijcce.2024.09.003.
- [10] L. T. Duong, P. T. Nguyen, C. Di Sipio, and D. Di Ruscio, “*Automated fruit recognition using Efficientnet and MixNet*,” *Comput. Electron. Agric.*, vol. 171, p. 105326, Apr. 2020, doi: 10.1016/j.compag.2020.105326.
- [11] A. Haris Rangkuti, J. Tantio, and J. Muliadi Kerta, “*Comparison of Deep Convolutional Neural Network Architectures for Fruit Categorization*,” *Int. J. Electr. Comput. Eng. Syst.*, vol. 15, no. 3, pp. 247–259, 2024, doi: 10.32985/ijeces.15.3.4.
- [12] S. Ketsa, “Durian— *Durio zibethinus*,” in *Exotic Fruits*, Elsevier, 2018, pp. 169–180. doi: 10.1016/B978-0-12-803138-4.00022-8.
- [13] “Dataset 7 Varietas Durian.” [Online]. Available: https://drive.google.com/drive/folders/1uSFZBY5gE-hoGDMY4MDA_jS9peevgISD?usp=sharing
- [14] Chitkara Institute of Engineering and Technology, Chitkara University, Punjab-140401, India *et al.*, “*Real World of Artificial intelligence – A Review*,” *J. Technol. Manag. Grow. Econ.*, vol. 11, no. 2, pp. 41–47, Nov. 2020, doi: 10.15415/jtmge.2020.112005.
- [15] I. Cholissodin, “*Buku Ajar AI, Machine Learning & Deep Learning*,” *Mach. Learn.*, 2020.
- [16] U. Khan *et al.*, “*A Systematic Literature Review of Machine Learning and Deep Learning Approaches for Spectral Image classification in Agricultural Applications Using Aerial Photography*,” *Comput. Mater. Contin.*, vol. 78, no. 3, pp. 2967–3000, 2024, doi: 10.32604/cmc.2024.045101.
- [17] G. N. Kaya, F. Beyhan, Z. Y. İlerisoy, and J. Cudzik, “*Evaluation of Machine Learning applications in building life cycle processes for energy efficiency: A systematic review*,” *Energy Rep.*, vol. 13, pp. 4900–4916, Jun. 2025, doi: 10.1016/j.egyr.2025.04.034.
- [18] S. A. Ajagbe and M. O. Adigun, “*Deep Learning techniques for detection and prediction of pandemic diseases: a systematic literature review*,” *Multimed.*

- Tools Appl.*, vol. 83, no. 2, pp. 5893–5927, Jan. 2024, doi: 10.1007/s11042-023-15805-z.
- [19] Y. F. Wijaya and D. Hindarto, “*Advancing Fruit Image classification with State-of-the-Art Deep Learning Techniques*,” *sinkron*, vol. 8, no. 2, pp. 1125–1134, Apr. 2024, doi: 10.33395/sinkron.v8i2.13604.
- [20] Y. Xie *et al.*, “*Convolutional Neural Network Techniques for Brain Tumor Classification (from 2015 to 2022): Review, Challenges, and Future Perspectives*,” *Diagnostics*, vol. 12, no. 8, p. 1850, Jul. 2022, doi: 10.3390/diagnostics12081850.
- [21] S. Bera, V. K. Shrivastava, and S. Chandra Satapathy, “*Advances in Hyperspectral Image classification Based on Convolutional Neural Networks: A Review*,” *Comput. Model. Eng. Sci.*, vol. 133, no. 2, pp. 219–250, 2022, doi: 10.32604/cmesci.2022.020601.
- [22] “CNN Introduction to Pooling layer.” [Online]. Available: <https://www.geeksforgeeks.org/cnn-introduction-to-pooling-layer/>
- [23] “Fully connected layer vs Convolutional Neural Network.” [Online]. Available: <https://builtin.com/machine-learning/fully-connected-layer#:~:text=Fully%20Connected%20Layer?-,A%20fully%20connected%20layer%20refers%20to%20a%20neural%20network%20layer,output%20of%20the%20output%20vector.>
- [24] H. Cai, L. Zhu, and S. Han, “ProxlessNAS: Direct Neural Architecture Search on Target Task and Hardware,” Feb. 23, 2019, arXiv: arXiv:1812.00332. doi: 10.48550/arXiv.1812.00332.
- [25] F. Farhangi, “*Investigating the role of data preprocessing, hyperparameters tuning, and type of Machine Learning algorithm in the improvement of drowsy EEG signal modeling*,” *Intell. Syst. Appl.*, vol. 15, p. 200100, Sep. 2022, doi: 10.1016/j.iswa.2022.200100.
- [26] *Neural Network from Scratch in Python by Harrison Kinsley Daniel.*
- [27] “What is Fine Tuning.” [Online]. Available: <https://www.ibm.com/think/topics/fine-tuning>
- [28] “geeks Fine Tuning.” [Online]. Available: <https://www.geeksforgeeks.org/deep-learning/what-is-fine-tuning/>

- [29] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, “*Plant leaf disease classification using Efficientnet deep Learning model*,” *Ecol. Inform.*, vol. 61, p. 101182, Mar. 2021, doi: 10.1016/j.ecoinf.2020.101182.
- [30] R. F. Muharram and A. Suryadi, “Implementasi *artificial intelligence* untuk deteksi masker secara realtime dengan *tensorflow* dan *ssdmobilenet* Berbasis *python*,” vol. 3.
- [31] “*Tensorflow* Introduction.” [Online]. Available: <https://www.revou.co/kosakata/tensorflow>
- [32] D. Diana, “*Convolutional Neural Network Based Deep Learning Model for Accurate Classification of Durian Types*,” *J. Appl. Data Sci.*, vol. 6, no. 1, pp. 101–114, Jan. 2024, doi: 10.47738/jads.v6i1.480.
- [33] M. Almomen, M. Al-Saeed, and H. F. Ahmad, “*Date Fruit Classification Based on Surface Quality Using Convolutional Neural Network Models*,” *Appl. Sci.*, vol. 13, no. 13, p. 7821, Jul. 2023, doi: 10.3390/app13137821.
- [34] J. Wen and J. He, “*Agricultural development driven by the digital economy: improved Efficientnet vegetable quality grading*,” *Front. Sustain. Food Syst.*, vol. 8, p. 1310042, Jan. 2024, doi: 10.3389/fsufs.2024.1310042.
- [35] Q.-H. Phan, V.-T. Nguyen, C.-H. Lien, T.-P. Duong, M. T.-K. Hou, and N.-B. Le, “*Classification of Tomato Fruit Using Yolov5 and Convolutional Neural Network Models*,” *Plants*, vol. 12, no. 4, p. 790, Feb. 2023, doi: 10.3390/plants12040790.
- [36] F. M. Sarimole and A. Syaeful, “*Classification of Durian Types Using Features Extraction Gray Level Co-Occurrence Matrix (GLCM) AND K-Nearest Neighbors (KNN)*,” *J. Appl. Eng. Technol. Sci. JAETS*, vol. 4, no. 1, pp. 111–121, Sep. 2022, doi: 10.37385/jaets.v4i1.959.
- [37] D. A. Pramudhita, F. Azzahra, I. K. Arfat, R. Magdalena, and S. Saidah, “*Strawberry Plant Diseases Classification Using CNN Based on MobileNetV3-Large and Efficientnet-b0 Architecture*,” *J. Ilm. Tek. Elektro Komput. Dan Inform.*, vol. 9, no. 3, pp. 522–534, Jul. 2023, doi: 10.26555/jiteki.v9i3.26341.
- [38] “Ciri Varietas Durian Musang King.” [Online]. Available: <https://www.tempo.co/gaya-hidup/muasal-nama-durian-musang-king->

terinspirasi-binatang-yang-pandai-memilih-kualitas-durian-
53758#goog_rewarded

- [39] “Ciri Varietas Durian D24/Sultan.” [Online]. Available:
<https://www.durianed.com/d24-durian>
- [40] “Ciri Durian *Golden phoenix*.” [Online]. Available:
<https://www.durianed.com/golden-phoenix>
- [41] “Ciri Varietas Durian Medan.” [Online]. Available:
<https://food.detik.com/info-kuliner/d-7502722/mantap-ini-5-durian-unggulan-asli-sumatera-yang-legit-harum>