

**KINERJA *MOBILENET* UNTUK KLASIFIKASI NILAI KERAPATAN
DAN TRANSPARANSI TAJUK DALAM METODE *FOREST HEALTH*
MONITORING (FHM) PADA TAJUK POHON JENIS DAUN LEBAR**

(Skripsi)

Oleh

**FANIRIZKI SOFIYANA
1917051050**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

**KINERJA *MOBILENET* UNTUK KLASIFIKASI NILAI KERAPATAN
DAN TRANSPARANSI TAJUK DALAM METODE *FOREST HEALTH
MONITORING* (FHM) PADA TAJUK POHON JENIS DAUN LEBAR**

Oleh

FANIRIZKI SOFIYANA

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA KOMPUTER**

Pada

**Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

ABSTRAK

KINERJA *MOBILENET* UNTUK KLASIFIKASI NILAI KERAPATAN DAN TRANSPARANSI TAJUK DALAM METODE *FOREST HEALTH MONITORING* (FHM) PADA TAJUK POHON JENIS DAUN LEBAR

Oleh

Fanirizki Sofiyana

Kesehatan hutan merupakan keadaan hutan yang mampu menjalankan keseluruhan fungsinya. Pemantauan kesehatan hutan dengan *Forest Health Monitoring* (FHM) menilai beberapa parameter salah satunya kerapatan dan transparansi tajuk. Pengukuran kerapatan dan transparansi tajuk saat ini menggunakan kartu *magic card*. Penggunaan *deep learning* untuk mengklasifikasikan nilai kerapatan dan transparansi tajuk pohon memiliki potensi untuk mempermudah dan meningkatkan efektivitas kerja. Penelitian ini bertujuan untuk mengukur kinerja MobileNet dalam mengklasifikasi nilai kerapatan dan transparansi tajuk pohon jenis daun lebar dalam metode *Forest Health Monitoring* (FHM). *Dataset* yang terdiri dari 2.965 gambar dari empat jenis pohon daun lebar (pohon cokelat, pohon durian, pohon karet, dan pohon kemiri) dikumpulkan dan dibagi menjadi 10 kelas. Kelas tersebut diperoleh dari kartu nilai kerapatan dan transparansi tajuk (*magic card*). Metode yang digunakan pada penelitian ini, yaitu arsitektur MobileNet dengan *tuning hyperparameter* seperti *epoch* dengan fungsi *callback early stopping*, *batch size*, *learning rate*, dan *optimizer*. Hasil akurasi pada proses pengujian model klasifikasi nilai kerapatan dan transparansi tajuk pohon cokelat sebesar 61,36%; pohon durian sebesar 90,96%; pohon karet sebesar 65,87%; dan pada pohon kemiri sebesar 80,95%. Model *MobileNet* klasifikasi nilai kerapatan dan transparansi tajuk pohon jenis daun lebar mengalami *overfitting*. *Overfitting* ditunjukkan dengan perbedaan yang signifikan antara hasil akurasi pada proses pelatihan dan pengujian. Hasil kinerja model yang mengalami *overfitting* tersebut menunjukkan bahwa model *MobileNet* tidak dapat diimplementasikan secara langsung untuk mengklasifikasi nilai kerapatan dan transparansi tajuk pohon dalam metode *Forest Health Monitoring* (FHM) untuk pohon jenis daun lebar.

Kata kunci: *deep learning*, *forest health monitoring*, nilai kerapatan dan transparansi tajuk, *mobilenet*

ABSTRACT

MOBILENET PERFORMANCE FOR CLASSIFICATION OF CROWN DENSITY AND FOLIAGE TRANSPARENCY SCALE IN THE FOREST HEALTH MONITORING (FHM) ON BROADLEAF TREES

by

Fanirizki Sofiyana

Forest health is a condition of the forest that can carry out all its functions. Forest Health Monitoring (FHM) assesses several parameters, one of which is crown density (CD) and foliage transparency (FT). Measurement of crown density and foliage transparency currently uses magic cards. The use of deep learning to classify tree CD and FT values has the potential to simplify and increase work effectiveness. This research aims to measure the performance of MobileNet in classifying the CD and FT values of broadleaf trees using the FHM method. Dataset consisting of 2,965 images from four types of broadleaf trees (*Theobroma cacao*, *Durio zibethinus*, *Hevea brasiliensis*, and *Aleurites moluccana*) was collected and divided into 10 classes. This class is obtained from the magic cards of CD-FT. The method used in this research is the MobileNet architecture with hyperparameter tuning such as epoch with early stopping callback function, batch size, learning rate, and optimizer. The accuracy results in the testing process for classification model of crown density and foliage transparency value of *Theobroma cacao* by 61.36%; *Durio zibethinus* by 90.96%; *Hevea brasiliensis* by 65.87%; and *Aleurites moluccana* by 80.95%. The MobileNet model for classifying broad leaf trees' CD and FT values experiences overfitting. Overfitting is indicated by a significant difference between accuracy results in the training and testing processes. The performance results of the overfitting model indicate that the MobileNet model cannot be implemented directly to classify crown density and foliage transparency values in the FHM method for broadleaf trees.

Keyword: deep learning, forest health monitoring, crown density and foliage transparency, mobilenet

Judul Skripsi : **KINERJA *MOBILENET* UNTUK
KLASIFIKASI NILAI KERAPATAN DAN
TRANSPARANSI TAJUK DALAM METODE
FOREST HEALTH MONITORING (FHM)
PADA TAJUK POHON JENIS DAUN LEBAR**

Nama Mahasiswa : **Fanirizki Sofiyanna**


Nomor Pokok Mahasiswa : 1917051050

Program Studi : Ilmu Komputer


Fakultas : Matematika dan Ilmu Pengetahuan Alam

MENYETUJUI

1. Komisi Pembimbing




Rico Andrian S.Si., M.Kom
NIP. 19750627 200501 1 001



Dr. Rahmat Safe'i S.Hut., M.Si
NIP. 19760123 200604 1 001

2. Ketua Jurusan Ilmu Komputer




Dwi Sakethi, S.Si., M.Kom
NIP. 19680611 199802 1 001


MENGESAHKAN

1. Tim Penguji


Ketua : Rico Andrian, S.Si., M.Kom



Sekretaris : Dr. Rahmat Safe'i, S.Hut., M.Si



Anggota : Favorisen R. Lumbanraja, S.Kom.,
M.Si., Ph.D



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi: 8 Mei 2024

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Fanirizki Sofiyana

NPM : 1917051050

Menyatakan bahwa skripsi yang saya susun dengan judul “Kinerja *Mobilenet* untuk Klasifikasi Nilai Kerapatan dan Transparansi Tajuk dalam Metode *Forest Health Monitoring* (FHM) pada Tajuk Pohon jenis daun Lebar” merupakan hasil karya saya sendiri dan tidak ada bagian yang diambil dari karya orang lain tanpa mencantumkan sumbernya dengan benar sesuai dengan ketentuan yang berlaku. Saya juga menyatakan bahwa skripsi ini telah dibuat dengan mengikuti standar penulisan ilmiah Universitas Lampung yang tertuang dalam “Panduan Penulisan Karya Ilmiah Universitas Lampung 2020 edisi revisi ke-5”. Saya menyadari sepenuhnya bahwa jika di kemudian hari terbukti bahwa skripsi ini merupakan hasil karya orang lain, maka saya bersedia menerima sanksi akademik yang berlaku.

Bandar Lampung, 2 Juli 2024



Fanirizki Sofiyana
NPM. 1917051050

RIWAYAT HIDUP



Penulis lahir di Bandar Lampung pada Agustus 2000. Penulis adalah anak pertama dari empat bersaudara. Pendidikan dasar ditempuh di SDN 3 Campang Raya (2006-2012), kemudian melanjutkan ke MTsN 2 Bandar Lampung (2012-2015) dan MAN 1 Bandar Lampung (2015-2018). Saat ini, Penulis melanjutkan pendidikan tinggi di Jurusan Ilmu Komputer, Fakultas MIPA Universitas Lampung, angkatan 2019 melalui jalur SBMPTN.

Selama masa perkuliahan, penulis aktif mengikuti berbagai kegiatan di kampus, seperti:

1. Asisten Dosen Logika Ilmu Komputer semester ganjil periode 2020/2021
2. Asisten Dosen Matematika Diskrit Ilmu Komputer semester genap periode 2020/2021
3. Anggota Divisi Desain Youth for Nation pada periode Agustus 2020-2021
4. Moderator dalam Seminar Nasional Bersama FMIPA Tahun 2021 pada September 2021

5. Asisten Dosen Analisis dan Desain Sistem Informasi (ADSI) Pendidikan Teknologi Informasi (PTI) FKIP Unila semester ganjil periode 2021/2022
6. Asisten Dosen Analisis dan Desain Sistem Informasi (ADSI) Ilmu Komputer semester genap periode 2021/2022
7. Kredensial Mikro Mahasiswa Indonesia (KMMI) Kampus Merdeka Kelas Acceleration Bootcamp di Sekolah Bisnis Manajemen Institut Teknologi Bandung (SBM ITB) pada September-Oktober 2021
8. Kuliah Kerja Nyata (KKN) di Desa Way Tataan, Kecamatan Teluk Betung Timur, Bandar Lampung pada tahun 2022 periode I.
9. Kerja Praktik di PT Swadharma Duta Data (Jakarta Timur) divisi *System Analyst* pada Juni-Agustus 2022
10. Studi Independen Bersertifikat (SIB) Kampus Merdeka *Product, Data, Sales, & Marketing* di RevoU Tech Academy pada Agustus-Desember 2022.

MOTTO

“Setiap aksi punya reaksi. Setiap tindakan punya konsekuensi.”

PERSEMBAHAN

Alhamdulillahirabbilamin

Puji syukur kepada Allah SWT atas limpahan rahmat, taufik, dan hidayah-Nya, penulis dikaruniai kekuatan dan keteguhan dalam menyelesaikan skripsi ini.

Selawat teriring salam senantiasa tercurah kepada Nabi Muhammad saw. Beliau adalah teladan utama dalam menuntut ilmu dan menyebarkan kebaikan. Semoga penulis dapat meneladani semangat dan keteladanan beliau dalam mengamalkan ilmu yang diperoleh.

Kepada kedua orang tuaku, terima kasih atas cinta, kasih sayang, doa, bimbingan, dan pengorbanan yang telah diberikan. Skripsi ini penulis persembahkan sebagai wujud rasa bakti anak dan terima kasih yang tak terhingga.

Kepada adik-adikku, terima kasih atas dukungan dan semangat yang selalu kalian berikan. Semoga kalian dapat terus belajar dan meraih cita-cita dengan gemilang.

Kepada teman-teman, terima kasih atas cerita yang telah mewarnai masa perkuliahan.

Dan untuk diriku sendiri, terima kasih atas kegigihan, ketekunan, dan semangat pantang menyerah dalam menyelesaikan skripsi ini. Semoga ini menjadi awal dari perjalanan yang lebih gemilang di masa depan.

Almamater tercinta,

UNIVERSITAS LAMPUNG

SANWACANA

Puji syukur kepada Allah SWT yang telah memberikan rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi dengan judul “Kinerja *MobileNet* untuk Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Dalam Metode *Forest Health Monitoring* (FHM) pada Tajuk Pohon jenis daun Lebar”. Skripsi ini merupakan salah satu syarat dalam menyelesaikan proses perkuliahan dan mendapatkan gelar Sarjana Komputer di Jurusan Ilmu Komputer FMIPA Universitas Lampung.

Selama proses penyusunan skripsi ini tidak terlepas dari dukungan dari banyak pihak, sehingga pada kesempatan ini penulis ingin mengucapkan rasa terima kasih kepada:

1. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan FMIPA Universitas Lampung.
2. Bapak Dwi Sakethi, M.Kom. selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
3. Ibu Anie Rose Irawati, S.T., M.Cs. selaku sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
4. Ibu Yohana Tri Utami, M.Kom. selaku pembimbing akademik yang telah membimbing selama perkuliahan di Jurusan Ilmu Komputer.
5. Bapak Rico Andrian, S.Si., M.Kom. selaku pembimbing utama yang telah membimbing saya dengan memberikan arahan, motivasi, kritik, dan saran dalam menyelesaikan skripsi ini dengan baik.
6. Bapak Dr. Rahmat Safe'i, S.Hut., M.Si. selaku pembimbing pembantu yang telah memberikan arahan dan saran kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik.

7. Bapak Favorisen R. Lumbanraja, Ph.D. selaku pembahas yang telah memberikan kritik dan saran yang sangat membantu dalam perbaikan skripsi ini.
8. Kedua orang tua serta ketiga saudara kandung saya yang senantiasa memberikan doa, kepercayaan, dan dukungan baik moral maupun materiel kepada penulis sehingga dapat menyelesaikan perkuliahan sampai dengan skripsi dengan baik.
9. Ibu Ade Nora Maela, Bang Zainuddin, Mas Nofal, dan Mas Sam yang telah membantu segala urusan administrasi dan izin penulis di Jurusan Ilmu Komputer.
10. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan ilmu bermanfaat dan pengalaman hidup untuk menjadi lebih baik.
11. Ibu Eny, Pak Agus, Ibu Laviyanti, dan Kak Listiana Putri yang senantiasa membantu penulis baik dalam administrasi maupun mendampingi dalam proses pengambilan data di Tahura WAR, Sumber Agung, Kemiling, Bandar Lampung.
12. Teman-teman saya sejak awal perkuliahan Nur Ayu Octarina, Okta Toyibah, dan Aghita Namira Yuliza yang senantiasa memberikan semangat, dukungan, dan doa.
13. Teman-teman satu bimbingan skripsi Flaurensia dan Diah yang selalu membantu dan mendoakan dalam penyelesaian skripsi.
14. Kim Sunoo, Park Sunghoon, Kwon Hoshi, Jeon Wonwoo, dan SEVENTEEN yang senantiasa memberikan motivasi dan hiburan sehingga membantu penulis dalam menjaga kesehatan mental selama proses penyusunan skripsi.
15. Hanse dan Naira yang senantiasa mendengarkan keluh kesah penulis serta memberikan dukungan dan doa.
16. Semua pihak yang telah berpartisipasi baik secara langsung maupun tidak langsung dalam membantu penyusunan skripsi ini.

Penulis berharap skripsi ini dapat menambah pengetahuan bagi pembaca tentang kesehatan hutan terutama kondisi tajuk dan digitalisasinya menggunakan metode

Convolutional Neural Network (CNN). Penulis menyadari bahwa dalam penulisan skripsi ini masih terdapat banyak kekurangan karena keterbatasan kemampuan, pengalaman, dan pengetahuan penulis. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan sebagai bahan evaluasi. Semoga skripsi ini dapat bermanfaat bagi semua pihak.

Bandar Lampung, 8 Mei 2024

Fanirizki Sofiyana
NPM. 1917051050

DAFTAR ISI

	Halaman
DAFTAR ISI.....	v
DAFTAR TABEL	ix
DAFTAR GAMBAR.....	xi
DAFTAR KODE PROGRAM	xiii
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah.....	5
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	6
II. TINJAUAN PUSTAKA	7
2.1 Penelitian Terdahulu	7
2.1.1 Kesehatan Hutan di Blok Koleksi Tumbuhan dan/atau Satwa Tahura Wan Abdul Rachman Provinsi Lampung (Pertiwi <i>et al.</i> , 2020)	8
2.1.2 <i>Explainable Deep Learning Model for Automatic Mulberry Leaf Disease Classification</i> (Nahiduzzaman <i>et al.</i> , 2023)	8
2.1.3 Implementasi Metode CNN <i>Computer Vision</i> Dalam Identifikasi Tipe Kerusakan Pohon Berbasis FHM (Nopriyanto <i>et al.</i> , 2022).....	9
2.2 Hutan	9
2.2.1 Taman Hutan Raya Wan Abdul Rachman	10
2.2.2 Tajuk	10

2.3	Daun Lebar.....	11
2.3.1	Pohon Cokelat (<i>Theobroma cacao</i>).....	11
2.3.2	Pohon Durian (<i>Durio zibethinus</i>).....	12
2.3.3	Pohon Karet (<i>Hevea brasiliensis</i>).....	13
2.3.4	Pohon Kemiri (<i>Aleurites moluccana</i>).....	14
2.4	Kesehatan Hutan	15
2.4.1	Forest Health Monitoring (FHM).....	16
2.5	CNN	18
2.5.1	Input Layer	19
2.5.2	Convolutional Layer.....	20
2.5.3	Pooling Layer	21
2.5.4	Fungsi Aktivasi (nonlinieritas).....	21
2.5.5	Fully Connected Layer	22
2.5.6	Loss Functions	22
2.6	<i>MobileNet</i>	22
2.7	<i>Preprocessing Data</i>	25
2.8	<i>Hyperparameter</i>	25
2.8.1	<i>Learning rate</i>	26
2.8.2	<i>Batch size</i>	26
2.8.3	<i>Optimizer</i>	27
2.8.4	<i>Epoch</i>	27
2.9	<i>Confusion Matrix</i>	27
2.9.1	Accuracy	28
2.9.2	Precision.....	28
2.9.3	Recall.....	29
2.9.4	F1-score.....	29

III. METODOLOGI PENELITIAN.....	30
3.1 Waktu dan Tempat	30
3.2 Bahan dan Alat	30
3.2.1 Bahan Penelitian.....	31
3.2.2 Alat Penelitian	31
3.3 Metode.....	33
3.3.1 Pengumpulan <i>Dataset</i>	33
3.3.2 Pelabelan Data.....	34
3.3.3 <i>Preprocessing</i> Data	34
3.3.4 Pembagian <i>Dataset</i>	34
3.3.5 Model <i>MobileNet</i>	35
3.3.6 Pengujian Model	35
3.3.7 Evaluasi Model.....	36
IV. HASIL DAN PEMBAHASAN.....	37
4.1 Pengumpulan <i>Dataset</i>	37
4.2 Pelabelan <i>Dataset</i>	40
4.3 <i>Preprocessing</i> Data.....	44
4.4 Pembagian <i>Dataset</i>	45
4.5 Model <i>MobileNet</i>	46
4.5.1 Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Cokelat.....	50
4.5.2 Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Durian	53
4.5.3 Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Karet	57
4.5.4 Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Kemiri.....	60

4.6	Pengujian Model <i>MobileNet</i>	63
4.6.1	Pengujian dan Evaluasi Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Cokelat	63
4.6.2	Pengujian dan Evaluasi Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Durian	68
4.6.3	Pengujian dan Evaluasi Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Karet	71
4.6.4	Pengujian dan Evaluasi Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Kemiri	75
4.7	Evaluasi Model <i>MobileNet</i>	79
V.	SIMPULAN DAN SARAN	82
5.1	Simpulan	82
5.2	Saran.....	82
	DAFTAR PUSTAKA.....	84

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu yang Terkait	7
2. Rincian Lapisan pada Arsitektur <i>MobileNet</i>	25
3. Metrik Utama Standar <i>Confusion Matrix</i> (Chicco dan Jurman, 2020)	28
4. Waktu Penelitian	30
5. Jumlah Citra Kerapatan dan Transparansi Tajuk Pohon jenis daun Lebar Sebagai Bahan Penelitian	31
6. <i>Library</i> yang Digunakan pada Model <i>MobileNet</i>	32
7. Pengaturan Kamera Pengambilan Citra Kerapatan dan Transparansi Tajuk ..	37
8. Hasil Pengumpulan <i>Dataset</i> Tajuk Pohon jenis daun Lebar	39
9. Jumlah Citra Kerapatan dan Transparansi Tajuk Tiap Jenis Pohon jenis daun Lebar pada Kelas Kerapatan dan Transparansi Tajuk	43
10. Jumlah Data Tajuk Pohon jenis daun Lebar pada Masing-Masing Jenis Pohon	45
11. <i>Hyperparameter</i> pada Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Cokelat	50
12. Hasil Pelatihan Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Cokelat	53
13. <i>Hyperparameter</i> pada Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Durian	53
14. Hasil Pelatihan Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Durian	56
15. <i>Hyperparameter</i> pada Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Karet	57

16. Hasil Pelatihan Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Karet	60
17. <i>Hyperparameter</i> pada Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Kemiri	60
18. Hasil Pelatihan Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Kemiri.....	63
19. <i>Precision, Recall, dan F1-Score</i> Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Cokelat	66
20. <i>Precision, recall, f1-score</i> Model <i>MobileNet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Durian	70
21. <i>Precision, Recall, F1-Score</i> Model <i>Mobilenet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Karet.....	74
22. <i>Precision, Recall, F1-Score</i> Model <i>Mobilenet</i> Klasifikasi Nilai Kerapatan dan Transparansi Tajuk Pohon Kemiri	78

DAFTAR GAMBAR

Gambar	Halaman
1. Pohon cokelat (<i>Theobroma cacao</i>).	11
2. Pohon durian (<i>Durio zibethinus</i>).	12
3. Pohon karet (<i>Hevea brasiliensis</i>).	13
4. Pohon kemiri (<i>Aleurites moluccana</i>).	14
5. Kartu <i>magic card</i> kerapatan tajuk (Mangold, 1997).	17
6. Kartu <i>magic card</i> transparansi tajuk (Mangold, 1997).	18
7. Lapisan arsitektur CNN untuk klasifikasi citra (Alzubaidi dkk., 2021).	19
8. Perhitungan pada langkah <i>convolutional layer</i> (Alzubaidi dkk., 2021).	20
9. Contoh tiga jenis <i>pooling</i> (Alzubaidi dkk., 2021).	21
10. Filter konvolusi standar seperti gambar (a) diganti dengan <i>depthwise convolution</i> (b) dan <i>pointwise convolution</i> (c) untuk membuat <i>depthwise separable convolution</i> (Howard dkk., 2017).	23
11. Perbandingan konvolusi standar dan <i>depthwise separable convolution</i> (Howard dkk., 2017).	23
12. Arsitektur <i>MobileNet</i> (W. Wang dkk., 2020).	24
13. Metode penelitian.	33
14. Lokasi pengumpulan <i>dataset</i>	38
15. Citra tajuk pohon jenis daun lebar pada kelas nilai kerapatan 75% dan transparansi 25% (CD75FT25).	40
16. <i>Flowchart</i> pelabelan data.	42
17. Citra tajuk pohon karet IMG_9383.	43
18. <i>RGB</i> citra tajuk pohon jenis daun lebar.	48
19. Proses klasifikasi tajuk pohon jenis daun lebar.	49
20. Lapisan <i>fully connected</i>	49

21. Struktur model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon cokelat.	51
22. Grafik <i>accuracy</i> dan <i>loss</i> model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon cokelat.	52
23. Struktur model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon durian.	55
24. Grafik <i>accuracy</i> dan <i>loss</i> model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon durian.	56
25. Struktur model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon karet.	58
26. Grafik <i>accuracy</i> dan <i>loss</i> model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon karet.	59
27. Struktur model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon kemiri.	62
28. Grafik <i>accuracy</i> dan <i>loss</i> model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon kemiri.	62
29. <i>Confusion Matrix</i> model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon cokelat.	64
30. <i>Confusion Matrix</i> model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon durian.	68
31. <i>Confusion Matrix</i> model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon karet.	72
32. <i>Confusion Matrix</i> model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon kemiri.	76
33. Hasil kinerja model <i>MobileNet</i> pada <i>dataset</i> empat jenis pohon jenis daun lebar.	79

DAFTAR KODE PROGRAM

Kode Program	Halaman
1. <i>Resize</i> citra.	44
2. Pembagian data.	45
3. Model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon coklat.	51
4. Model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon durian.....	54
5. Model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon karet.	58
6. Model <i>MobileNet</i> klasifikasi nilai kerapatan dan transparansi tajuk pohon kemiri.	61

I. PENDAHULUAN

1.1 Latar Belakang

Hutan sebagai salah satu penentu sistem penyangga kehidupan telah memberikan banyak manfaat untuk manusia. Hutan juga memiliki peranan dalam keseimbangan dan keselarasan lingkungan dunia sehingga harus dijaga kelestariannya. Hutan merupakan sumber daya alam yang berharga karena sangat berpengaruh dan memberikan manfaat pada ekologis, iklim, serta sosial ekonomi. Hutan menciptakan keseimbangan dari banyaknya emisi karbon yang dihasilkan perindustrian. Indonesia merupakan salah satu negara yang dianugerahi sumber daya hutan yang melimpah. Indonesia menempati urutan ketiga hutan hujan tropis terbesar di dunia dengan luas 120,35 juta hektar menyebutkan bahwa hutan dikategorikan menjadi beberapa jenis di antaranya Taman Nasional, Suaka Margasatwa, Cagar Alam, Taman Hutan Raya, dan lain-lain. Taman Hutan Raya (Tahura) adalah Kawasan Pelestarian Alam yang dilindungi untuk memelihara dan mempelajari berbagai jenis tumbuhan dan hewan yang tidak membahayakan lingkungan. Koleksi ini dimanfaatkan untuk penelitian, pendidikan, pengembangan budidaya, pelestarian budaya, pariwisata, dan rekreasi. Tahura Wan Abdul Rachman (WAR) merupakan salah satu Tahura yang berada di Provinsi Lampung. Tahura WAR ditetapkan berdasarkan Surat Keputusan Menteri Kehutanan No. 742/KPTS – VI/2992 pada 21 Juli 1992 (Djoko dkk., 2019). Pengelolaan Tahura WAR dibagi menjadi lima blok pengelolaan sesuai dengan aturan dari Dinas Kehutanan Provinsi Lampung. Blok pengelolaan tersebut salah satunya adalah blok tradisional. Blok tradisional Tahura WAR memungkinkan masyarakat yang telah mengelola kawasan hutan untuk usaha pemanfaatan seperti usaha jasa lingkungan

dan usaha hasil hutan selain kayu (Herwanti dkk., 2022). Blok tradisional tersebar di berbagai lokasi di Provinsi Lampung, salah satunya berada di Sumber Agung, Kemiling, Bandar Lampung.

Tahura WAR dengan luas 22.249,31 hektar memiliki keanekaragaman jenis baik tumbuhan maupun satwanya. Keragaman jenis tumbuhan salah satunya adalah pada bentuk kayu dan daunnya. Tumbuhan berkayu dibedakan menjadi dua sub divisi, yaitu *Angiospermae* dan *Gymnospermae*. *Gymnospermae* atau tumbuhan berbiji terbuka umumnya memiliki jenis kayu daun jarum. *Angiospermae* atau tumbuhan berbiji tertutup terbagi lagi menjadi monokotil dan dikotil. Monokotil merupakan tumbuhan berbiji satu, sedangkan dikotil merupakan tumbuhan berbiji dua. Tumbuhan dikotil memiliki jenis kayu daun lebar (Yunianti dkk., 2020).

Peranan dan manfaat hutan dengan keanekaragamannya yang besar menyebabkan kondisi kesehatan ekosistem hutan menjadi perhatian yang amat penting bagi seluruh dunia. Kesehatan hutan merupakan keadaan hutan yang mampu menjalankan keseluruhan fungsinya, baik fungsi perlindungan bagi air dan tanah, konservasi, maupun produksi. Fungsi-fungsi tersebut dapat berjalan dengan baik walaupun mengalami gangguan dari faktor biotik dan abiotik di sekitarnya. Indikator ekologis utama kesehatan hutan hujan di Indonesia ada empat, salah satunya yaitu vitalitas yang terdiri atas kerusakan pohon dan kondisi tajuk. Tajuk merupakan bagian berdaun pada tumbuhan. Tajuk yang lebar dan lebat menunjukkan laju pertumbuhan yang tinggi. Tajuk kecil dan renggang menunjukkan kondisi yang tidak atau kurang mendukung pertumbuhan, misalnya terjadi kompetisi antar pohon, kelembaban yang terlalu rendah atau tinggi, atau pengaruh lainnya.

Data dan informasi kesehatan hutan dapat diperoleh melalui pemantauan kesehatan hutan secara berkala. Pemantauan kesehatan hutan atau *Forest Health Monitoring* (FHM) merupakan metode untuk memantau, menilai, dan melaporkan mengenai status saat ini, perubahan, dan kecenderungan jangka panjang menggunakan indikator ekologis. Ada lima parameter untuk menilai kondisi tajuk di antaranya

kerapatan tajuk (*crown density*) dan transparansi tajuk (*foliage transparency*) tajuk (Safe'i dan Tsani, 2016). Pengukuran kerapatan dan transparansi tajuk saat ini menggunakan kartu *magic card* kerapatan dan transparansi. Penggunaan kartu *magic card* ini masih kurang efektif dalam mengukur kerapatan dan transparansi tajuk sebab mengandalkan penglihatan secara langsung kemudian dibandingkan dengan nilai pada kartu *magic card*. Pengamatan dan penilaian tersebut harus dilakukan oleh pakar/tenaga ahli kesehatan hutan. Klasifikasi nilai kerapatan dan transparansi tajuk dapat memanfaatkan teknologi pengolahan citra digital sehingga mempermudah dan meningkatkan efektivitas kerja sebab dapat dilakukan oleh siapa saja. *Deep learning* sebagai salah satu teknologi pengolahan citra dapat dimanfaatkan untuk pengklasifikasian nilai kerapatan dan transparansi tajuk ini.

Deep learning sebagai bagian dari *machine learning* terinspirasi dari pola pemrosesan informasi yang ditemukan di otak manusia. *Deep learning* menggunakan sejumlah besar data untuk memetakan *input* yang diberikan ke label tertentu. *Deep learning* memiliki kemampuan untuk mengotomatiskan pembelajaran kumpulan fitur untuk beberapa tugas (ekstraksi fitur dan pemilihan fitur), tidak seperti metode *machine learning* konvensional (Alzubaidi dkk., 2021). *Deep learning* dapat digunakan untuk menganalisis teks, gambar, audio, bahkan untuk mesin penerjemah. *Deep learning* mencakup berbagai metode, salah satunya adalah *Convolutional Neural Network* (CNN). CNN dibangun dari *Multilayer Perceptron* (MLP) yang berguna untuk mengolah data dua dimensi dan secara umumnya ada dua jenis lapisan dalam CNN, yakni lapisan ekstraksi fitur (*feature extraction layer*) dan lapisan klasifikasi (*classification layer*). CNN memiliki arsitektur yang beragam, di antaranya *MobileNet* yang dikembangkan oleh Howard dan tim pada tahun 2017. *MobileNet* merupakan arsitektur yang telah dilatih sebelumnya untuk klasifikasi citra menggunakan *database ImageNet*. *MobileNet* memiliki kedalaman 28 lapisan dengan mengusung konsep *depthwise separable convolution* untuk mengurangi jumlah parameter dan komputasi yang dibutuhkan, sehingga memungkinkan penggunaan yang efisien pada perangkat dengan daya komputasi terbatas (Howard dkk., 2017). *MobileNet* dapat diterapkan untuk aplikasi pengenalan citra di perangkat *mobile* dan *Internet of Things* (IoT).

Penelitian sebelumnya terkait kondisi kesehatan hutan adalah penelitian yang dilakukan untuk mengetahui nilai status kondisi kesehatan hutan menggunakan metode *Forest Health Monitoring* (FHM) di blok koleksi tumbuhan dan/atau satwa Tahura WAR. Penelitian dilakukan dengan membagi wilayah menjadi delapan klaster plot. Berdasarkan penelitian yang dilakukan, diperoleh nilai indeks kerusakan tertinggi adalah 3,32 pada klaster plot satu, dan terendah bernilai 0.04 pada klaster plot delapan. Kondisi tajuk dengan nilai tertinggi berada pada klaster plot delapan sebesar 3,91 dan terendah pada klaster plot dua sebesar 3,10. Kondisi kesehatan hutan di blok koleksi tumbuhan dan/atau satwa sebanyak 25% luas wilayah berkategori sangat baik, 38% berkategori baik, 12% berkategori sedang, dan 25% berkategori sangat buruk (Pertiwi dkk., 2020).

Penelitian terkait penggunaan arsitektur *MobileNet* yaitu penelitian yang dilakukan oleh (Nahiduzzaman dkk., 2023) untuk mengklasifikasi penyakit pada daun murbei sebagai makanan pokok ulat *Bombyx mori* penghasil sutera. *Dataset* yang digunakan pada penelitian ini adalah citra daun murbei. Total *dataset* yang digunakan berjumlah 1.091 citra yang terdiri atas 440 daun sehat, 489 daun dengan penyakit karat daun, dan 162 daun dengan bercak daun. Eksperimen yang dilakukan dengan menggunakan beberapa arsitektur CNN, salah satunya *MobileNet*. Skema pertama, *dataset* diklasifikasikan menjadi tiga kelas, yaitu daun sehat, daun dengan karat daun, dan daun dengan bercak daun. Skema ini memperoleh akurasi 93,03%; *precision* 91,40%; *recall* 89,60%; serta *f1-score* 90,20%. Skema kedua, *dataset* diklasifikasi menjadi dua kelas, yaitu daun sehat dan daun tidak sehat. Skema kedua ini memperoleh akurasi 92,75%; *precision* 93,8%; *recall* 92,00%; serta *f1-score* 92,60%.

Penelitian terkait pemanfaatan *deep learning* terkait kesehatan hutan juga pernah dilakukan (Nopriyanto dkk., 2022) untuk mengklasifikasi tipe kerusakan pohon sebagai salah satu indikator dalam mengevaluasi ekosistem hutan pada metode FHM. Penelitian ini menggunakan 1600 citra kerusakan pohon yang diklasifikasikan ke dalam 16 kelas. Arsitektur CNN yang digunakan pada penelitian

ini ada dua jenis, yaitu *LeNet* dan *MobileNet*. Model dengan arsitektur *LeNet* mencapai akurasi 88,99%, sedangkan model dengan arsitektur *MobileNet* mencapai akurasi 99,06% .

Penelitian yang akan dilakukan ini untuk mengukur nilai kerapatan dan transparansi tajuk pohon berdasarkan metode *Forest Health Monitoring* (FHM). Penelitian ini akan menggunakan *dataset* tajuk empat jenis pohon kayu daun lebar yang dibagi dalam 10 kelas sesuai dengan klasifikasi pada kartu *magic card* dari rentang 5-95%. *MobileNet* akan digunakan untuk membangun model yang akan dilatih dan diuji menggunakan citra tajuk pohon kayu daun lebar yang dimiliki.

1.2 Rumusan Masalah

Rumusan masalah pada penelitian ini berdasarkan latar belakang yang telah dipaparkan ialah sebagai berikut.

1. Apakah *MobileNet* dapat diimplementasikan untuk mengklasifikasi nilai kerapatan dan transparansi tajuk pohon dalam metode *Forest Health Monitoring* (FHM) untuk jenis daun lebar?
2. Berapa hasil evaluasi kinerja *MobileNet* yang didapatkan dalam mengklasifikasi nilai kerapatan dan transparansi tajuk daun lebar?
3. Apakah faktor yang mempengaruhi kinerja *MobileNet* yang didapatkan dalam mengklasifikasi nilai kerapatan dan transparansi tajuk daun lebar?

1.3 Batasan Masalah

Batasan masalah pada penelitian ini di antaranya sebagai berikut.

1. Menggunakan *dataset* pohon dengan jenis daun lebar di blok tradisional Taman Hutan Raya Wan Abdul Rachman (Tahura WAR) Sumber Agung, Kemiling, Bandar Lampung.
2. Menggunakan 2.965 citra dari empat jenis pohon jenis daun lebar, yaitu pohon cokelat, durian, karet, dan kemiri. *Dataset* kemudian dibagi ke dalam 10 kelas

sesuai dengan kartu *magic card* pengukuran kerapatan dan transparansi tajuk pohon.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk mengukur kinerja *MobileNet* dalam mengklasifikasi nilai kerapatan dan transparansi tajuk tajuk pohon jenis daun lebar pada metode *Forest Health Monitoring* (FHM).

1.5 Manfaat Penelitian

Manfaat penelitian ini adalah untuk mendeteksi salah satu parameter *Forest Health Monitoring* (FHM) yaitu nilai kerapatan dan transparansi tajuk jenis daun lebar yang berpengaruh pada kesehatan hutan di blok tradisional Tahura WAR Sumber Agung, Kemiling, Bandar Lampung. Penelitian ini juga diharapkan dapat menjadi acuan dalam mengembangkan penelitian selanjutnya mengenai penerapan *deep learning* dalam mengklasifikasi nilai kerapatan dan transparansi tajuk tajuk pohon jenis daun lebar.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian yang dilakukan berlandaskan pada penelitian-penelitian terdahulu, sehingga memiliki kesamaan dan perbedaan objek penelitian. Tabel 1 menyajikan ringkasan dari penelitian terdahulu yang relevan dengan penelitian ini.

Tabel 1. Penelitian Terdahulu yang Terkait

No.	Penelitian	Metode	Hasil
1	Kesehatan Hutan di Blok Koleksi Tumbuhan dan/atau Satwa Tahura Wan Abdul Rachman Provinsi Lampung (Pertiwi dkk., 2020)	<i>Forest Health Monitoring</i> (FHM)	Kondisi kesehatan hutan di blok koleksi tumbuhan dan/atau satwa: Sangat baik: 25% Baik: 38% Sedang: 12% Sangat buruk: 25%
2	<i>Explainable Deep Learning Model for Automatic Mulberry Leaf Disease Classification</i> (Nahiduzzaman dkk., 2023)	PDS-CNN, <i>DenseNet121</i> , <i>MobileNet</i> , <i>MobileNet2</i> , <i>Xception</i> , VGG19, dan <i>ResNet152</i>	Akurasi klasifikasi 3 kelas metode: PDS-CNN: 95.05% <i>DenseNet121</i> : 93.12% <i>MobileNet</i> : 93.03% <i>MobileNet2</i> : 91.38% <i>Xception</i> : 89.54% VGG19: 87.89% <i>ResNet152</i> : 67.25% Akurasi klasifikasi 2 kelas metode: PDS-CNN: 96,06% <i>DenseNet121</i> : 94,20% <i>MobileNet</i> : 92,75% <i>MobileNet2</i> : 92,66% <i>Xception</i> : 88.90% VGG19: 87.89% <i>ResNet152</i> : 71.84%
3	Implementasi Metode CNN <i>Computer Vision</i> Dalam Identifikasi Tipe Kerusakan Pohon Berbasis FHM (Nopriyanto dkk., 2022)	<i>LeNet</i> dan <i>MobileNet</i>	<i>LeNet</i> : 89.99% <i>MobileNet</i> : 99.06%

Penelitian ini merujuk pada penelitian-penelitian sebelumnya, dengan penjelasan sebagai berikut.

2.1.1 Kesehatan Hutan di Blok Koleksi Tumbuhan dan/atau Satwa Tahura Wan Abdul Rachman Provinsi Lampung (Pertiwi *et al.*, 2020)

Penelitian ini dilakukan oleh Pertiwi dkk., (2020) untuk mengetahui nilai status kondisi kesehatan hutan menggunakan metode *Forest Health Monitoring* (FHM) di blok koleksi tumbuhan dan/atau satwa Tahura WAR. Penelitian dilakukan dengan membagi wilayah menjadi delapan klaster plot. Berdasarkan penelitian yang dilakukan, diperoleh nilai indeks kerusakan tertinggi adalah 3,32 pada klaster plot satu, dan terendah bernilai 0.04 pada klaster plot delapan. Kondisi tajuk dengan nilai tertinggi berada pada klaster plot delapan sebesar 3,91 dan terendah pada klaster plot dua sebesar 3,10. Kondisi kesehatan hutan di blok koleksi tumbuhan dan/atau satwa sebanyak 25% luas wilayah berkategori sangat baik, 38% berkategori baik, 12% berkategori sedang, dan 25% berkategori sangat buruk.

2.1.2 *Explainable Deep Learning Model for Automatic Mulberry Leaf Disease Classification* (Nahiduzzaman *et al.*, 2023)

Penelitian ini dilakukan oleh Nahiduzzaman dkk. (2023) untuk mengidentifikasi penyakit pada daun murbei sebagai makanan pokok ulat *Bombyx mori* penghasil sutera. *Dataset* yang digunakan pada penelitian ini adalah citra daun murbei. Total *dataset* yang digunakan berjumlah 1.091 citra yang terdiri atas 440 daun sehat, 489 daun dengan penyakit karat daun, dan 162 daun dengan bercak daun. Eksperimen yang dilakukan dengan menggunakan beberapa arsitektur CNN, yaitu: PDS-CNN, *DenseNet121*, *MobileNet*, *MobileNet2*, *Xception*, VGG19, DAN *ResNet152*. PDS-CNN adalah model unik yang dibangun sendiri oleh peneliti. PDS-CNN memperoleh hasil yang tertinggi, meskipun demikian, model *MobileNet* juga menunjukkan hasil yang tinggi dan memiliki parameter terkecil dibandingkan model dan arsitektur lain yang digunakan. Skema pertama, *dataset* diklasifikasikan

menjadi tiga kelas, yaitu daun sehat, daun dengan karat daun, dan daun dengan bercak daun. *MobileNet* pada skema ini memperoleh akurasi 93,03%; *precision* 91,40%; *recall* 89,60%; serta *f1-score* 90,20%. Skema kedua, *dataset* diklasifikasi menjadi dua kelas, yaitu daun sehat dan daun tidak sehat. *MobileNet* pada skema kedua ini memperoleh akurasi 92,75%; *precision* 93,8%; *recall* 92,00%; serta *f1-score* 92,60%.

2.1.3 Implementasi Metode CNN *Computer Vision* Dalam Identifikasi Tipe Kerusakan Pohon Berbasis FHM (Nopriyanto *et al.*, 2022)

Penelitian yang dilakukan oleh Nopriyanto dkk. (2022) ini merupakan pemanfaatan *deep learning* terkait kesehatan hutan. Penelitian ini dilakukan untuk mengidentifikasi tipe kerusakan pohon sebagai salah satu indikator dalam mengevaluasi ekosistem hutan pada metode FHM. Penelitian ini menggunakan 1.600 citra kerusakan pohon yang diklasifikasikan ke dalam 16 kelas. Arsitektur CNN yang digunakan pada penelitian ini ada dua jenis, yaitu *LeNet* dan *MobileNet*. Model dengan arsitektur *LeNet* mencapai akurasi 88,99%, sedangkan model dengan arsitektur *MobileNet* mencapai akurasi 99,06%.

2.2 Hutan

Hutan adalah kawasan pepohonan yang bersama-sama membentuk komunitas hidup dengan makhluk hidup lainnya beserta lingkungan yang ditetapkan oleh pemerintah sebagai hutan (Damanik dan Sahudra, 2021). Undang-Undang Nomor 41 Tahun 1999 Pasal 1 menyebutkan bahwa pengertian hutan adalah suatu kesatuan ekosistem berupa hamparan lahan berisi sumber daya alam hayati yang didominasi pepohonan dalam persekutuan alam lingkungannya, yang satu dengan lainnya tidak dapat dipisahkan. Kawasan hutan adalah wilayah tertentu yang ditunjuk dan atau ditetapkan oleh Pemerintah untuk dipertahankan keberadaannya sebagai hutan tetap.

2.2.1 Taman Hutan Raya Wan Abdul Rachman

Taman Hutan Raya (Tahura) adalah Kawasan Pelestarian Alam yang dilindungi untuk memelihara dan mempelajari berbagai jenis tumbuhan dan hewan yang tidak membahayakan lingkungan. Koleksi ini dimanfaatkan untuk penelitian, pendidikan, pengembangan budidaya, pelestarian budaya, pariwisata, dan rekreasi. Taman Hutan Rakyat Wan Abdul Rachman (Tahura WAR) adalah salah satu Tahura yang berlokasi di Provinsi Lampung. Tahura WAR ditetapkan berdasarkan Surat Keputusan Menteri Kehutanan No. 742/KPTS – VI/1992 pada 21 Juli 1992. Tahura WAR memiliki luas 22.249,31 hektar. Dinas Kehutanan Provinsi Lampung mengatur pengelolaan Tahura WAR menjadi beberapa blok sebagai upaya penyesuaian dengan daya dukung lingkungan (Djoko dkk., 2019). Salah satu blok pengelolaan tersebut adalah blok tradisional. Blok tradisional merupakan area yang terdiri dari berbagai jenis tumbuhan dan/atau satwa. Blok tradisional Tahura WAR memungkinkan masyarakat yang telah mengelola kawasan hutan untuk usaha pemanfaatan seperti usaha jasa lingkungan dan usaha hasil hutan selain kayu (Herwanti dkk., 2022).

2.2.2 Tajuk

Tajuk pohon adalah bagian dari pohon mulai dari tinggi batang tanpa cabang hingga ujung pohon, termasuk batang, daun, dan struktur reproduksi. Tajuk dapat digunakan sebagai salah satu indikator untuk menentukan kesehatan hutan. Tajuk juga dapat menggambarkan stratifikasi pohon pada suatu kawasan. Tajuk yang lebar dan lebat menunjukkan laju pertumbuhan yang tinggi. Tajuk kecil dan renggang menunjukkan kondisi yang tidak atau kurang mendukung pertumbuhan, misalnya terjadi kompetisi antar pohon, kelembaban yang terlalu rendah atau tinggi, atau pengaruh lainnya (Safe'i dan Tsani, 2016). Tajuk, terutama bagian yang terkena cahaya berperan penting dalam pertumbuhan pohon sebagai tempat fotosintesis terjadi. Tajuk yang lebar memperluas proses fotosintesis pohon

sehingga pertumbuhannya pun akan lebih cepat (Sadono, 2018). Tajuk juga dapat membantu memperkecil energi kinetik hujan yang turun ke tanah.


2.3 Daun Lebar

Tumbuhan berkayu dibedakan menjadi dua sub divisi, yaitu *Angiospermae* dan *Gymnospermae*. *Gymnospermae* adalah tumbuhan berbiji terbuka. *Gymnospermae* pada umumnya memiliki jenis kayu daun jarum. *Angiospermae* adalah tumbuhan berbiji tertutup. *Angiospermae* terbagi lagi menjadi monokotil dan dikotil. Monokotil merupakan tumbuhan berbiji satu, sedangkan dikotil merupakan tumbuhan berbiji dua. Tumbuhan dikotil memiliki jenis kayu daun lebar (Yunianti dkk., 2020). Kayu daun lebar (*hardwood*) memiliki beberapa tipe sel. Sel-sel kayu daun lebar (*hardwood*) bersifat multiserat. Pohon dengan jenis daun lebar umumnya memiliki tajuk yang lebar dan membundar serta batangnya berbentuk tidak lurus dan berbonggol (Panggabean, 2022). Contoh pohon yang termasuk dalam jenis pohon jenis daun lebar di antaranya adalah cokelat, durian, karet, dan kemiri.

2.3.1 Pohon Cokelat (*Theobroma cacao*)



(a) Pohon cokelat (Agrozine, 2021)



(b) Tajuk pohon cokelat
(sumber: foto pribadi, 2023)


Gambar 1. Pohon cokelat (*Theobroma cacao*).

Theobroma cacao termasuk dalam kerajaan *Plantae*, divisi *Magnoliophyta*, kelas *Magnoliopsida*, ordo *Malvales*, famili *Sterculiaceae*, genus *Theobroma*, dan spesies *Theobroma cacao* (USDA, 2024). *Theobroma cacao* tumbuh di hingga 50 negara yang memiliki iklim tropis lembab. Biji *Theobroma cacao* dibungkus dalam polong dan digunakan untuk produksi cokelat, kembang gula, dan kosmetik. Tanaman ini beradaptasi pada daerah dengan kelembapan tinggi, sehingga rentan terhadap berbagai penyakit jamur (Abdullah dkk., 2021). *Theobroma cacao* memiliki ketinggian rata-rata antara 4 hingga 8 meter, dan jarang tumbuh hingga 20 m. Pohon ini memiliki kulit kayu yang berwarna abu-abu tua. *Theobroma cacao* memiliki panjang daun yang berkisar antara 20 hingga 35 cm dan lebar 6 hingga 10 cm (Jean-Marie dkk., 2022). Bentuk tajuk *Theobroma cacao* bervariasi ada yang membentuk lingkaran utuh, melebar, dan simetris (*complete circle perfect*), ada yang kurang simetris dan terdapat cabang mati (*irregular circle good*), dan ada pula yang berbentuk lonjong (*tolerable half crown*) (Tiralla *et al.*, 2013). Contoh tajuk pohon cokelat ditunjukkan pada Gambar 1.

2.3.2 Pohon Durian (*Durio zibethinus*)



(a) Pohon durian (Agroni, 2021)



(b) Tajuk pohon durian
(sumber: foto pribadi, 2023)


Gambar 2. Pohon durian (*Durio zibethinus*).

Pohon durian (*Durio zibethinus*) termasuk dalam kerajaan *Plantae*, divisi *Magnoliophyta*, kelas *Magnoliopsida*, ordo *Malvales*, famili *Bombacaceae*, genus *Durio*, dan spesies *Durio zibethinus* (USDA, 2024). Durian merupakan buah yang dibudidayakan di daerah beriklim tropis. Varietas durian memiliki banyak jenis dengan tekstur, rasa, aroma, ukuran, bentuk, dan warna daging yang berbeda-beda. Durian adalah buah yang eksotik dan musiman di sebagian besar wilayah Asia Tenggara, khususnya di Malaysia, Indonesia, Thailand, dan Filipina. Pohon durian umumnya memiliki ketinggian 20-50 meter dengan batang berwarna cokelat. Durian memiliki daun dengan panjang dan lebar yang bervariasi. Panjang daun durian berkisar antara 6-12 cm dan lebar daunnya berkisar antara 2-4 cm (Yuniastuti *et al.*, 2018). Bentuk tajuk pohon durian bermacam-macam di antaranya: piramida, jorong, bulat, setengah membulat, lonjong dan tidak beraturan (Pratiwi *et al.*, 2018). Contoh tajuk pohon durian ditunjukkan pada Gambar 2.

2.3.3 Pohon Karet (*Hevea brasiliensis*)



(a) Pohon karet (Hatiqah, 2017)



(b) Tajuk pohon karet
(sumber: foto pribadi, 2023)

Gambar 3. Pohon karet (*Hevea brasiliensis*).

Pohon karet (*Hevea brasiliensis*) adalah bagian dari kingdom *Plantae*, divisi *Magnoliophyta*, kelas *Magnoliopsida*, ordo *Euphorbiales*, famili *Euphorbiaceae*, genus *Hevea*, dan spesies *Hevea brasiliensis* (USDA, 2024). Pohon karet berasal

dari hutan hujan Amerika Selatan dan menyebar di wilayah tropis dekat garis khatulistiwa. Pohon karet memiliki struktur kulit kayu yang terbentuk dari lapisan kulit keras, kulit lunak, kambium, dan *xylem*. Pohon karet umumnya mempunyai ketinggian rata-rata 25-30 meter, namun dalam beberapa kasus ketinggian pohon dapat melebihi 30 meter. *Havea brasiliensis* sebagian besar memiliki kanopi yang tinggi, tajuk berbentuk kerucut yang khas, batang berbentuk silinder, dan pangkal yang umumnya membesar. Ketebalan kulit kayu *Havea brasiliensis* bervariasi dan warna permukaan kulit antara cokelat muda hingga cokelat, dan dari ungu kemerahan hingga ungu tua. Pohon karet yang masih muda dan belum menghasilkan getah memiliki kulit kayu berwarna cokelat-hijau (Wei dan Razak, 2021). Pohon karet memiliki daun berukuran panjang berkisar antara 18-25 cm dan lebar antara 7-10cm (Pasaribu *et al.*, 2023). Pohon karet memiliki kanopi tinggi dan tajuk berbentuk kerucut yang khas, batang berbentuk silinder, dan pangkal yang biasanya menggembung (Wei and Razak, 2021b). Contoh tajuk pohon karet ditunjukkan pada Gambar 3.

2.3.4 Pohon Kemiri (*Aleurites moluccana*)



(a) Pohon kemiri
(Krisnawati *et al.*, 2011)



(b) Tajuk pohon kemiri
(sumber: foto pribadi, 2023)

Gambar 4. Pohon kemiri (*Aleurites moluccana*).

Aleurites moluccana termasuk dalam kerajaan *Plantae*, divisi *Magnoliophyta*, kelas *Magnoliopsida*, ordo *Euphorbiales*, famili *Euphorbiaceae*, genus *Aleurites*, dan spesies *Aleurites moluccana* (USDA, 2024). Pohon kemiri (*Aleurites moluccana*) merupakan salah satu pohon multiguna hampir setiap bagian tanaman ini dapat digunakan untuk memenuhi kebutuhan hidup manusia. Misalnya bijinya dapat digunakan sebagai media penerangan, memasak, dan obat-obatan, sedangkan batangnya dapat digunakan untuk kayu (Susilowati dkk., 2020). Kemiri memiliki ketinggian berkisar antara 10 hingga 40 meter dan diameter batang mencapai 110 cm. Kemiri memiliki warna kayu kering putih, putih keabuan atau putih yang agak kusam dengan tekstur sedikit kasar dan memiliki serat lurus. Daun kemiri berwarna hijau gelap dengan kilauan perak. Permukaan bawah daun kemiri terdapat rambut halus berwarna putih, sementara pada permukaan atas daun terdapat kelenjar minyak (*oil gland*) yang terletak di ujung tangkai daun. Panjang daun kemiri berkisar antara 12,5-23 cm serta lebar 6-12 cm (Udarno dkk., 2019). Bentuk morfologi daun kemiri pada fase awal pertumbuhan termasuk jenis daun tunggal berbentuk bulat dengan letak daun berselang-seling. Daun kemiri menjadi lonjong dengan tepi bergelombang dan ujung runcing saat mencapai tahap pertumbuhan lebih lanjut (Muhammad dkk., 2015). *Aleurites moluccana* mempunyai pangkal tajuk yang rendah dan secara alami tumbuh setinggi 20 m dengan diameter tajuk 10–15 m dengan cabang lebar menonjol atau menjuntai serta dedaunan hampir menyentuh tanah (Tiralla *et al.*, 2013). Contoh tajuk pohon kemiri ditunjukkan pada Gambar 4.

2.4 Kesehatan Hutan

Kesehatan hutan adalah keadaan hutan yang mampu menjalankan keseluruhan fungsinya, baik fungsi perlindungan bagi air dan tanah, konservasi, maupun produksi. Fungsi-fungsi tersebut dapat berjalan dengan baik walaupun mengalami gangguan dari faktor biotik dan abiotik di sekitarnya. Kesehatan hutan menjadi suatu kriteria pencapaian hutan lestari. Penentuan kesehatan hutan tidak terlepas dari upaya perlindungan terhadap hutan, untuk mencegah dan membatasi kerusakan

hutan dari berbagai faktor biotik dan abiotiknya sehingga tidak menjadi faktor pembatas tujuan pembangunan suatu hutan (Safe'i dan Tsani, 2016).

2.4.1 *Forest Health Monitoring (FHM)*

Salah satu metode yang dapat digunakan untuk menilai kesehatan hutan adalah FHM. FHM adalah sebuah metode untuk memantau, menilai, dan melaporkan tentang status terkini, perubahan, dan kecenderungan jangka panjang kesehatan ekosistem hutan. FHM melibatkan serangkaian kegiatan survei dan pemantauan yang dilakukan secara berkala. Data yang dikumpulkan berkaitan dengan beberapa faktor seperti kepadatan populasi tumbuhan dan hewan, kualitas tanah, kondisi tanaman, serta dampak dari faktor-faktor eksternal seperti penyakit, hama, dan perubahan iklim. Informasi vital dikumpulkan untuk memantau kesehatan hutan, mengidentifikasi potensi ancaman, dan merancang strategi perlindungan dan pemulihan yang tepat. Hasil tersebut dapat digunakan untuk membantu pengelola sumber daya dan pembuat kebijakan dalam mengelola sumber daya hutan negara dan mengevaluasi kebijakan lingkungan untuk sumber daya hutan. Data dari FHM juga dapat digunakan untuk melakukan penelitian lebih lanjut terkait masalah-masalah kesehatan hutan dan berkontribusi pada pengembangan praktik pengelolaan hutan yang berkelanjutan (Mangold, 1997).


FHM menggunakan data dari plot dan survei tanah, survei udara, dan sumber data biotik dan abiotik lainnya dan mengembangkan pendekatan analitis untuk mengatasi masalah kesehatan hutan yang memengaruhi kelestarian ekosistem hutan. Kegiatan FHM dilakukan dengan menggunakan indikator-indikator ekologis yang terukur. Indikator-indikator ekologis tersebut di antaranya adalah vitalitas, produktivitas, biodiversitas, dan kualitas tapak. Vitalitas terdiri dari pengukuran kerusakan pohon dan kondisi tajuk. Pengukuran dan penilaian kondisi tajuk dalam teknik FHM memiliki lima parameter (Safe'i dan Tsani, 2016).

2.4.1.1 Rasio Tajuk Hidup

Perhitungan tajuk hidup didasarkan pada persentase total tinggi pohon yang menyokong kehidupan daun-daun hijau. Daun-daun hijau ini merupakan daun yang masih aktif berfotosintesis.

2.4.1.2 Kerapatan Tajuk


Kerapatan tajuk merupakan penjumlahan dari bagian-bagian pohon yang membentuk tajuk. Kerapatan tajuk juga dikenal sebagai jumlah sinar yang dapat dihalangi oleh tajuk pohon untuk mencapai ke lantai hutan. Kerapatan tajuk dinyatakan dalam desimal kerapatan relatif tajuk hutan dengan kondisi kanopi yang sama sekali tidak dapat menyalurkan sinar ke lantai hutan. Pengukuran kerapatan tajuk dapat menggunakan alat bantu, yaitu berupa kartu *magic card* seperti ditunjukkan pada Gambar 5.



Gambar 5. Kartu *magic card* kerapatan tajuk (Mangold, 1997).

2.4.1.3 Transparansi Tajuk

Transparansi tajuk adalah kebalikan dari kerapatan tajuk. Jika pada kerapatan tajuk yang diukur adalah nilai tajuk yang menghalangi sinar matahari masuk ke lantai hutan, maka pada transparansi tajuk yang diukur adalah sinar matahari yang masuk ke lantai hutan. Pengukuran transparansi tajuk berdasarkan kartu *magic card* dapat dilihat pada Gambar 6.



Gambar 6. Kartu *magic card* transparansi tajuk (Mangold, 1997).

2.4.1.4 Diameter Tajuk

Diameter tajuk diukur pada titik terlebar tajuk menggunakan pita pengukur dengan meminta satu pengamat berdiri di bawah tepi terlebar tajuk, lalu pengamat lainnya berdiri di tepi terlebar tajuk bagian seberang, serta dilakukan pula pengukuran pada 90° sisi lainnya.


2.4.1.5 Dieback/Mati Pucuk

Mati pucuk adalah matinya cabang yang dimulai dari bagian ujung cabang menuju ke batang atau ke pangkal tajuk hidup. Pengukuran data mati pucuk dilakukan dengan pengamatan secara langsung terhadap pucuk pohon yang mati.

2.5 CNN

CNN adalah salah satu metode *deep learning* yang sering digunakan. CNN pada awalnya dirancang untuk *computer vision* dan pengenalan karakter oleh Lecun pada tahun 1995 (Nejedly dkk., 2019). Konsep CNN terinspirasi oleh neuron pada otak manusia dan hewan. CNN memiliki keunggulan, yaitu secara otomatis mendeteksi fitur-fitur penting dari citra tanpa pengawasan manusia. Setiap *input* disusun sebagai matriks tiga dimensi, yaitu: tinggi (*height*), lebar (*width*), dan kedalaman (*depth*), di mana nilai *height* umumnya sama dengan nilai *width*, sehingga

$m \times m \times r$. Kedalaman juga disebut sebagai nilai saluran (*channel*). Misalnya, pada citra RGB, nilai kedalaman (r) adalah 3 (Alzubaidi dkk., 2021).



Gambar 7. Lapisan arsitektur CNN untuk klasifikasi citra (Alzubaidi dkk., 2021).


Arsitektur CNN terbagi menjadi dua bagian, yaitu *feature detection layers* dan *classification layer*. *Feature detection layer* mengubah citra menjadi angka kemudian menghitung matriksnya. *Feature detection layer* terdapat beberapa lapisan di antaranya *input*, *convolution*, *pooling*, dan *function activation*. *Classification layer* terdiri atas *fully connected layer* dan biasanya akan dilanjutkan dengan perhitungan *loss function* (Miranda dkk., 2020). Gambar 7 menunjukkan ilustrasi proses setiap lapisan pada CNN.

2.5.1 Input Layer

Input layer adalah bagian di mana citra diambil untuk dimodelkan sebagai data *input*. Struktur lapisan ini cukup penting dalam hal keberhasilan model yang dirancang. Algoritma lain seperti *preprocessing* seperti penskalaan dan pengurangan kebisingan (*noise*) dapat diterapkan pada data *input* bila diperlukan. *Input* citra yang beresolusi rendah dapat menyebabkan penurunan kedalaman dan performa jaringan pada model.

2.5.2 Convolutional Layer


Convolutional layer terdiri dari kumpulan filter konvolusi yang disebut *kernel*. Citra *input* dinyatakan sebagai matriks N-dimensi yang selanjutnya disederhanakan nilainya tanpa menghilangkan informasi utama ciri dari objek (Alzubaidi dkk., 2021). Filter diterapkan pada setiap subbagian citra, yang selanjutnya ditentukan oleh parameter konektivitas lokal dari lapisan tersebut. Filter yang telah diaplikasikan tersebut menghasilkan nilai skalar untuk lokasi piksel tertentu (Bhardwaj dkk., 2018). Hasil dari proses konvolusi ini berupa *feature map*. Langkah-langkah perhitungan dari *convolution layer* menjadi *feature map* ditunjukkan pada Gambar 8.



Gambar 8. Perhitungan pada langkah *convolutional layer* (Alzubaidi dkk., 2021).

2.5.3 Pooling Layer

Pooling layer memiliki tugas utama untuk subsampling *feature map* hasil dari *convolutional layer*, sehingga membuat *feature map* yang lebih kecil (Alzubaidi dkk., 2021). *Pooling* dilakukan dengan tujuan jumlah parameter yang harus dipelajari oleh jaringan sehingga dapat mengurangi sumber daya komputasi yang dibutuhkan untuk memproses data. Proses pengurangan parameter tersebut berguna mempercepat proses komputasi (Meliuwati dan Kurniati, 2022). Metode *pooling* ada beberapa jenis, di antaranya: *tree pooling*, *gated pooling*, *average pooling*, *min pooling*, *max pooling*, *Global Average Pooling (GAP)*, dan *global max pooling*. Gambar 9 mengilustrasikan contoh proses *average pooling*, *max pooling*, dan *Global Average Pooling (GAP)*.



Gambar 9. Contoh tiga jenis *pooling* (Alzubaidi dkk., 2021).

2.5.4 Fungsi Aktivasi (*nonlinieritas*)

Fungsi utama fungsi aktivasi pada setiap jenis jaringan saraf (*neural network*) adalah memetakan *input* ke *output*. Fungsi aktivasi menentukan neuron yang akan diaktifkan dan dipetakan oleh fungsi nonlinear, sehingga dapat digunakan untuk menyelesaikan masalah nonlinear (Y. Wang dkk., 2020). Lapisan aktivasi nonlinear umumnya digunakan setelah semua lapisan dengan bobot (seperti *fully connected layer* dan *convolutional layer*) dalam arsitektur CNN (Alzubaidi dkk., 2021).

Fungsi aktivasi digunakan untuk meningkatkan kemampuan ekspresi model *neural network* karena mengontrol hasil penjumlahan bobot agar tidak terlalu tinggi atau terlalu rendah. Jenis fungsi aktivasi yang umum digunakan pada arsitektur CNN di antaranya: *ReLU*, *softmax*, *sigmoid*, *tanh*, dan *softplus*.

2.5.5 *Fully Connected Layer*

Fully connected layer umumnya terletak di akhir setiap arsitektur CNN. *Fully connected layer* menggunakan pendekatan *Fully Connected* (FC) yang menghubungkan setiap neuron dengan semua neuron pada lapisan sebelumnya. *Input* dari *fully connected layer* berasal dari *pooling* atau *convolutional layer* terakhir (Alzubaidi dkk., 2021). Data yang sebelumnya multidimensi akan ditransformasikan menjadi data linier dengan melakukan *flatten* atau *reshape* (Fuadah dkk., 2022).


2.5.6 *Loss Functions*

Loss function digunakan pada lapisan *output* untuk menghitung kesalahan prediksi yang dibuat pada saat pelatihan dalam model CNN. *Loss function* menunjukkan perbedaan antara *output* aktual dan *output* hasil prediksi. *Loss function* biasanya menggunakan dua parameter untuk menghitung kesalahan, yaitu *output* perkiraan CNN (disebut sebagai prediksi) dan *output* aktual (disebut sebagai label). Jenis *loss function* yang umum digunakan di antaranya: *softmax*, *euclidean*, dan *hinge* (Alzubaidi dkk., 2021).


2.6 *MobileNet*

MobileNet adalah salah satu arsitektur CNN bersifat *open source* dari Google yang diusulkan pada tahun 2017. *MobileNet* dirancang untuk memaksimalkan akurasi dengan memperhatikan keterbatasan sumber daya, sehingga dapat diimplementasikan pada perangkat *mobile* dan aplikasi tertanam (*embedded application*). *MobileNet* merupakan arsitektur yang telah dilatih sebelumnya

menggunakan *database ImageNet*, sehingga dapat diterapkan untuk tugas klasifikasi, segmentasi, dan deteksi.




Gambar 10. Filter konvolusi standar seperti gambar (a) diganti dengan *depthwise convolution* (b) dan *pointwise convolution* (c) untuk membuat *depthwise separable convolution* (Howard dkk., 2017).



Gambar 11. Perbandingan konvolusi standar dan *depthwise separable convolution* (Howard dkk., 2017).

MobileNet menggunakan konsep *depthwise separable convolution* yang dilakukan dengan membagi konvolusi menjadi *depthwise convolution* dan *pointwise convolution* seperti ditunjukkan pada Gambar 10. *Depthwise* digunakan untuk memisahkan setiap saluran pada *input*. Misalnya ada 3 saluran *input*, yaitu merah, hijau, dan biru (RGB), maka setiap saluran akan diolah secara terpisah dengan filter khususnya. *Depthwise* akan menghasilkan matriks *output* yang memiliki kedalaman yang sama dengan matriks *input*, namun dengan dimensi spasial yang telah diubah. *Depthwise* hanya memfilter saluran masuk, sedangkan untuk menggabungkannya digunakan lapisan *pointwise*. *Pointwise* menghitung kombinasi linier dari *output depthwise convolution* melalui konvolusi 1×1 untuk

menghasilkan fitur-fitur baru. Konvolusi 1×1 ini bertujuan untuk menggabungkan dan memadukan informasi dari berbagai saluran yang telah diolah pada tahap sebelumnya (Howard dkk., 2017). Perbandingan konvolusi standar dan *depthwise separable convolution* dapat dilihat pada Gambar 11. *Batch Normalization* (BN) juga diterapkan pada *MobileNet* untuk meningkatkan stabilitas mempercepat pelatihan dengan menormalisasikan *output* dari lapisan kovolusi sebelumnya. BN memastikan bahwa setiap *mini-batch* memiliki rata-rata nol dan varians satu.



Gambar 12. Arsitektur *MobileNet* (W. Wang dkk., 2020).

MobileNet memiliki struktur yang terdiri dari *input layer*, *convolution layer*, *depthwise separable convolutional layer*, *fully connected layer*, dan *output layer* seperti diilustrasikan pada Gambar 12. *Input layer* berfungsi untuk menerima citra dengan ukuran tertentu. *Convolution layer* digunakan untuk mengekstraksi fitur-fitur dasar penting dari citra *input*. *Depthwise separable convolutional layer* merupakan teknik penting untuk mengurangi beban komputasi tanpa mengorbankan akurasi. *Depthwise separable convolutional layer* membagi konvolusi menjadi *depthwise* dan *pointwise*. Hasil dari lapisan terakhir *depthwise separable convolutional layer* digunakan sebagai *input* untuk lapisan *fully-connected*, yang bertugas untuk mengklasifikasikan citra ke dalam kelas-kelas tertentu. *Output layer* menghasilkan prediksi berupa probabilitas kemungkinan kelas dari citra yang diberikan (Howard dkk., 2017). Lapisan-lapisan tersebut secara rinci dapat dilihat pada Tabel 2.

Tabel 2. Rincian Lapisan pada Arsitektur *MobileNet*

No.	Tipe	Stride	Filter Shape	Ukuran Input
1	Conv2D	2	3×3×3×32	224×224×3
2	DepthwiseConv2D	1	3×3×32 dw	112×112×32
3	Conv2D	1	1×1×32×64	112×112×32
4	DepthwiseConv2D	2	3×3×64 dw	112×112×64
5	Conv2D	1	1×1×64×128	56×56×64
6	DepthwiseConv2D	2	3×3×128 dw	56×56×128
7	Conv2D	1	1×1×128×128	56×56×128
8	DepthwiseConv2D	2	3×3×128 dw	56×56×128
9	Conv2D	1	1×1×128×256	28×28×128
10	DepthwiseConv2D	2	3×3×256 dw	28×28×256
11	Conv2D	1	1×1×256×256	28×28×256
12	DepthwiseConv2D	2	3×3×256 dw	28×28×256
13	Conv2D	1	1×1×256×512	14×14×256
14	DepthwiseConv2D	1	3×3×512 dw	14×14×512
15	Conv2D	1	1×1×512×512	14×14×512
16	DepthwiseConv2D	1	3×3×512 dw	14×14×512
17	Conv2D	1	1×1×512×512	14×14×512
18	DepthwiseConv2D	1	3×3×512 dw	14×14×512
19	Conv2D	1	1×1×512×512	14×14×512
20	DepthwiseConv2D	1	3×3×512 dw	14×14×512
21	Conv2D	1	1×1×512×512	14×14×512
22	DepthwiseConv2D	2	3×3×512 dw	14×14×512
23	Conv2D	1	1×1×512×1024	7×7×512
24	DepthwiseConv2D	2	3×3×1024 dw	7×7×1024
25	Conv2D	1	1×1×1024×1024	7×7×1024
26	Avg Pool	1	Pool 7×7	7×7×1024
27	FC	1	1024×1000	1×1×1024
28	Softmax	1	Classifier	1×1×1000

2.7 Preprocessing Data

Preprocessing data adalah serangkaian proses yang dilakukan pada data sebelum data tersebut digunakan untuk melatih atau menguji model. Tujuannya adalah untuk membersihkan, mentransformasi, dan mempersiapkan data sehingga dapat digunakan secara efektif oleh model untuk mendapatkan hasil yang lebih baik. Hasil dari *preprocessing* data adalah *dataset* final (Kotsiantis dkk., 2006).

2.8 Hyperparameter

Learning parameter terdiri dari bobot (*weight*) dan bias. Nilai-nilai *learning parameter* diinisialisasi secara acak sebelum pelatihan dimulai. *Hyperparameter*

adalah bagian dari parameter yang biasanya dikonfigurasi secara manual oleh praktisi sebelum menerapkan algoritma pembelajaran ke *dataset*. Istilah *hyperparameter* pada *machine learning* diperkenalkan oleh Lindley dan Smith pada tahun 1972. *Hyperparameter* memiliki peran penting dalam menentukan performa dan keberhasilan model yang dilatih (Afaq dan Rao, 2020). *Hyperparameter* yang umum digunakan di antaranya, yaitu *learning rate*, *batch size*, *optimizer*, dan *epoch*.

2.8.1 Learning rate

Learning rate merupakan salah satu *hyperparameter* yang ditetapkan untuk menghitung nilai koreksi bobot selama proses pelatihan. Nilai *learning rate* berkisar antara 0 sampai 1 (Palakodati dkk., 2020). *Learning rate* yang tidak tepat akan mengurangi kecepatan bahkan dapat membuat algoritma pelatihan menyimpang. Performa model atau akurasi klasifikasi juga terkait erat dengan perubahan *learning rate* (Zhao dkk., 2019). *Learning rate* yang terlalu kecil menyebabkan waktu pelatihan menjadi lama, sedang jika terlalu besar dapat menyebabkan proses pembelajaran terlalu cepat sehingga kurang optimal (Rismiyati dan Luthfiarta, 2021).

2.8.2 Batch size

Batch size adalah jumlah sampel pelatihan yang diteruskan ke jaringan pada satu iterasi. *Batch size* merupakan salah satu *hyperparameter* terpenting yang berpengaruh dalam menentukan akurasi klasifikasi. *Batch size* yang berukuran besar akan memengaruhi kebutuhan memori dan juga semakin membutuhkan waktu pelatihan *dataset* (Palakodati dkk., 2020).

2.8.3 Optimizer

Optimizer adalah mekanisme yang digunakan jaringan untuk memperbarui dirinya sendiri berdasarkan data yang dilihatnya dan fungsi kerugiannya (*loss function*) (Chollet, 2017). *Optimizer* digunakan dalam mengoptimalkan kinerja model dengan memperbarui parameter bobot yang meminimalkan *loss function*. Macam-macam *optimizer* di antaranya: SGD, Adam, Adagrad, dan RMSprop (Palakodati dkk., 2020). Adam adalah pengembangan dari *Stochastic Gradient Descent* (SGD) di mana bobot pada jaringan dioptimalkan.

2.8.4 Epoch

Epoch adalah jumlah iterasi yang dilakukan pada pelatihan *dataset*. *Epoch* diperlukan sebagai batasan untuk proses pembelajaran. *Epoch* merupakan suatu kondisi di mana setiap *dataset* yang dimasukkan ke model telah selesai melewati seluruh proses pelatihan pada *neural network* dalam satu kali putaran secara *forward propagation* dan *back propagation* (Rozaqi dan Sunyoto, 2020).

2.9 Confusion Matrix

Confusion matrix merupakan salah satu teknik untuk membuat ringkasan dari kinerja algoritma klasifikasi yang dibuat. *Confusion matrix* diperkenalkan pada tahun 1955 oleh Miller dan Nicely pada penelitian mengenai huruf konsonan dalam Bahasa Inggris. *Confusion matrix* adalah tabel yang menunjukkan seberapa baik pengklasifikasi dilakukan pada sekumpulan data uji dibandingkan dengan nilai sebenarnya. *Confusion matrix* biasanya berupa matriks dua dimensi dengan label "aktual" dan "prediksi". *Confusion matrix* mempunyai empat metrik utama, yaitu: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) (Maxwell dkk., 2021).

Tabel 3. Metrik Utama Standar *Confusion Matrix* (Chicco dan Jurman, 2020)

	Diprediksi Positif	Diprediksi Negatif
Positif Sebenarnya	TP	FN
Negatif Sebenarnya	FP	TN

Keterangan:

TP : model dengan benar memprediksi sebuah kelas (positif) sebagai kelas yang sebenarnya (positif).

TN : model dengan benar memprediksi sebuah kelas (negatif) sebagai kelas lain (negatif).

FP : model salah memprediksi kelas lain (negatif) sebagai kelas yang sebenarnya (positif).

FN : model salah memprediksi kelas yang sebenarnya (positif) sebagai kelas lain (negatif).

Confusion matrix juga terdiri atas analisis statistik, yaitu: *accuracy*, *precision*, *recall*, dan *f1-score* yang bertujuan untuk menyampaikan struktur *confussion matrix* ke dalam satu citra (Chicco dan Jurman, 2020).

2.9.1 Accuracy

Accuracy menggambarkan kinerja model dalam melakukan klasifikasi. *Accuracy* adalah rasio antara jumlah sampel yang diklasifikasikan dengan benar dan jumlah keseluruhan sampel (Pedregosa dkk., 2011). Persamaan (1) menunjukkan perhitungan *accuracy*.

$$Accuracy(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} 1(\hat{y}_i = y_i) \dots \dots \dots (1)$$

Keterangan:

y = nilai atau kelas sebenarnya

$\hat{y}$ = hasil prediksi

$n_{samples}$ = jumlah keseluruhan sampel (data uji)

2.9.2 Precision

Precision ini terdiri dari prediksi benar untuk kelas yang sebenarnya dan prediksi salah dibandingkan dengan kelas sebenarnya. Ketika hasil prediksi benar (TP) besar dan hasil prediksi salah (FP) kecil, model akan memiliki *precision* yang tinggi (Chicco dan Jurman, 2020). Persamaan (2) menunjukkan perhitungan *precision*.

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

2.9.3 Recall

Recall digunakan untuk menghitung hasil deteksi kelas sebenarnya yang diprediksi sebagai kelas lain atau kelas yang diprediksi benar sebagai kelas sebenarnya (TP) (Chicco dan Jurman, 2020). Persamaan (3) menunjukkan perhitungan *recall*.

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

2.9.4 F1-score

F1-score menghitung rata-rata *precision* dan *recall*. *F1-score* umumnya digunakan ketika *dataset* untuk pelatihan model tiap kelas jumlahnya *imbalance* (tidak seimbang). *F1-score* dapat digunakan sebagai nilai perbandingan antar model (Chicco dan Jurman, 2020). Persamaan (4) menunjukkan perhitungan *F1-score*.

$$F1 - score = 2 \times \frac{Recall \times Precision}{Recall + Precision} \dots\dots\dots (4)$$

III.METODOLOGI PENELITIAN

3.1 Waktu dan Tempat

Penelitian ini dilakukan di Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Laboratorium Rekayasa Perangkat Lunak (Lab RPL) FMIPA, dan Tahura WAR Sumber Agung, Kemiling, Bandar Lampung. Penelitian dilaksanakan dari Maret sampai dengan Oktober tahun 2023. Waktu penelitian ditunjukkan pada Tabel 4.

Tabel 4. Waktu Penelitian

Nama Kegiatan	2023							
	Maret	April	Mei	Juni	Juli	Agustus	September	Oktober
Pengumpulan <i>Dataset</i>								
Pelabelan Data <i>Preprocessing</i>								
Data Pembagian <i>Dataset</i>								
Model CNN <i>MobileNet</i>								
Pengujian dan Evaluasi Model								
Penulisan Laporan								

3.2 Bahan dan Alat

Bahan dan alat yang digunakan dalam penelitian ini ialah sebagai berikut.

3.2.1 Bahan Penelitian

Penelitian ini menggunakan *dataset* citra tajuk pohon jenis daun lebar yang terdiri dari empat jenis pohon, yaitu pohon cokelat, durian, karet, dan kemiri. *Dataset* diperoleh dari observasi yang dilakukan di Tahura WAR Sumber Agung, Kemiling, Bandar Lampung. Data citra tersebut dibagi ke dalam 10 kelas sesuai dengan kartu *magic card*. Total data dari pengumpulan *dataset* di Tahura WAR Sumber Agung secara keseluruhan berjumlah 2.965 citra. Tabel 5 menunjukkan jumlah citra kerapatan dan transparansi tajuk pohon jenis daun lebar yang digunakan sebagai bahan penelitian.

Tabel 5. Jumlah Citra Kerapatan dan Transparansi Tajuk Pohon Jenis Daun Lebar Sebagai Bahan Penelitian

Jenis Pohon	Jumlah Citra Kerapatan dan Transparansi Tajuk Pohon jenis daun Lebar
Cokelat	620
Durian	818
Karet	600
Kemiri	927
Total	2.965

3.2.2 Alat Penelitian

Alat yang digunakan pada penelitian ini dapat dikelompokkan menjadi perangkat lunak dan perangkat keras.

3.2.2.1 Perangkat Lunak

Perangkat lunak yang digunakan untuk mendukung penelitian ini dalam mengklasifikasi kerapatan dan transparansi tajuk pada tajuk pohon jenis daun lebar adalah sistem operasi Windows 11 64-bit, Jupyter Notebook, Google Colab, Google Drive, dan Avenza Maps. Bahasa pemrograman yang digunakan adalah *python*, dengan beberapa *library* seperti ditunjukkan pada Tabel 6.


Tabel 6. *Library* yang Digunakan pada Model *MobileNet*

No.	<i>Library</i>	Keterangan
1	<i>os</i>	<i>Library</i> dalam bahasa <i>python</i> yang memungkinkan pengguna untuk berinteraksi dengan sistem operasi, seperti membaca file, membuat direktori, maupun menghapus direktori (Python Software Foundation, 2023).
2	<i>splitfolders</i>	<i>Library python</i> yang digunakan untuk membagi <i>dataset</i> menjadi <i>subset</i> data latih, validasi, dan uji (Filter, 2022).
3	<i>numpy</i>	<i>Library</i> dalam bahasa <i>python</i> untuk komputasi ilmiah seperti menyediakan multidimensional <i>array</i> dan berbagai fungsi untuk melakukan operasi matematika pada <i>array</i> tersebut (NumPy, 2022).
4	<i>Pandas</i>	<i>Library</i> bersifat <i>open source</i> pada <i>python</i> yang dirancang untuk bekerja dengan <i>time series</i> dan data tabel seperti <i>DataFrame</i> (Gevorkyan dkk., 2019).
5	<i>Keras</i>	<i>Keras</i> adalah sebuah API (<i>Application Programming Interface</i>) yang dirancang untuk memudahkan pengembangan model <i>deep learning</i> sehingga memungkinkan eksperimen cepat dan pembuatan prototipe sederhana (Chicho dan Bibo Sallow, 2021).
6	<i>Tensorflow</i>	<i>Library</i> yang dikembangkan Google untuk komputasi numerik, terutama untuk membangun, melatih, dan menerapkan berbagai model <i>machine learning</i> dan <i>deep learning</i> (Gevorkyan dkk., 2019).
7	<i>Scikit Learn (sklearn)</i>	<i>Library</i> yang menyediakan beragam algoritma <i>machine learning</i> yang mencakup klasifikasi, regresi, klastering, serta alat evaluasi model (Gevorkyan dkk., 2019).
8	<i>Matplotlib</i>	<i>Library</i> dalam <i>python</i> yang digunakan untuk visualisasi data dalam bentuk grafik 2D, misalnya diagram batang, diagram garis, diagram lingkaran, dan lainnya (Sial dkk., 2021).
9	<i>Seaborn</i>	<i>Library</i> berbasis <i>Matplotlib</i> yang dirancang untuk menghasilkan visualisasi data yang menarik dan informatif, seperti heatmap (Sial dkk., 2021).
10	<i>Visualkeras</i>	<i>Library python</i> yang memungkinkan untuk memvisualisasikan arsitektur model yang dibuat dengan <i>Keras</i> (Gavrikov, 2021).

3.2.2.2 Perangkat Keras

Komputer NVIDIA Tesla K80, kamera Canon EOS 250D, dan laptop Lenovo Ideapad 3 dengan spesifikasi prosesor AMD Ryzen 7 5700U menggunakan Radeon Graphics 1.80 GHz, RAM 8.00 GB digunakan sebagai alat untuk proses klasifikasi kerapatan dan transparansi tajuk pada tajuk pohon jenis daun lebar.

3.3 Metode



Gambar 13. Metode penelitian.

Gambar 13 mengilustrasikan tahapan metode penelitian klasifikasi nilai kerapatan dan transparansi tajuk pohon jenis daun lebar. Penjelasan tahapan yang dilakukan pada penelitian ini ialah sebagai berikut.

3.3.1 Pengumpulan Dataset

Dataset yang diperlukan untuk penelitian ini adalah citra tajuk tajuk pohon jenis daun lebar, sehingga diperlukan proses pengumpulan *dataset* tersebut. Citra tajuk tajuk pohon jenis daun lebar diambil di blok tradisional Tahura WAR Sumber

Agung, Kemiling, Bandar Lampung. *Dataset* yang dikumpulkan berupa citra tajuk pohon jenis daun lebar dari empat jenis pohon yang kemudian dikelompokkan menjadi 10 kelas. Pengambilan citra dilakukan setelah proposal disetujui pada bulan Maret-Mei 2023. Pengambilan data dalam penelitian ini dapat dilakukan selama sinar matahari masuk ke tajuk pohon sampai menyentuh lantai hutan sehingga waktu tidak mempengaruhi data yang diambil. Alat yang digunakan untuk mengambil citra adalah kamera Canon EOS 250D.

3.3.2 Pelabelan Data

Pelabelan data dilakukan berdasarkan kartu *magic card* dengan melibatkan 15 responden di antaranya 5 orang dari jurusan Ilmu Komputer yang melakukan penelitian berkaitan dengan topik kesehatan hutan, dan 10 orang dari jurusan Kehutanan.

3.3.3 Preprocessing Data

Tahapan *preprocessing* yang dilakukan pada penelitian ini adalah mengubah dimensi data (*resize*) dari 1600×1600 piksel menjadi 224×224 piksel. *Resize* dilakukan dengan tujuan mengurangi beban komputasi dan memori GPU yang diperlukan untuk menyimpan data.

3.3.4 Pembagian Dataset

Dataset dibagi menjadi data latih (*training*), data validasi (*validation*), dan data uji (*testing*).

3.3.2.1 Data latih

Data latih (*training*) digunakan sebagai bahan utama untuk melatih model. Pembagian data latih diambil sebesar 70% dari *dataset*.

3.3.2.2 Data validasi

Data validasi (*validation*) digunakan untuk melakukan validasi model untuk mencegah *overfitting*. Proses pelatihan memerlukan proses validasi untuk melihat keakuratan dan kesamaan data yang telah diklasifikasikan oleh model. Penelitian ini menggunakan 10% dari *dataset* untuk data validasi.

3.3.2.3 Data uji

Data uji (*testing*) digunakan dalam proses pengujian model untuk melihat kinerja dan akurasi model yang telah dibangun. Pembagian data uji pada penelitian ini adalah sebesar 20% dari *dataset*.

3.3.5 Model *MobileNet*

Tahapan yang dilakukan adalah pelatihan model dan validasi model. Pelatihan model CNN arsitektur *MobileNet* menggunakan data latih dan data validasi dengan beberapa *hyperparameter* yang ditentukan untuk mengoptimalkan model yang akan dilatih. *Hyperparameter* yang digunakan di antaranya: *epoch*, *batch size*, *learning rate*, dan *optimizer*. Selain itu, digunakan juga fungsi *callback* seperti *EarlyStopping* untuk menghentikan iterasi pelatihan ketika sudah mencapai nilai optimum sehingga dapat mengurangi beban komputasi.

3.3.6 Pengujian Model

Proses pengujian model dilakukan setelah proses pelatihan model dilakukan. Tahapan ini menggunakan data uji untuk menguji kinerja model yang telah dilatih. Hasil uji model kemudian ditampilkan dalam akurasi model yang menunjukkan hasil klasifikasi objek oleh model. Klasifikasi objek akan menampilkan kecenderungan objek terhadap suatu kelas. Kecenderungan ini dinyatakan dengan nilai probabilitas yang ditunjukkan oleh masing-masing kelas. Hasil pengujian model disajikan dengan *confusion matrix* yang terdiri dari TP, TN, FP, dan FN.

V. SIMPULAN DAN SARAN

5.1 Simpulan

Hasil eksperimen menunjukkan bahwa model *MobileNet* tidak dapat diimplementasikan secara langsung untuk mengklasifikasi nilai kerapatan dan transparansi tajuk pohon dalam metode *Forest Health Monitoring* (FHM) untuk pohon jenis daun lebar. Model *MobileNet* klasifikasi nilai kerapatan dan transparansi tajuk pohon jenis daun lebar mengalami *overfitting*. *Overfitting* ditunjukkan dengan perbedaan yang signifikan antara hasil akurasi pada proses pelatihan dan pengujian. Hasil akurasi pada proses pelatihan lebih besar dibandingkan dengan akurasi proses pengujian. Nilai *loss* pada tahap pengujian juga relatif tinggi dan memiliki perbedaan yang signifikan dibanding *loss* pada proses pelatihan menandakan bahwa model tidak mampu mengklasifikasi dengan presisi nilai kerapatan dan transparansi tajuk pohon pada jenis daun lebar.

5.2 Saran

Saran yang dapat dipertimbangkan untuk penelitian selanjutnya di antaranya sebagai berikut.

1. Memperbanyak jumlah *dataset* masing-masing jenis pohon jenis daun lebar, sehingga model dapat lebih optimal dalam mempelajari citra tajuk untuk dapat diklasifikasi nilai kerapatan dan transparansi tajuknya. Tujuan memperbanyak jumlah *dataset* tersebut adalah untuk memperkaya *dataset* dan meningkatkan akurasi model.
2. Memperluas cakupan jenis pohon jenis daun lebar lainnya selain cokelat, durian, karet, dan kemiri, serta meningkatkan variasi citra untuk setiap kelas

kerapatan dan transparansi pada tajuk pohon jenis daun lebar. Jenis pohon jenis daun lebar lain yang bisa diteliti selanjutnya di antaranya adalah melinjo, pala, randu, sirsak, angkana, dan lain-lain. Hal ini bertujuan untuk menambah variasi model klasifikasi nilai kerapatan dan transparansi tajuk daun lebar sebab karakteristik tajuk tiap jenis pohon berbeda-beda.

3. Menggunakan teknik segmentasi gambar agar model terfokus pada tajuk daun lebar saja, tanpa ranting pohonnya.
4. Menggunakan berbagai arsitektur CNN lain seperti *LeNet*, *Inception*, *YOLO*, dan lainnya untuk melakukan perbandingan hasil akurasi dengan arsitektur yang berbeda, sehingga dapat mencapai hasil yang optimal.

DAFTAR PUSTAKA

- Abdullah. *et al.* (2021) 'The GASA Gene Family in Cacao (Theobroma Cacao, Malvaceae): Genome Wide Identification and Expression Analysis'. *Agronomy*, 11(7), p. 1425. DOI: 10.3390/agronomy11071425.
- Afaq, S. and Rao, S. (2020) 'Significance Of Epochs On Training A Neural Network'. *International Journal of Scientific & Technology Research*, 9, pp. 485–488.
- Agroni, D. (2021) *Durio Zibethinus*. flickr. Available at: <https://www.flickr.com/photos/148298326@N02/49779900793/> (Accessed: 27 June 2024).
- Agrozine, R. (2021) *Panduan Lengkap Cara Budidaya Tanaman Kakao*. Available at: <https://agrozine.id/panduan-lengkap-cara-budidaya-tanaman-kakao/> (Accessed: 27 June 2024).
- Alzubaidi, L. *et al.* (2021) 'Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions'. *Journal of Big Data*, 8(1), p. 53. DOI: 10.1186/s40537-021-00444-8.
- Bhardwaj, A., Di, W. and Wei, J. (2018) *Deep Learning Essentials: Your Hands-on Guide to the Fundamentals of Deep Learning and Neural Network Modeling*. Packt Publishing Available at: <https://books.google.co.id/books?id=ISBKDwAAQBAJ>.
- Chicco, D. and Jurman, G. (2020) 'The Advantages of the Matthews Correlation Coefficient (MCC) over F1 Score and Accuracy in Binary Classification Evaluation'. *BMC Genomics*, 21(1), p. 6. DOI: 10.1186/s12864-019-6413-7.
- Chicho, B.T. and Bibo Sallow, A. (2021) 'A Comprehensive Survey of Deep Learning Models Based on Keras Framework'. *Journal of Soft Computing and Data Mining*, 2(2). DOI: 10.30880/jscdm.2021.02.02.005.

- Chollet, F. (2017) *Deep Learning with Python*. New York: Manning Publications.
- Damanik, S.E. and Sahudra, T.M. (2021) *Manajemen Wilayah Hutan*. Simatupang, P. (ed.). Yogyakarta: Penerbit K-Media.
- Djoko, G. *et al.* (2019) *Taman Hutan Raya Wan Abdul Rachman Lampung*. Bandar Lampung: Pustaka Media.
- Filter, J. (2022) *Split-Folders*. PyPI Python Software Foundation. Available at: <https://pypi.org/project/split-folders/> (Accessed: 31 January 2024).
- Fuadah, Y.N. *et al.* (2022) 'Optimasi Convolutional Neural Network Dan K-Fold Cross Validation Pada Sistem Klasifikasi Glaukoma'. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(3), p. 728. DOI: 10.26760/elkomika.v10i3.728.
- Gavrikov, P. (2021) *Visualkeras · PyPI*. PyPI Python Software Foundation. Available at: <https://pypi.org/project/visualkeras/> (Accessed: 31 January 2024).
- Gevorkyan, M.N. *et al.* (2019) 'Review and Comparative Analysis of Machine Learning Libraries for Machine Learning'. *Discrete and Continuous Models and Applied Computational Science*, 27(4), pp. 305–315. DOI: 10.22363/2658-4670-2019-27-4-305-315.
- Hatiqah, N. (2017) *Pokok Getah*. flickr. Available at: <https://www.flickr.com/photos/152544904@N08/23974120128/> (Accessed: 27 June 2024).
- Herwanti, S. *et al.* (2022) 'Peningkatan Kapasitas Masyarakat Sekitar Taman Hutan Raya Wan Abdul Rachman Dalam Memasarkan Produk Hasil Hutan Bukan Kayu'. *Jurnal Pengabdian Fakultas Pertanian Universitas Lampung*, 01(01), pp. 057–069. DOI: <http://dx.doi.org/10.23960/jpfp.v1i1.5762>.
- Howard, A.G. *et al.* (2017) Available at: <https://arxiv.org/abs/1704.04861> (Accessed: 5 October 2023).
- Jean-Marie, E. *et al.* (2022) 'Theobroma Cacao and Theobroma Grandiflorum: Botany, Composition and Pharmacological Activities of Pods and Seeds'. *Foods*, 11(24), p. 3966. DOI: 10.3390/foods11243966.
- Kotsiantis, S.B., Kanellopoulos, D. and Pintelas, P.E. (2006) 'Data Preprocessing for Supervised Learning'. *International Journal of Computer Science*, 1(2), pp. 111–117.

- Krisnawati, H., Kallio, M. and Kanninen, M. (2011) *Aleurites Moluccana (L.) Willd.: Ecology, Silviculture and Productivity*. Bogor, Indonesia: CIFOR.
- LeCun, Y. and Bengio, Y. (1995) 'Convolutional Networks for Images, Speech, and Time Series'. *The Handbook of Brain Theory and Neural Networks*, 3361(10), p. 1995.
- Lindley, D. v. and Smith, A.F.M. (1972) 'Bayes Estimates for the Linear Model'. *Journal of the Royal Statistical Society Series B-Methodological*, 34, pp. 1–18.
- Mangold, R. (1997) *Forest Health Monitoring: Field Methods Guide*. New Year: USDA Forest Service.
- Maxwell, A.E., Warner, T.A. and Guillén, L.A. (2021) 'Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 1: Literature Review'. *Remote Sensing*, 13(13). DOI: 10.3390/rs13132450.
- Meliuwati, P. and Kurniati, E. (2022) 'Ekstraksi Data Digital Menggunakan Teknik Max Pooling Dan Average Pooling'. *Jurnal Riset Matematika (JRM)*, 2(2), pp. 137–144. DOI: 10.29313/jrm.v2i2.1338.
- Miller, G.A. and Nicely, P.E. (1955) 'An Analysis of Perceptual Confusions Among Some English Consonants'. *The Journal of the Acoustical Society of America*, 27(2), pp. 338–352. DOI: 10.1121/1.1907526.
- Miranda, N.D., Novamizanti, L. and Rizal, S. (2020) 'Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan ResNet-50'. *Jurnal Teknik Informatika (Jutif)*, 1(2), pp. 61–68. DOI: 10.20884/1.jutif.2020.1.2.18.
- Muhammad, L.A., Dharmono, D. and Sri, A. (2015) 'Struktur Populasi Aleurites Moluccana Willd Di Kawasan Wisata Air Terjun Bajuin Tanah Laut'. *Prosiding Seminar Nasional XII FKIP UNS*, 12(1). Available at: <https://repo-dosen.ulm.ac.id/handle/123456789/16661> (Accessed: 17 September 2023).
- Nahiduzzaman, Md. *et al.* (2023) 'Explainable Deep Learning Model for Automatic Mulberry Leaf Disease Classification'. *Frontiers in Plant Science*, 14. DOI: 10.3389/fpls.2023.1175515.
- Nejedly, P. *et al.* (2019) 'Intracerebral EEG Artifact Identification Using Convolutional Neural Networks'. *Neuroinformatics*, 17(2), pp. 225–234. DOI: 10.1007/s12021-018-9397-6.

- Nopriyanto, Z. *et al.* (2022) 'Implementasi Metode CNN Computer Vision Dalam Identifikasi Tipe Kerusakan Pohon Berbasis FHM'. *InComTech: Jurnal Telekomunikasi Dan Komputer*, 10(1), pp. 15–22.
- NumPy. (2022) *NumPy Documentation*. NumPy Developers. Available at: <https://numpy.org/doc/stable/> (Accessed: 31 January 2024).
- Palakodati, S.S.S. *et al.* (2020) 'Fresh and Rotten Fruits Classification Using CNN and Transfer Learning'. *Revue d'Intelligence Artificielle*, 34(5), pp. 617–622. DOI: 10.18280/ria.340512.
- Panggabean, R.M. (2022) *Pengaruh Daya Laser CO2 Terhadap Tingkat Kekasaran Permukaan Dan Perubahan Warna Kayu Jati (Tectona Grandis) Dan Kayu Pinus (Pinus Merkusii)*. Universitas Lampung.
- Pasaribu, S.A., Prasetyo, N.E. and Oktavia, F. (2023) 'Keunikan Dan Keseragaman Klon Karet IRR 220 Dan IRR 429'. *Jurnal Penelitian Karet*, pp. 81–92. DOI: 10.22302/ppk.jpk.v41i2.866.
- Pedregosa, F. *et al.* (2011) 'Scikit-Learn: Machine Learning in Python'. *Journal of Machine Learning Research*, 12, pp. 2825–2830.
- Pertiwi, D., Safe'i, R. and Kaskoyo, H. (2020) 'Kesehatan Hutan Di Blok Koleksi Tumbuhan Dan/Atau Satwa Tahura Wan Abdul Rachman Provinsi Lampung'. *Jurnal Hutan Tropis*, 8(3), pp. 244–347.
- Pratiwi, N., Hanafiah, D.S. and Siregar, L.A.M. (2018) 'Identifikasi Karakter Morfologis Durian(Durio Zibethinus Murr) Di Kecamatan Tigalingga Dan Pegagan Hilir Kabupaten Dairi Sumatera Utara'. *Jurnal Agroekoteknologi FP USU*, 6(2), pp. 200–208.
- Python Software Foundation. (2022) *Os — Miscellaneous Operating System Interfaces*. Python Documentation. Available at: <https://docs.python.org/3/library/os.html> (Accessed: 10 October 2023).
- Rismiyati, R. and Luthfiarta, A. (2021) 'VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification'. *Telematika: Jurnal Informatika Dan Teknologi Informasi*, 18(1), p. 37. DOI: 10.31315/telematika.v18i1.4025.
- Rozaqi, A.J. and Sunyoto, A. (2020) 'Identification of Disease in Potato Leaves Using Convolutional Neural Network (CNN) Algorithm'. In *2020 3rd International Conference on Information and Communications Technology (ICOIACT)*. IEEE, pp. 72–76. DOI: 10.1109/ICOIACT50329.2020.9332037.

- Sadono, R. (2018) 'Predicting Crown-Width of Dominant Trees on Teak Plantation from Clonal Seed Orchards in Ngawi Forest Management Unit, East Java Ronggo Sadono'. *Jurnal Ilmu Kehutanan*, 12, pp. 127–141. Available at: <https://jurnal.ugm.ac.id/jikkt>.
- Safe'i, R. and Tsani, M.K. (2016) *Kesehatan Hutan: Penilaian Kesehatan Hutan Menggunakan Teknik Forest Health Monitoring*. 1st Edition. Yogyakarta: Plantaxia.
- Sekretariat Negara Republik Indonesia. (1999) *Undang-Undang Nomor 41 Tahun 1999*. Indonesia.
- Sial, A.H., Rashdi, S.Y.S. and Khan, A.H. (2021) 'Comparative Analysis of Data Visualization Libraries Matplotlib and Seaborn in Python'. *International Journal of Advanced Trends in Computer Science and Engineering*, 10(1), pp. 277–281. DOI: 10.30534/ijatcse/2021/391012021.
- Susilowati, A. *et al.* (2020) 'Morphology and Germination of the Candlenut Seed (Aleurites Moluccana) from Samosir Island-North Sumatra'. *IOP Conference Series: Earth and Environmental Science*, 454(1), p. 012156. DOI: 10.1088/1755-1315/454/1/012156.
- Tiralla, N., Panferov, O. and Knohl, A. (2013) 'Allometric Relationships of Frequently Used Shade Tree Species in Cacao Agroforestry Systems in Sulawesi, Indonesia'. *Agroforestry Systems*, 87(4), pp. 857–870. DOI: 10.1007/s10457-013-9602-4.
- Udarno, L., Setiyono, R.T. and Tjahjana, B.E. (2019) 'Penampilan Morfologis Kemiri Di Kebun Koleksi Bogor'. In Balai Penelitian Tanaman Industri dan Penyegar (ed.) *Kemiri Sunan Penghasil Biodiesel*. Unit Penerbitan Dan Publikasi . Available at: <https://repository.pertanian.go.id/handle/123456789/15834> (Accessed: 17 September 2023).
- USDA, N. (2024) *The PLANTS Database*. National Plant Data Team, Greensboro, NC USA. Available at: <http://plants.usda.gov> (Accessed: 30 May 2024).
- Wang, W. *et al.* (2020) 'A Novel Image Classification Approach via Dense-MobileNet Models'. *Mobile Information Systems*, 2020, p. 7602384. DOI: 10.1155/2020/7602384.
- Wang, Y. *et al.* (2020) 'The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition'. *Applied Sciences*, 10(5). DOI: 10.3390/app10051897.

- Wei, O.C. and Razak, S.B.A. (2021a) 'Rubber Tree Cultivation and Improvement in Malaysia: Anatomical and Morphological Studies on Hevea Brasiliensis and Hevea Camargoana'. *Journal of Agriculture and Crops*, 7, pp. 27–32.
- Wei, O.C. and Razak, S.B.A. (2021b) 'Rubber Tree Cultivation and Improvement in Malaysia: Anatomical and Morphological Studies on Hevea Brasiliensis and Hevea Camargoana'. *Journal of Agriculture and Crops*, 7(1), pp. 27–32.
- Yunianti, A.D. *et al.* (2020) *Buku Ajar Ilmu Kayu*. I. Makassar: Fakultas Kehutanan Universitas Hasanuddin.
- Yuniastuti, E., Nandariyah, N. and Bukka, S.R. (2018) 'Karakterisasi Durian (Durio Zibenthinus) Ngrambe Di Jawa Timur, Indonesia'. *Caraka Tani: Journal of Sustainable Agriculture*, 33(2), p. 136. DOI: 10.20961/carakatani.v33i2.19610.
- Zhao, H. *et al.* (2019) 'Research on a Learning Rate with Energy Index in Deep Learning'. *Neural Networks*, 110, pp. 225–231. DOI: 10.1016/j.neunet.2018.12.009.