

**PENGEMBANGAN APLIKASI *MOBILE* PEMINDAI *REAL-TIME* UNTUK
IDENTIFIKASI KERAPATAN DAN TRANSPARANSI TAJUK POHON
MENGUNAKAN YOLOV10**

(Skripsi)

Oleh

**ALKHADAFI SADDAM SIMPARICO
2117051049**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2026**

ABSTRAK

PENGEMBANGAN APLIKASI *MOBILE* PEMINDAI *REAL-TIME* UNTUK IDENTIFIKASI KERAPATAN DAN TRANSPARANSI TAJUK POHON MENGGUNAKAN YOLOV10

Oleh

ALKHADAFI SADDAM SIMPARICO

Pemantauan kesehatan hutan selama ini memiliki keterbatasan pada metode pengukuran yang masih dilakukan secara manual yang menggunakan kartu skala atau *magic card* sehingga kurang efisien hasil pengukuran masih bersifat subjektif. Penelitian ini bertujuan mengembangkan aplikasi *mobile* pemindai *real-time* untuk mengidentifikasi kerapatan dan transparansi tajuk pohon daun jarum dan daun lebar berdasarkan metode *Forest Health Monitoring* menggunakan YOLOv10. Metode penelitian meliputi pengumpulan dataset sebanyak 5.000 citra, *preprocessing* melalui augmentasi data, pelatihan model, hingga konversi ke format *TensorFlow Lite* untuk implementasi pada perangkat *Android*. Data yang digunakan mencakup pengambilan citra tajuk dari sepuluh jenis pohon yang terdiri dari lima jenis daun jarum yaitu Cemara Norfolk (*Araucaria heterophylla*), Cemara Bundel (*Cupressus retusa*), Pinus Sumatra (*Pinus merkusii*), Damar Mata-Kucing (*Anthoshorea javanica*), dan Damar Biasa (*Agathis dammara*) serta lima jenis daun lebar yaitu Cokelat (*Theobroma cacao*), Durian (*Durio zibethinus*), Karet (*Havea brasiliensis*), Kemiri (*Aleurites moluccana*), dan Sonokeling (*Dalbergia latifolia*). Hasil pengujian aplikasi di lapangan menghasilkan hasil prediksi yang cukup baik serta hasil dari *User Acceptance Testing* (UAT) memperoleh nilai rata-rata 80.40%, yang mendukung simpulan bahwa aplikasi ini layak digunakan sebagai alat bantu digital yang efisien dan praktis bagi praktisi kehutanan di lapangan.

Kata Kunci: YOLOv10, *Deep Learning*, *Forest Health Monitoring*, Tajuk Pohon, Aplikasi *Mobile*

ABSTRACT

DEVELOPMENT OF A REAL-TIME MOBILE SCANNING APPLICATION FOR IDENTIFYING TREE CANOPY DENSITY AND TRANSPARENCY USING YOLOV10

By

ALKHADAFI SADDAM SIMPARICO

Forest health monitoring currently faces limitations due to measurement methods that are still performed manually using scale cards or magic cards, resulting in inefficiency and subjective outcomes. This study aims to develop a real-time mobile scanning application to identify canopy density and transparency of coniferous and broadleaf trees based on the Forest Health Monitoring method using the YOLOv10 algorithm. The research methodology includes dataset collection consisting of 5.000 images, preprocessing through data augmentation, model training, and conversion into TensorFlow Lite format for implementation on Android devices. The data used consist of canopy images from ten tree species, including five coniferous species Norfolk Island Pine (*Araucaria heterophylla*), Bundled Cypress (*Cupressus retusa*), Sumatran Pine (*Pinus merkusii*), Javanese Dammar (*Anthoshorea javanica*), and Common Dammar (*Agathis dammara*) and five broadleaf species: Cacao (*Theobroma cacao*), Durian (*Durio zibethinus*), Rubber Tree (*Hevea brasiliensis*), Candlenut (*Aleurites moluccana*), and Sonokeling (*Dalbergia latifolia*). The field testing results show that the application achieves satisfactory prediction performance. Furthermore, the User Acceptance Testing (UAT) yielded an average score of 80.40%, supporting the conclusion that this application is feasible to be used as an efficient and practical digital tool for forestry practitioners in the field.

Keywords: YOLOv10, Deep Learning, Forest Health Monitoring, Tree Crown, Mobile Application

**PENGEMBANGAN APLIKASI *MOBILE* PEMINDAI *REAL-TIME* UNTUK
IDENTIFIKASI KERAPATAN DAN TRANSPARANSI TAJUK POHON
MENGUNAKAN YOLOV10**

Oleh

**ALKHADAFI SADDAM SIMPARICO
2117051049**

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

Pada

Jurusan Ilmu Komputer

Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2026**

Judul Skripsi

**: PENGEMBANGAN APLIKASI MOBILE
PEMINDAI REAL-TIME UNTUK
IDENTIFIKASI KERAPATAN DAN
TRANSPARANSI TAJUK POHON
MENGUNAKAN YOLOV10**

Nama Mahasiswa

: Alkhadafi Saddam Simparico

Nomor Pokok Mahasiswa

: 2117051049

Program Studi


: S1 Ilmu Komputer

Jurusan

: Ilmu Komputer

Fakultas

: Matematika dan Ilmu Pengetahuan Alam



MENYETUJUI

Komisi Pembimbing

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

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

MENGETAHUI

Ketua Jurusan Ilmu Komputer

**Ketua Program Studi S1 Ilmu
Komputer**

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

Tristiyanto, M.I.S., Ph.D.
NIP. 19810414 200501 1 001


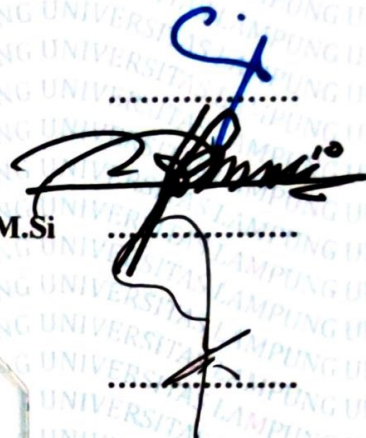
MENGESAHKAN

1. Tim Penguji

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

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

Penguji Utama : Prof. Eng. Admi Syarif, 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: 11 Februari 2026

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Alkhadafi Saddam Simparico

NPM : 2117051049

Dengan ini menyatakan bahwa skripsi saya yang berjudul **“Pengembangan Aplikasi *Mobile* Pemindai *Real-Time* untuk Identifikasi Kerapatan dan Transparansi Tajuk Pohon Menggunakan YOLOv10”** merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya tulis ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil jiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang saya terima.

Bandar Lampung, 15 April 2026

Penulis,



Alkhadafi Saddam Simparico
NPM. 2117051049

RIWAYAT HIDUP



Penulis dilahirkan di Kota Bandar Lampung pada 29 Maret 2003, putra pertama dari tiga bersaudara pasangan Bapak Yovi Simparico dan Ibu Sundarti. Perjalanan akademis dimulai dari SD Negeri 2 Rawa Laut yang dituntaskan pada Tahun 2015, disusul SMP Negeri 23 Bandar Lampung pada Tahun 2018, hingga SMA Negeri 2 Bandar Lampung pada tahun 2021.

Dedikasi intelektual penulis berlanjut pada Tahun 2021 saat terpilih sebagai mahasiswa Program Studi S1 Ilmu Komputer Universitas Lampung melalui jalur kompetitif SBMPTN. Selama masa studi penulis mengintegrasikan ketajaman akademik dengan pengembangan diri transformatif melalui berbagai pengalaman kontributif berikut ini:

1. Sebagai anggota divisi Sains Pengabdian Masyarakat (SPM) Badan Eksekutif Mahasiswa (BEM) Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung Periode 2021/2022.
2. Sebagai anggota divisi Kaderisasi Himpunan Mahasiswa Ilmu Komputer (HIMAKOM) Universitas Lampung Periode 2021/2022.
3. Sebagai Asisten Dosen mata kuliah Pemrograman Interpreter Jurusan Ilmu Komputer Universitas Lampung Periode 2022/2023.
4. Melaksanakan Kerja Praktik pada bulan Januari 2024 di SMA Negeri 2 Bandar Lampung.
5. Melaksanakan Kuliah Kerja Nyata (KKN) di Desa Waringin Jaya Kecamatan Bandar Sribhawono Kabupaten Lampung Timur pada tahun 2024.

PERSEMBAHAN

Dengan penuh ketundukan dan rasa syukur yang mendalam, segala puji saya haturkan ke hadirat Allah Subhanahu wa Ta'ala atas limpahan rahmat, karunia, dan inayah-Nya yang tiada bertepi. Shalawat serta salam semoga senantiasa terlimpah ruah kepada junjungan alam, Nabi Muhammad Shallallahu 'Alaihi wa Sallam, suri teladan sepanjang zaman yang melalui cahaya petunjuknya saya diberi kekuatan, keteguhan dan kelapangan hati hingga akhirnya mampu menuntaskan penulisan skripsi ini.

Skripsi ini saya persembahkan kepada:

Keluarga tercinta dan seluruh rekan seperjalanan yang senantiasa kebersamai setiap langkah, menghadirkan doa, dukungan serta penguatan dalam setiap fase penyusunan karya ini, saya haturkan rasa terima kasih yang setulus-tulusnya. Apresiasi yang mendalam juga saya persembahkan kepada diri saya sendiri atas keteguhan, kesabaran dan ikhtiar yang tak surut hingga berhasil menuntaskan pendidikan pada Program Studi S1 Ilmu Komputer Universitas Lampung sebagai sebuah capaian yang sarat makna dan perjuangan.

MOTTO

“Jika kamu tidak sanggup menahan lelahnya belajar, maka kamu harus sanggup menahan perihnya kebodohan.”

- Imam Syafi’i

“Apabila takdir telah tiba, maka lenyaplah semua rencana.”

- Mahfuzhat

“It’s okay to be scared. We just have to do it anyway.”

- Missy Cooper

“We can’t change what’s done, we can only move on.”

- Arthur Morgan

SANWACANA

Dengan memohon ridha dan pertolongan Allah Subhanahu wa Ta'ala, penulis memanjatkan puji syukur yang sedalam-dalamnya atas limpahan rahmat, taufik, dan hidayah-Nya, sehingga skripsi ini dapat diselesaikan dengan baik dan tepat pada waktunya. Shalawat serta salam semoga senantiasa tercurah kepada junjungan umat, Nabi Muhammad Shallallahu 'alaihi wa sallam, teladan agung sepanjang zaman, yang syafaatnya senantiasa penulis harapkan di yaumul akhir kelak.

Skripsi yang berjudul “Pengembangan Aplikasi *Mobile* Pemindai *Real-Time* untuk Identifikasi Kerapatan dan Transparansi Tajuk Pohon Menggunakan YOLOv10” ini disusun sebagai salah satu prasyarat akademik guna memperoleh gelar Sarjana pada Program Studi S1 Ilmu Komputer, Universitas Lampung.

Pada kesempatan yang penuh rasa syukur ini, penulis menyampaikan penghargaan dan terima kasih yang setinggi-tingginya kepada seluruh pihak yang telah memberikan dukungan, bimbingan, arahan, serta kontribusi pemikiran dalam proses penyusunan skripsi ini, yakni:

1. Allah Subhanahu wa Ta'ala, atas segala limpahan rahmat, taufik, hidayah serta kekuatan lahir dan batin yang senantiasa menyertai setiap langkah penulis hingga karya ilmiah ini dapat terselesaikan.
2. Kedua orang tua tercinta, beserta dua saudara penulis, yang senantiasa menjadi sumber doa, kasih sayang, pengorbanan dan sandaran moral dalam setiap fase perjalanan pendidikan ini.
3. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung atas kepemimpinan dan dukungan akademik yang diberikan.

4. Bapak Dwi Sakethi, S.Si., M.Kom., selaku Ketua Jurusan Ilmu Komputer Universitas Lampung atas arahan dan dedikasi dalam pengembangan akademik di lingkungan jurusan.
5. Ibu Yunda Heningtyas, M.Kom., selaku Sekretaris Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung atas perhatian dan dukungan administratif yang diberikan selama masa studi.
6. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D., selaku Ketua Program Studi S1 Ilmu Komputer Universitas Lampung sekaligus Dosen Pembimbing Akademik penulis atas bimbingan, nasihat, dan motivasi yang diberikan sejak awal perkuliahan hingga tahap akhir penyusunan skripsi.
7. Bapak Rico Andrian, S.Si., M.Kom., selaku Dosen Pembimbing Utama, atas waktu, ilmu, ketelitian serta arahan konstruktif yang sangat berarti dalam proses penelitian dan penulisan skripsi ini.
8. Bapak Prof. Dr. Rahmat Safe'i, S.Hut., M.Si., selaku Dosen Pembimbing Pembantu, atas masukan ilmiah, perspektif akademik dan dukungan yang memperkaya substansi penelitian ini.
9. Bapak Prof. Eng. Admi Syarif, Ph.D., selaku Dosen Penguji, atas kesediaan waktu, ketelitian serta kontribusi pemikiran yang tajam dan konstruktif dalam memberikan evaluasi, kritik, dan saran yang sangat berharga demi penyempurnaan skripsi ini.
10. Seluruh Bapak dan Ibu Dosen Ilmu Komputer Universitas Lampung, atas dedikasi dalam mentransformasikan ilmu, nilai, dan wawasan selama masa pendidikan penulis.
11. Ibu Ade Nora Maela dan seluruh staf Jurusan Ilmu Komputer, yang dengan penuh kesabaran dan ketelitian telah membantu berbagai urusan administrasi selama masa perkuliahan.
12. Sahabat dan teman-teman terdekat, yang senantiasa menghadirkan semangat, dukungan emosional serta kebersamaan yang menguatkan dalam setiap proses.

13. Keluarga besar Ilmu Komputer Universitas Lampung angkatan 2021, sebagai ruang tumbuh, belajar dan berproses bersama dalam dinamika akademik maupun non-akademik.

Sebagai penutup penulis menyadari sepenuhnya bahwa dalam penyusunan karya ini masih terdapat berbagai keterbatasan dan kekurangan. Bisa jadi terdapat uraian yang belum sepenuhnya merepresentasikan hakikat yang sebenarnya, mungkin pula hal-hal yang esensial luput tersampaikan, sementara bagian yang kurang mendasar justru terpapar lebih panjang. Tidak tertutup kemungkinan masih banyak aspek yang sepatutnya dimuat namun belum terakomodasi dalam tulisan ini.

Oleh karena itu dengan segala kerendahan hati, penulis memohon kesediaan para pembaca yang budiman untuk berkenan memberikan kritik, saran, dan tinjauan yang membangun, sebagai ikhtiar penyempurnaan di masa mendatang.

Akhirnya penulis akan merasa memperoleh suatu kehormatan yang teramat besar apabila karya yang sederhana ini dapat dipandang sebagai setitik embun di waktu pagi, kecil adanya, namun semoga tetap menghadirkan kesegaran dan kemanfaatan bagi siapa pun yang membacanya.

Bandar Lampung, 15 April 2026
Penulis,

Alkhadafi Saddam Simparico
NPM. 2117051049

DAFTAR ISI

	Halaman
DAFTAR ISI	vi
DAFTAR GAMBAR	viii
DAFTAR TABEL	x
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	10
1.3 Batasan Masalah	10
1.4 Tujuan	10
1.5 Manfaat	11
II. TINJAUAN PUSTAKA	12
2.1 Hutan.....	12
2.2 Aplikasi <i>Mobile</i>	29
2.3 Pemindai <i>Real-Time</i>	29
2.4 <i>Application Programming Interface (API)</i>	30
2.5 <i>Python</i>	31
2.6 <i>Tensorflow Lite</i>	31
2.7 <i>Kotlin</i>	32
2.8 Pengujian Perangkat Lunak	32
2.9 <i>User Acceptance Testing (UAT)</i>	33
2.10 Skala <i>Likert</i>	33
2.11 <i>Deep Learning</i>	33
2.12 YOLOv10.....	40

2.13 <i>Preprocessing Data</i>	41
2.14 <i>Hyperparameter</i>	43
2.15 <i>Confusion Matrix</i>	46
III. METODE PENELITIAN	49
3.1 Waktu dan Tempat	49
3.2 Alat dan Bahan.....	50
3.3 Metode Penelitian	51
3.4 <i>Model Deploy</i>	55
IV. HASIL DAN PEMBAHASAN	63
4.1 Hasil	63
4.2 Pembahasan.....	63
4.3 Pelatihan dan Evaluasi pada Model YOLOv10	65
4.4 Konversi Model YOLOv10 kedalam Format <i>TensorFlow Lite</i>	81
4.5 Kinerja YOLOv10 pada Aplikasi <i>Mobile</i>	82
4.6 Pengujian Sistem.....	83
V. SIMPULAN DAN SARAN	86
5.1 Simpulan	86
5.2 Saran.....	86
DAFTAR PUSTAKA	88

DAFTAR GAMBAR

Gambar	Halaman
1. Kartu Skala Kerapatan dan Transparansi Tajuk (US Forest Service, 2023)...	17
2. Tajuk Pohon Cemara Norfolk (<i>Araucaria heterophylla</i>).....	19
3. Tajuk Pohon Cemara Bundel (<i>Cupressus retusa</i>).....	20
4. Tajuk Pohon Pinus Sumatra (<i>Pinus merkusii</i>).	21
5. Tajuk Pohon Damar Mata-Kucing (<i>Anthoshorea javanica</i>).....	22
6. Tajuk Pohon Damar Biasa (<i>Agathis dammara</i>).	23
7. Tajuk Pohon Cokelat (<i>Theobroma cacao</i>).	24
8. Tajuk Pohon Durian (<i>Durio zibethinus</i>).....	25
9. Tajuk Pohon Karet (<i>Havea brasiliensis</i>).....	26
10. Tajuk Pohon Kemiri (<i>Aleurites moluccana</i>).	27
11. Tajuk Pohon Sonokeling (<i>Dalbergia latifolia</i>).	28
12. Perbedaan antara <i>Machine Learning</i> dan <i>Deep Learning</i> (Alzubaidi <i>et al.</i> , 2021).	35
13. Arsitektur CNN (Zhu & Chen, 2023).	36
14. Grafik representasi ReLU (Wao & Soni, 2021).....	39
15. Arsitektur YOLOv10 (Sapkota <i>et al.</i> , 2024).....	40
16. Metode Penelitian (M. de A. Carvalho <i>et al.</i> , 2022).....	51
17. Proses <i>Labelling Data</i>	53
18. Tampilan <i>Register</i>	57
19. Tampilan <i>Login</i>	57
20. Tampilan <i>Forgot Password</i>	58
21. Tombol <i>Logout</i>	59
22. Tampilan <i>Detector</i>	59
23. Tombol <i>Export</i>	60

24. Tampilan <i>Gallery</i>	60
25. Tampilan FAQ.....	61
26. Tampilan <i>About</i>	61
27. <i>Confusion Matrix</i> pada Pelatihan Pertama.....	66
28. <i>Confusion Matrix</i> pada Pelatihan Kedua.....	68
29. <i>Confusion Matrix</i> pada Pelatihan Ketiga.....	70
30. <i>Confusion Matrix</i> pada Pelatihan Keempat.....	72
31. <i>Confusion Matrix</i> pada Pelatihan Kelima.....	74
32. <i>Confusion Matrix</i> pada Pelatihan Keenam.....	76
33. <i>Confusion Matrix</i> pada Pelatihan Ketujuh.....	78
34. <i>Confusion Matrix</i> pada Pelatihan Kedelapan.....	80
35. Contoh beberapa <i>Output</i> dari Prediksi Model pada Aplikasi <i>Mobile</i>	82

DAFTAR TABEL

Tabel	Halaman
1. Nilai matriks utama dari <i>Confusion Matrix</i>	46
2. Jadwal Penelitian.....	49
3. Tabel <i>Hyperparameter</i>	54
4. Tabel Kebutuhan Fitur	55
5. Tabel <i>Hyperparameter</i> pada Pelatihan Pertama	65
6. <i>Accuracy, Precision, Recall, dan F1-score</i> pada Pelatihan Pertama	67
7. Tabel <i>Hyperparameter</i> pada Pelatihan Kedua	67
8. <i>Accuracy, Precision, Recall, dan F1-score</i> pada Pelatihan Kedua	69
9. Tabel <i>Hyperparameter</i> pada Pelatihan Ketiga.....	69
10. <i>Accuracy, Precision, Recall, dan F1-score</i> pada Pelatihan Ketiga.....	71
11. Tabel <i>Hyperparameter</i> pada Pelatihan Keempat	71
12. <i>Accuracy, Precision, Recall, dan F1-score</i> pada Pelatihan Keempat.....	73
13. Tabel <i>Hyperparameter</i> pada Pelatihan Kelima.....	73
14. <i>Accuracy, Precision, Recall, dan F1-score</i> pada Pelatihan Kelima.....	75
15. Tabel <i>Hyperparameter</i> pada Pelatihan Keenam	75
16. <i>Accuracy, Precision, Recall, dan F1-score</i> pada Pelatihan Keenam	77
17. Tabel <i>Hyperparameter</i> pada Pelatihan Ketujuh.....	77
18. <i>Accuracy, Precision, Recall, dan F1-score</i> pada Pelatihan Ketujuh	79
19. Tabel <i>Hyperparameter</i> pada Pelatihan Kedelapan	79
20. <i>Accuracy, Precision, Recall, dan F1-score</i> pada Pelatihan Kedelapan	81
21. Kinerja Prediksi Model	83
22. Hasil Pengujian	84

I. PENDAHULUAN

1.1 Latar Belakang

Penilaian kondisi tajuk pohon salah satu komponen penting dalam *monitoring* kesehatan hutan karena tajuk mencerminkan respons fisiologis pohon terhadap perubahan lingkungan. *Forest Health Monitoring* (FHM) merupakan pendekatan untuk menilai kesehatan hutan yang didasarkan pada empat indikator utama, salah satunya adalah vitalitas. Indikator vitalitas dicirikan oleh dua parameter, yaitu tingkat kerusakan pohon dan kondisi tajuk. Penilaian kondisi tajuk dicirikan oleh *Visual Crown Ratio* (VCR) yang terdiri atas lima parameter, dua parameter yang menjadi fokus penelitian adalah kerapatan tajuk dan transparansi tajuk. Kerapatan tajuk dan transparansi tajuk merupakan salah dua parameter yang menggambarkan kemampuan pohon dalam melakukan fotosintesis, mempertahankan struktur tajuk, serta menunjukkan tingkat stres atau gangguan eksternal. Pemantauan kedua parameter tersebut memberikan informasi awal mengenai perubahan kondisi fisiologis pohon dan dinamika kesehatan hutan secara keseluruhan (Zarnoch *et al.*, 2004).

Sebagian besar penelitian terkait kesehatan hutan berbasis *deep learning* masih berfokus pada tahap pengembangan dan evaluasi model secara eksperimental, seperti peningkatan akurasi klasifikasi tanpa diarahkan pada penerapan model tersebut dalam praktik pemantauan lapangan secara langsung. Penelitian yang mengintegrasikan model *deep learning* ke dalam aplikasi *mobile* yang dapat digunakan secara *real-time* di lapangan untuk mengidentifikasi kerapatan dan transparansi tajuk pohon masih terbatas. Kondisi tersebut menunjukkan adanya kesenjangan antara pengembangan model secara teoretis dan kebutuhan

operasional *monitoring* kesehatan hutan di lapangan. Penelitian ini mengambil langkah untuk mengembangkan dan mengimplementasikan model *deep learning* ke dalam aplikasi *mobile* guna mendukung identifikasi kerapatan dan transparansi tajuk pohon secara *real-time*, sehingga diharapkan dapat membantu petugas dalam melakukan *monitoring* kesehatan hutan secara lebih efisien, praktis, dan aplikatif.

Urgensi pengembangan aplikasi *mobile* untuk mengukur kerapatan dan transparansi tajuk pohon secara *real-time* muncul dari keterbatasan metode pemantauan kesehatan hutan yang hingga saat ini masih banyak dilakukan secara manual di lapangan. Penilaian kondisi tajuk pohon melalui observasi visual langsung memerlukan waktu relatif lama, penggunaan alat bantu tertentu, serta sangat bergantung pada kondisi medan dan cuaca, sehingga kurang efektif untuk diterapkan pada areal hutan yang luas atau sulit dijangkau. Kondisi tersebut berdampak pada rendahnya frekuensi pemantauan serta keterlambatan dalam mendeteksi perubahan kondisi tajuk pohon (Fassnacht *et al.*, 2024). Pengembangan aplikasi *mobile* berbasis *deep learning* diharapkan menjadi solusi yang relevan untuk mendukung identifikasi kerapatan dan transparansi tajuk pohon secara efisien dan aplikatif di lapangan.

Indikator kesehatan hutan mencakup beberapa aspek penting yang menentukan keberlanjutan ekosistem hutan dan parameter yang digunakan meliputi produktivitas, vitalitas, kualitas tapak, serta biodiversitas (Safe'i, 2018). Vitalitas merupakan salah satu indikator yang digunakan untuk menilai kesehatan hutan yang dicirikan oleh dua parameter yaitu tingkat kerusakan pohon serta kondisi tajuk pohon (Safe'i *et al.*, 2021). Kondisi tajuk dinilai berdasarkan *Visual Crown Ratio* (VCR) yang mana VCR adalah rasio panjang tajuk hidup terhadap tinggi total pohon, yang diestimasi secara visual di lapangan (Schomaker *et al.*, 2007). Nilai VCR diperoleh berdasarkan lima parameter yaitu kerapatan tajuk, transparansi tajuk, diameter tajuk, *Live Crown Ratio* (LCR), dan *Crown Dieback* (Safe'i *et al.*, 2021).

Pemeriksaan kondisi hutan yang umum dilakukan adalah dengan pemantauan tajuk pohon (Meng *et al.*, 2016). Tajuk pohon adalah struktural yang menyusun

komponen tumbuhan (Ramadhani, 2023). Kerapatan dan transparansi tajuk merupakan parameter kunci dalam evaluasi kesehatan hutan, di mana hutan dikatakan sehat apabila kerapatan tajuknya mencapai atau melebihi 55% dan tingkat transparansinya berada di antara 0 hingga 45% (Dan & Iskandar, 2018). Kerapatan tajuk mencerminkan kepadatan vegetasi di suatu area, yang berhubungan langsung dengan potensi hutan dalam menyerap karbon dioksida (Xu *et al.*, 2018), sementara transparansi tajuk dapat menjadi petunjuk adanya kerusakan akibat gangguan eksternal, seperti penebangan liar, penyakit pohon, atau perubahan iklim (Eilmann *et al.*, 2013). Pengukuran ini penting untuk memantau dinamika ekosistem hutan, termasuk kapasitas hutan dalam menyerap karbon dan mendukung kehidupan berbagai spesies (Yan *et al.*, 2025). Keberlanjutan lingkungan melalui konservasi hutan dan pemantauan tajuk pohon bukan hanya masalah lokal, tetapi juga merupakan strategi global dalam menghadapi krisis iklim (Gessler *et al.*, 2022). Permasalahan yang terkadang dialami saat pemantauan tajuk pohon adalah hasil pengamatan kurang efektif karena masih mengandalkan pengamatan visual dan membandingkannya dengan kartu skala secara manual (Tarigan *et al.*, 2023). Pengamatan secara manual ini sering kali tidak efisien dan rawan kesalahan manusia. Solusi yang dapat ditawarkan adalah dengan menggunakan teknologi pemrosesan citra yang menggunakan kecerdasan buatan yang dapat menawarkan solusi yang lebih cepat, akurat, dan efisien.

Pemrosesan citra digital mencakup berbagai macam algoritma yang dapat diaplikasikan untuk berbagai keperluan, salah satunya adalah YOLO (*You Only Look Once*). Algoritma ini telah menjadi salah satu metode paling populer dalam deteksi objek berkat kemampuannya yang sangat efisien dan cepat. YOLO merupakan algoritma yang cocok diterapkan pada sistem deteksi objek berbasis *real-time*, di mana keunggulan utamanya terletak pada kemampuannya untuk mendeteksi banyak objek dalam satu gambar hanya dengan satu kali proses pemindaian. Pendekatan ini sangat berbeda dari metode tradisional yang memerlukan pemindaian berulang, yang umumnya membutuhkan lebih banyak waktu dan sumber daya komputasi (Gao *et al.*, 2024). Perkembangan YOLO terus disempurnakan, dan versi terbarunya, YOLOv10, dirilis oleh *Ultralytics* pada pertengahan tahun 2024. Versi terbaru ini menawarkan peningkatan signifikan

dalam hal akurasi, kecepatan deteksi, dan efisiensi dibandingkan versi sebelumnya. YOLOv10 menggunakan arsitektur jaringan saraf yang lebih canggih dan strategi pelatihan yang lebih optimal, sehingga mampu mengatasi berbagai tantangan dalam deteksi objek, seperti variasi skala, perubahan pencahayaan, dan objek yang saling tumpang tindih (da Silva *et al.*, 2024). Versi terbaru ini telah dilengkapi dengan peningkatan kemampuan untuk mendeteksi objek dengan presisi yang lebih tinggi dalam lingkungan yang lebih kompleks.

Perkembangan teknologi *mobile* semakin pesat yang membuat integrasi algoritma canggih yang sebelumnya hanya dapat dijalankan pada perangkat komputasi besar kini semakin dimungkinkan pada perangkat seluler. *TensorFlow Lite* merupakan *library* yang dirancang khusus untuk mengimplementasikan model pembelajaran mesin pada perangkat seluler, mikrokontroler, dan berbagai perangkat lainnya (Muncie, 2024). Model yang diinginkan dapat dilatih sebelumnya di *cloud* atau di tempat untuk berbagai tugas seperti klasifikasi gambar dan deteksi objek, kemudian diubah menjadi format *TensorFlow Lite* yang lebih kecil dan efisien. Langkah-langkah untuk melakukan inferensi melibatkan inisialisasi interpreter, memuat model, alokasi tensor, praproses input, dan eksekusi inferensi untuk menghasilkan output yang diinginkan, membuatnya ideal untuk perangkat dengan sumber daya terbatas (Nguyen, 2022). Kehadiran *framework* seperti *TensorFlow Lite* telah membuka peluang yang signifikan dalam membawa kecerdasan buatan dan model pembelajaran mesin ke dalam genggamannya sehari-hari. *TensorFlow Lite* memungkinkan optimasi model-model yang kompleks, seperti YOLOv10, sehingga dapat dijalankan secara efisien pada perangkat *mobile* yang memiliki keterbatasan sumber daya komputasi, seperti memori dan daya pemrosesan. Keunggulan utama dari *TensorFlow Lite* adalah kemampuannya untuk mengonversi model YOLOv10 menjadi versi yang lebih ringan dan cepat, tanpa mengorbankan akurasi deteksi objek sehingga perangkat *mobile* dapat menjalankan deteksi objek secara *real-time* di lingkungan lokal, tanpa memerlukan koneksi internet atau server eksternal. Hal ini tidak hanya meningkatkan efisiensi, tetapi juga mempercepat proses pengambilan keputusan, mengurangi latensi, dan mengurangi ketergantungan pada infrastruktur jaringan (Gandadipoera *et al.*, 2024). Pemanfaatan model YOLOv10 pada platform *mobile* juga memberikan

peluang besar bagi pengembang untuk merancang aplikasi yang lebih mandiri, hemat energi, dan lebih mudah diakses oleh masyarakat luas, tanpa terbatas pada kemampuan perangkat keras yang mahal.

Pemanfaatan teknologi *deep learning* dalam bidang kehutanan terus berkembang, terutama dalam mendukung kegiatan *monitoring* kesehatan hutan secara lebih cepat dan otomatis. Berbagai penelitian terdahulu menunjukkan bahwa model *deep learning* berbasis citra mampu memberikan kontribusi dalam mendukung upaya menjaga Kesehatan hutan. Pendekatan ini relevan dengan upaya *monitoring* kesehatan hutan, karena kondisi tajuk, struktur vegetasi, dan karakteristik pohon, serta gejala kerusakan pohon dapat diamati melalui citra visual dan dianalisis secara otomatis menggunakan model *deep learning* (Ecke *et al.*, 2024). Penelitian-penelitian terdahulu yang memanfaatkan teknologi *deep learning* dan aplikasi *mobile* menjadi dasar penting dalam pengembangan sistem *monitoring* kesehatan hutan berbasis teknologi digital.

Penelitian terdahulu oleh (Yao *et al.*, 2024) berfokus pada penerapan model *deep learning* berbasis CNN, yaitu *Mask R-CNN*, untuk mendeteksi tajuk pohon individu dan mengklasifikasikan pohon hidup serta mati sebagai indikator vitalitas hutan. Model dilatih menggunakan dataset beranotasi yang terdiri atas 21800 pohon hidup dan 7157 pohon mati dengan skema *five-fold cross-validation*. Hasil penelitian menunjukkan bahwa kombinasi citra RGB menghasilkan performa terbaik dengan nilai *F1 score* sebesar 74,18% dan *Intersection over Union* (IoU) sebesar 69,80% untuk deteksi simultan pohon hidup dan mati, Penelitian ini menunjukkan efektivitas pendekatan CNN berbasis citra visual dalam mendukung pemantauan kesehatan hutan secara otomatis.

Penelitian lain oleh (Zhao *et al.*, 2023) penggunaan CNN untuk deteksi dan delineasi *individual tree crown* (ITC) dari citra visual sebagai bagian dari monitoring kondisi hutan, penelitian ini mengulas 35 studi yang relevan dan mengidentifikasi tren utama serta tantangan metodologis dalam aplikasi CNN pada tugas tersebut. Penelitian ini melaporkan bahwa model CNN menunjukkan peningkatan akurasi deteksi tajuk pohon dibandingkan teknik analisis citra

tradisional, dengan sejumlah studi yang menemukan peningkatan akurasi lebih dari 11-16% dalam metrik seperti *F1-score* dan *precision* ketika CNN dibandingkan dengan pendekatan klasik seperti *edge detection* atau *local maximum filtering* untuk deteksi tajuk pohon.

Penelitian lain oleh (Yang *et al.*, 2024) mengembangkan model berbasis *machine learning* untuk memprediksi kematian individu pohon jenis *Larix gmelinii var. principis-rupprechtii* di hutan dataran berkisar menggunakan beberapa algoritma. *Dataset* mencakup variabel struktural dan lingkungan pohon tunggal. Model terbaik menunjukkan akurasi sekitar 92.91% pada prediksi kematian pohon. Penelitian ini menunjukkan bahwa pendekatan *machine learning* dapat diterapkan secara efektif untuk deteksi risiko kematian pohon di level individu, mendukung kegiatan pemantauan kesehatan hutan secara lebih proaktif.

Penelitian lain oleh (Recchia *et al.*, 2024) mengembangkan metode AVALON, yaitu sebuah arsitektur *Convolutional Neural Network* (CNN) yang dilengkapi mekanisme *attention* untuk mendeteksi area kematian pohon yang disebabkan oleh serangan hama (*bark beetle*) pada citra Sentinel-2, sebagai bagian dari inventaris gangguan kesehatan hutan. Pendekatan ini mengubah setiap piksel citra menjadi representasi visual berdasarkan lingkungan piksel di sekitarnya dan melatih CNN dengan *attention* untuk memilih informasi spektral paling bermakna, sehingga model dapat membedakan antara tajuk sehat dan rusak secara lebih akurat. Evaluasi pada dua studi kasus di *Northeast France* dan Republik Ceko menunjukkan bahwa model AVALON mengungguli metode pembanding lain dalam semua metrik akurasi yang diuji, serta *attention map* yang dihasilkan memberikan wawasan visual yang dapat membantu ahli kehutanan dalam menginterpretasi keputusan model dan mengidentifikasi kemungkinan kesalahan klasifikasi. Temuan ini menunjukkan bahwa integrasi perhatian (*attention*) dalam CNN mampu meningkatkan performa deteksi kematian pohon berbasis citra, sehingga mendukung potensi aplikasi deep learning untuk *forest health monitoring*.

Penelitian lain oleh (Schratz *et al.*, 2021) berfokus pada pemantauan kesehatan hutan melalui citra hiperspektral dengan menganalisis pengaruh *feature selection*

terhadap performa algoritma *machine learning*. Studi dilakukan di wilayah hutan Spanyol Utara untuk memprediksi tingkat *defoliation* (kehilangan daun) pada pohon. Beberapa algoritma yang diuji meliputi *Support Vector Machine* (SVM), *Random Forest* (RF), XGBoost, Lasso, dan *Ridge Regression* menggunakan data reflektansi pada berbagai panjang gelombang. Hasil menunjukkan bahwa SVM menghasilkan akurasi tertinggi, sekitar 3.00% lebih baik dibandingkan model lainnya, sedangkan teknik *feature selection* berbasis filter hanya memberikan peningkatan performa kecil dan tidak selalu konsisten. Penelitian ini menegaskan bahwa penggunaan citra hiperspektral dengan algoritma *machine learning* dapat secara efektif mengidentifikasi kondisi vitalitas hutan melalui deteksi dini gejala *defoliation*.

Penelitian lain oleh (Tao *et al.*, 2025) mengusulkan algoritma ringan berbasis YOLOv11 yang dioptimalkan untuk pemantauan kebakaran hutan secara *real-time* dengan menggunakan citra visual. Penelitian ini menekankan pentingnya mendeteksi dan mengevaluasi kebakaran hutan secara cepat untuk mendukung tindakan mitigasi, dan mengembangkan model deteksi objek yang dilengkapi dengan pengolahan visual dan sistem alarm. Model diuji pada *dataset* citra kebakaran hutan nyata dan mampu memberikan hasil yang cukup baik. Studi ini menunjukkan bahwa pengembangan algoritma deteksi objek ringan dan efisien memegang peranan penting untuk aplikasi lapangan *real-time* di lingkungan alam terbuka.

Penelitian lain oleh (Ritz *et al.*, 2025) menerapkan CNN untuk segmentasi tajuk pohon individual menggunakan citra penginderaan jauh resolusi tinggi, Penelitian ini menganalisis pengaruh tipe hutan dan umur tegakan terhadap performa model. Hasil penelitian menunjukkan bahwa kinerja CNN bervariasi antar kondisi hutan, di mana nilai *F1-score* dan *Intersection over Union* (IoU) berada pada kisaran 0.70 sampai dengan 0.80 pada hutan dengan struktur kanopi sederhana dan umur tegakan yang relatif homogen. Pada hutan tua dengan kanopi kompleks dan saling tumpang tindih, performa menurun dengan *F1-score* sekitar 0.60 sampai dengan 0.68. Temuan ini menegaskan bahwa meskipun CNN efektif dalam melakukan segmentasi tajuk pohon, kompleksitas struktur kanopi dan heterogenitas umur

hutan berpengaruh signifikan terhadap akurasi delineasi tajuk, sehingga faktor ekologi perlu dipertimbangkan dalam penerapan CNN untuk pemantauan vitalitas hutan.

Penelitian lain oleh (Gandadipoera *et al.*, 2024) mengembangkan sistem klasifikasi jenis kerusakan pohon berbasis *Forest Health Monitoring* (FHM) menggunakan arsitektur *MobileNetV2* pada perangkat *mobile*. *Dataset* terdiri dari 1.600 citra yang mewakili 16 jenis kerusakan pohon, dengan pembagian data pelatihan, validasi, dan pengujian. Model dilatih menggunakan transfer learning dan diimplementasikan dalam aplikasi *Android* melalui konversi ke format *TensorFlow Lite*. Hasil pengujian menunjukkan akurasi tertinggi sebesar 98.75%, dengan performa yang stabil pada sebagian besar kelas. Penelitian ini membuktikan bahwa model CNN ringan seperti *MobileNetV2* efektif untuk mendeteksi kerusakan pohon secara cepat dan efisien di lapangan.

Penelitian lain oleh (Tarigan *et al.*, 2023) tentang identifikasi kerapatan dan transparansi tajuk pohon telah banyak menggunakan teknologi *deep learning*, terutama CNN, untuk menggantikan metode manual yang memerlukan pengamatan langsung oleh tenaga ahli. Penelitian menggunakan VGG16 untuk mengklasifikasikan tingkat kerapatan dan transparansi tajuk pada pohon jenis daun jarum. Penelitian ini melibatkan empat jenis pohon yaitu Cemara Norfolk (*Araucaria heterophylla*), Cemara Bundel (*Cupressus retusa*), Pinus Sumatra (*Pinus merkusii*), dan Damar Mata-Kucing (*Anthoshorea javanica*) dengan 1.000 gambar per jenis pohon dan masing-masing memiliki sepuluh tingkat kerapatan serta transparansi. Hasil dari model VGG16 menunjukkan tingkat akurasi yang tinggi, dengan akurasi tertinggi dicapai pada *Anthoshorea javanica* sebesar 99.00%, sementara jenis lainnya juga mendapatkan hasil yang baik, yaitu 90.00% untuk *pinus merkusii*, 92.00% untuk *araucaria heterophylla*, dan 96.00% untuk *cupressus retusa*. Evaluasi performa model ini menggunakan metrik seperti *precision*, *recall*, dan *F1-score*, di mana kesalahan prediksi terutama terjadi pada kelas dengan tingkat kesamaan visual yang tinggi antar gambar.

Penelitian lain oleh (Sofiyana *et al.*, 2023) menggunakan arsitektur *MobileNet* untuk mengidentifikasi skala kerapatan dan transparansi tajuk pohon daun lebar. Penelitian ini menggunakan dataset dari empat jenis pohon daun lebar yaitu pohon cokelat (*Theobroma cacao*), pohon durian (*Durio zibethinus*), pohon karet (*Havea brasiliensis*), dan pohon kemiri (*Aleurites moluccana*), dengan 5.000 citra untuk setiap jenis pohon. Model *MobileNet* yang digunakan berhasil mencapai akurasi yang sangat baik, dengan akurasi tertinggi sebesar 99.20% pada pohon kemiri selama pelatihan, dan 98.70% selama pengujian. Pohon lain seperti pohon karet juga menunjukkan performa tinggi dengan akurasi pengujian mencapai 97.90%. Pohon cokelat dan durian masing-masing mendapatkan akurasi 94.20% dan 87.50% pada fase pengujian. Penelitian ini menunjukkan bahwa *MobileNet* mampu menangani identifikasi skala kerapatan dan transparansi tajuk pohon daun lebar dengan akurasi yang baik, menggantikan metode tradisional *Forest Health Monitoring* (FHM) yang lebih lambat dan kurang efisien.

Penelitian ini berfokus pada penerapan YOLOv10 dalam pengembangan aplikasi *mobile* yang mampu mengidentifikasi kerapatan dan transparansi tajuk pohon secara *real-time*, memberikan solusi yang inovatif bagi para pemeriksa kesehatan hutan. Aplikasi ini dirancang untuk membuat proses pengukuran dan pemantauan kondisi hutan menjadi jauh lebih efisien, memungkinkan petugas melakukan tugas mereka dengan cepat tanpa memerlukan peralatan tambahan yang kompleks atau prosedur yang rumit. Penggunaan teknologi ini tidak hanya mempermudah pekerjaan lapangan, tetapi juga meningkatkan kecepatan pemeriksaan, sehingga area hutan yang luas dapat dipantau dalam waktu yang lebih singkat. Kemampuan aplikasi untuk memproses data secara *real-time* mengurangi risiko kesalahan manusia yang mungkin timbul akibat faktor eksternal seperti cuaca, pencahayaan, atau kondisi fisik pemeriksa sehingga hasil yang didapatkan lebih akurat dan konsisten, aplikasi ini mendukung pengambilan keputusan yang lebih tepat terkait konservasi dan pengelolaan hutan, sekaligus meningkatkan efisiensi kerja secara keseluruhan.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini yaitu, bagaimana mengembangkan aplikasi *mobile* pemindai *real-time* yang mampu mengidentifikasi kerapatan dan transparansi tajuk pohon berdasarkan metode *Forest Health Monitoring* (FHM) menggunakan YOLOv10.

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah:

1. Memakai YOLOv10 untuk mengidentifikasi kerapatan dan transparansi tajuk pohon.
2. Menggunakan dataset citra tajuk pohon jenis daun jarum dan daun lebar berupa 5.000 citra dari lima jenis daun jarum dan lima jenis daun lebar yaitu Cemara Norfolk (*Araucaria heterophylla*), Cemara Bundel (*Cupressus retusa*), Pinus Sumatra (*Pinus merkusii*), Damar Mata-Kucing (*Anthoshorea javanica*), Damar Biasa (*Agathis dammara*), Cokelat (*Theobroma cacao*), Durian (*Durio zibethinus*), Karet (*Havea brasiliensis*), Kemiri (*Aleurites moluccana*), dan Sonokeling (*Dalbergia latifolia*) dengan 500 foto dari masing-masing berdasarkan 10 kelas kerapatan dan transparansi tajuk.

1.4 Tujuan

Tujuan dari penelitian ini adalah untuk mengembangkan aplikasi *mobile* pemindai *real-time* yang mampu mengidentifikasi kerapatan dan transparansi tajuk pohon berdasarkan metode *Forest Health Monitoring* (FHM) menggunakan YOLOv10.

1.5 Manfaat

Penelitian ini memberikan manfaat pada berbagai pihak, baik dari sisi pengembangan ilmu pengetahuan maupun implementasi praktis. Manfaat dari aspek pengembangan ilmu, penelitian ini berkontribusi pada pengayaan kajian kecerdasan buatan dan visi komputer, khususnya dalam pengembangan metode deteksi objek berbasis *deep learning* untuk analisis tajuk pohon. Bagi masyarakat, hasil penelitian ini berpotensi menjadi sarana pendukung dalam meningkatkan pemahaman terhadap kondisi vegetasi dan pentingnya pemantauan kesehatan hutan secara mandiri. Manfaat bagi pemerintah dan instansi terkait, penelitian ini dapat dimanfaatkan sebagai referensi teknis dan alternatif teknologi dalam kegiatan pemantauan hutan serta penyusunan kebijakan pengelolaan hutan yang lebih efektif dan berbasis data.

II. TINJAUAN PUSTAKA

2.1 Hutan

Hutan merupakan suatu wilayah yang terdiri atas berbagai ekosistem, yang di dalamnya terdapat beragam sumber daya alam yang bermanfaat baik bagi unsur penyusun hutan itu sendiri maupun bagi lingkungan di sekelilingnya (Rahmadanty *et al.*, 2021). Indonesia mengatur definisi dan pengelolaan hutan dalam Undang-Undang Nomor 11 Tahun 2020 tentang Kehutanan, hutan didefinisikan sebagai suatu kesatuan ekosistem berupa hamparan lahan yang didominasi oleh pepohonan dalam persekutuan alam lingkungannya, di mana antara unsur biotik dan abiotik di dalamnya saling berinteraksi dan tidak dapat dipisahkan. Hutan di Indonesia dibedakan menjadi beberapa fungsi, yaitu hutan konservasi, hutan lindung, dan hutan produksi, masing-masing dengan tujuan dan aturan pengelolaan yang berbeda untuk menjaga kelestarian alam serta mendukung kesejahteraan Masyarakat (Rahmayanti, 2023). Pemantauan kesehatan hutan merupakan salah satu langkah penting yang dilakukan untuk menjaga dan mendukung kelestarian hutan (Safe'i *et al.*, 2022). Pemantauan kesehatan hutan dilakukan untuk mengetahui kondisi hutan saat ini, perubahan yang terjadi di masa mendatang, serta kecenderungan yang mungkin muncul akibat berbagai aktivitas yang berlangsung di dalam kawasan hutan (Haikal *et al.*, 2020). Salah satu aspek dalam *monitoring* kesehatan hutan yang krusial adalah pemantauan tajuk pohon (Putra *et al.*, 2023). Tajuk pohon merupakan bagian atas pohon yang tersusun dari cabang, ranting, dan daun yang saling menutupi satu sama lain. Tajuk pohon berperan penting dalam proses fotosintesis karena bentuk dan kerapatannya menentukan jumlah cahaya matahari yang dapat masuk melalui lapisan daun. Semakin padat tajuk pohon, semakin sedikit cahaya yang menembus hingga ke

permukaan tanah, sehingga bibit dan tanaman muda di bawahnya sering mengalami keterbatasan dalam memperoleh sinar matahari (Sadono, 2018).

2.1.1 Kesehatan Hutan

Kesehatan hutan mengacu pada kondisi di mana hutan dapat menjalankan fungsi ekologisnya dengan baik dan mendukung keseimbangan ekosistem (Siregar, 2014). Suatu hutan dapat dikategorikan sehat apabila ekosistem di dalamnya mampu menjalankan fungsinya dengan baik, baik bagi setiap komponen penyusunnya maupun bagi lingkungan di sekitarnya, sehingga keseimbangan dan keberlanjutan ekosistem tetap terjaga (Pangestu *et al.*, 2020). Pohon sehat adalah pohon yang berada dalam kondisi fisiologis dan struktur yang baik, tidak mengalami gangguan atau kerusakan berat, dan berkontribusi terhadap kesehatan hutan secara keseluruhan dengan tetap menjalankan fungsi ekologisnya (Abas, 2023). Secara fisiologis, pohon sehat dicirikan oleh proses fotosintesis yang berjalan normal, pertumbuhan tajuk dan batang yang seimbang, sistem perakaran yang kuat, serta kemampuan menyerap dan mendistribusikan air serta unsur hara secara efektif (Waruwu *et al.*, 2021). Pohon sehat umumnya memiliki ciri memiliki batang yang kokoh, tajuk yang relatif utuh tanpa gejala mati pucuk yang signifikan, serta daun dengan warna dan kerapatan yang mencerminkan tingkat klorofil yang baik (Morales-Gallegos *et al.*, 2023). Pemantauan kesehatan hutan dilakukan secara rutin agar kondisi hutan tetap terawasi, sehingga pengelola dapat melakukan pengendalian serta menyusun langkah penanganan kerusakan sedini mungkin (Aristoteles *et al.*, 2018). Manfaat dari pemantauan kesehatan hutan adalah memperoleh informasi yang akurat mengenai kondisi pohon maupun tanah, sehingga keadaan ekosistem hutan dapat dipahami dengan lebih menyeluruh dan langkah pengelolaan dapat dilakukan secara tepat (Pangestu *et al.*, 2020).

Penelitian ini memanfaatkan metode *Forest Health Monitoring* (FHM) yaitu suatu pendekatan terstruktur yang digunakan untuk menilai berbagai parameter kesehatan hutan secara sistematis dan berkelanjutan (Potter & Conkling, 2022). FHM mengumpulkan data untuk menunjukkan bagaimana kondisi hutan sekarang,

memahami komponen-komponen yang mencerminkan kondisi hutan tersebut berdasarkan beberapa indikator (Putri *et al.*, 2016), FHM menjelaskan Indikator kesehatan hutan dapat dibagi menjadi empat yaitu produktivitas, vitalitas, kualitas tapak, dan biodiversitas (Safe'i, 2018). Indikator ini membantu dalam mengevaluasi seberapa baik hutan mampu menjalankan peran ekologisnya. Produktivitas merujuk pada kemampuan suatu lahan untuk mendukung pertumbuhan dan hasil tanaman secara optimal (Puspita *et al.*, 2021). Vitalitas merujuk pada kesehatan pohon dalam suatu ekosistem hutan yang dapat diukur melalui ketahanan pohon terhadap gangguan, seperti hama dan faktor eksternal lainnya, serta kemampuannya untuk menjalankan fungsi fisiologis dengan baik (Pertiwi *et al.*, 2019). Vitalitas dicirikan berdasarkan dua parameter yaitu Kerusakan Pohon dan Kondisi Tajuk (Safe'i *et al.*, 2021). Kondisi tajuk dinilai berdasarkan *Visual Crown Ratio* (VCR) yang mana VCR adalah rasio panjang tajuk hidup terhadap tinggi total pohon, yang diestimasi secara visual di lapangan (Schomaker *et al.*, 2007). Nilai VCR diperoleh berdasarkan lima parameter yaitu kerapatan tajuk, transparansi tajuk, diameter tajuk, *Live Crown Ratio* (LCR), dan *Crown Dieback* (Safe'i *et al.*, 2021). Penelitian ini berfokus pada dua parameter yaitu kerapatan tajuk dan transparansi tajuk.

Crown Density atau kerapatan tajuk pohon adalah kemampuan tajuk pohon dalam menghalangi cahaya matahari agar tidak langsung mencapai permukaan tanah. Penilaian tingkat kerapatan tajuk dilakukan dengan rentang awal 5% dan meningkat secara bertahap setiap 10% sehingga dapat menggambarkan variasi tutupan tajuk secara lebih detail (Ansori *et al.*, 2020).

Foliage Transparency atau transparansi tajuk pohon *Transparansi tajuk* berasal dari perubahan pada kondisi tajuk seperti defoliasi dan perubahan warna dedaunan, yang kemudian tercermin dalam persentase bagian tajuk yang tidak tertutup daun sehingga memungkinkan cahaya menembus kanopi. Dalam proses survei lapangan, pohon-pohon dikelompokkan ke dalam kelas transparansi tajuk setiap 5% berdasarkan standar internasional dan meningkat secara bertahap setiap 10% hingga mencapai tingkat maksimum 95% (Montzka *et al.*, 2021).

Crown Diameter atau diameter tajuk didefinisikan sebagai ukuran horizontal tajuk pohon yang merepresentasikan lebar ruang tajuk yang ditempati oleh cabang dan daun pohon. *Crown diameter* menggambarkan luas proyeksi tajuk pohon pada bidang horizontal, yang mencerminkan seberapa besar ruang tumbuh yang dimanfaatkan pohon untuk menyebarkan tajuknya. Parameter ini digunakan untuk menjelaskan interaksi antar pohon dalam tegakan, khususnya terkait kompetisi cahaya, pertumbuhan pohon, dan produktivitas hutan, karena tajuk yang lebih lebar menunjukkan kemampuan pohon yang lebih besar dalam menangkap cahaya dan mendominasi ruang kanopi di sekitarnya (Raptis *et al.*, 2018).

Live Crown Ratio (LCR) didefinisikan sebagai rasio antara panjang tajuk hidup (*living crown*) dengan total tinggi pohon dan digunakan sebagai indikator pertumbuhan dan stabilitas pohon di dalam tegakan hutan. LCR merepresentasikan proporsi bagian batang pohon yang masih memiliki tajuk hidup, yang menggambarkan sejauh mana pohon masih mampu mempertahankan tajuk aktif secara fisiologis untuk proses fotosintesis dan pertumbuhan, serta berkontribusi terhadap kestabilan struktur pohon dalam menghadapi kompetisi dan gangguan (Stăncioiu *et al.*, 2021).

Crown Dieback atau mati pucuk didefinisikan sebagai persentase kematian tajuk pohon yang dinilai secara visual berdasarkan kehilangan daun yang mengering, hangus, atau gugur dibandingkan total area daun sepanjang musim pertumbuhan. *Crown dieback* menggambarkan proporsi kerusakan tajuk berupa kematian jaringan daun yang terjadi sebagai respon terhadap stres panas dan kekeringan ekstrem, dan diukur sebagai persentase area tajuk yang mati pada setiap individu pohon (Marchin *et al.*, 2022).

Kualitas Tapak menggambarkan tingkat kemampuan tanah dalam menunjang pertumbuhan pohon dan vegetasi lainnya, terutama terkait dengan ketersediaan nutrisi, air, dan kondisi lingkungan yang memengaruhi produktivitas hutan secara keseluruhan (Safe'i *et al.*, 2019).

Biodiversitas merupakan karakteristik yang menggambarkan tingkat keberagaman vegetasi berdasarkan keberadaan organisme biologis dalam suatu ekosistem.

Biodiversitas tidak hanya berkaitan dengan variasi jenis tumbuhan (flora), tetapi juga mencakup pengukuran keanekaragaman hewan (fauna) yang hidup di dalamnya (Doria *et al.*, 2021). Biodiversitas berperan sebagai indikator tingkat kestabilan sebuah komunitas ekosistem. Nilai biodiversitas yang tinggi menunjukkan kompleksitas interaksi antarjenis dalam suatu kawasan hutan, di mana hubungan ekologis antarorganisme berlangsung secara seimbang dan saling mendukung (Tapasya *et al.*, 2023).


2.1.2 Forest Health Monitoring (FHM)

Forest Health Monitoring (FHM) merupakan suatu metode yang digunakan untuk melakukan pemantauan serta evaluasi kondisi kesehatan ekosistem secara intensif, dengan menilai indikator ekologis yang meliputi kualitas tapak, vitalitas pohon, produktivitas, dan biodiversitas (Putri *et al.*, 2016). FHM memadukan data hasil observasi lapangan dengan informasi dari penginderaan jauh guna mengidentifikasi perubahan yang terjadi serta sumber tekanan yang bersifat biotik maupun abiotik (Mangold, 2000). Vitalitas mencerminkan kondisi kerusakan pohon dan kondisi tajuk yang dapat digunakan sebagai salah satu indikator dalam penilaian kesehatan hutan (Indriani *et al.*, 2020). Nilai vitalitas ditentukan melalui perhitungan yang mencakup lokasi kerusakan, tipe kerusakan, serta tingkat keparahan kerusakan yang terjadi pada pohon (Safe'i, 2014). Penelitian ini berfokus pada aspek vitalitas yang dicirikan oleh kondisi kerusakan pohon dan kondisi tajuk, khususnya pada penilaian kondisi tajuk yang dinilai melalui parameter *Visual Crown Ratio* (VCR). VCR mencakup beberapa parameter seperti kerapatan tajuk, transparansi tajuk, diameter tajuk, rasio tajuk hidup, dan mati pucuk. Fokus utama penelitian ini adalah pada kerapatan tajuk dan transparansi tajuk sebagai parameter yang dapat menggambarkan tingkat kesehatan dan kemampuan pohon dalam menjalankan fungsinya.

2.1.3 Kerapatan dan Transparansi Tajuk Pohon

Kerapatan dan transparansi tajuk merupakan salah dua parameter dari *Visual Crown Ratio* (VCR) yang digunakan dalam penilaian kesehatan hutan. Suatu hutan dapat dikategorikan sehat apabila memiliki tingkat kerapatan tajuk mencapai atau

melebihi 55%, serta transparansi tajuk berada pada kisaran 0 hingga 45% (Arwanda & Safe'i, 2021). Penilaian kedua parameter tersebut dilakukan menggunakan kartu skala atau yang dikenal dengan *Magic Card* yang berfungsi untuk mengukur persentase cahaya matahari yang tertahan oleh tajuk maupun yang berhasil menembus hingga ke bagian bawah pohon (Iskandar, 2018). Kerapatan tajuk adalah kemampuan tajuk pohon dalam menghalangi cahaya matahari agar tidak langsung mencapai permukaan tanah (Ansori *et al.*, 2020). Transparansi tajuk pohon menggambarkan seberapa banyak cahaya matahari yang dapat menembus celah-celah tajuk pohon hingga mencapai permukaan tanah (Montzka *et al.*, 2021). Pengukuran kerapatan dan transparansi tajuk pohon umumnya dilakukan dengan menggunakan kartu skala kerapatan dan transparansi tajuk pohon atau *Magic Card* (Puspita *et al.*, 2021). Dalam praktik pemantauan kesehatan pohon dan hutan parameter kondisi tajuk seperti *crown density* dan *foliage transparency* diukur secara visual oleh pengamat dan dikodifikasi dalam interval 5% dan secara bertahap naik 10%. Interval ini dipilih karena memberikan keseragaman, kemudahan estimasi visual, dan konsistensi data antar pengamat (Randolph & Thompson, 2010).



Gambar 1. Kartu Skala Kerapatan dan Transparansi Tajuk (US Forest Service, 2023).

Pengukuran yang umumnya dilakukan selama ini berdasarkan kartu skala yang awalnya dikembangkan oleh U.S.D.A *Forest Service* yang berjudul *Forest Health Monitoring: Field Methods Guide*. Pengukuran dilakukan dengan melihat seberapa banyak titik titik putih yang dapat menembus lantai hutan saat pengamat melihat

keatas pohon didepan batang pohon. Semakin banyak cahaya yang dapat menembus menandakan semakin besar presentase transparansi dan semakin besar kerapatan, namun sebaliknya semakin sedikit cahaya yang dapat menembus menandakan semakin kecil kecil transparansi dan semakin besar kerapatan yang ada di pohon tersebut (Pisani *et al.*, 2023).

2.1.4 Tajuk Pohon

Tajuk pohon merupakan bagian dari pohon yang berperan penting dalam menjalankan proses fisiologis. Bagian ini terdiri atas kumpulan ranting, cabang, dan daun yang berada di bagian atas pohon. Tajuk yang mendapatkan paparan cahaya adalah area teratas dari tajuk pohon yang aktif melakukan fotosintesis ketika terkena sinar matahari (Adhi, 2017). Tajuk pohon memiliki variasi bentuk dan struktur yang berbeda pada setiap jenis pohon, yang secara umum dapat diklasifikasikan menjadi Daun Jarum (*needleleaf*) dan Daun Lebar (*broadleaf*). Daun Jarum merujuk pada struktur daun yang panjang, sempit, dan menyerupai jarum, yang merupakan bentuk adaptasi khas pada tumbuhan *gymnospermae*, khususnya konifer untuk mengurangi kehilangan air dan bertahan di lingkungan yang keras seperti dingin atau kering (Du *et al.*, 2020). Daun Lebar merujuk pada spesies tanaman yang memiliki daun yang relatif lebar dan datar. Daun Lebar memiliki ukuran permukaan yang lebih besar, mempengaruhi morfologi daun dan fungsi ekologisnya, termasuk penyerapan cahaya, pertukaran gas, dan respons terhadap lingkungan (Zhou *et al.*, 2023). Penelitian ini berfokus pada dua tipe tajuk tersebut dengan memanfaatkan citra dari lima jenis pohon berdaun jarum dan lima jenis pohon berdaun lebar yaitu Cemara Norfolk (*Araucaria heterophylla*), Cemara Bundel (*Cupressus retusa*), Pinus Sumatra (*Pinus merkusii*), Damar Mata-Kucing (*Anthoshorea javanica*), Damar Biasa (*Agathis dammara*), Cokelat (*Theobroma cacao*), Durian (*Durio zibethinus*), Karet (*Havea brasiliensis*), Kemiri (*Aleurites moluccana*), dan Sonokeling (*Dalbergia latifolia*). Data yang digunakan dalam penelitian ini berasal dari penelitian terdahulu oleh; Tarigan *et al.*, (2023), Octarina *et al.*, (2023), Sriatna *et al.*, (2024), dan Sofiyana *et al.*, (2023). Variasi karakteristik tajuk pada spesies berbeda ini memberikan representasi yang lebih komprehensif dalam penilaian kondisi kesehatan tajuk pohon.

2.1.4.1 *Araucaria heterophylla*



Gambar 2. Tajuk Pohon Cemara Norfolk (*Araucaria heterophylla*).

Tingkatan taksonomi tajuk pohon jenis *Araucaria heterophylla* sebagai berikut:
Kumari *et al.*, (2024)

Kingdom: Plantae

Division: Pinophyte

Class: Pinopsida

Order: Pinales

Family: Araucariaceae

Genus: Araucaria

Species: Araucaria heterophylla

Cemara Norfolk (*Araucaria heterophylla*) termasuk dalam ordo *Araucariales* dan memiliki karakter morfologi khas dari kelompok tersebut. Sistem perakarannya bertipe tunggang yang mampu tumbuh cukup dalam. Batangnya berbentuk silindris, tegak, dan memiliki susunan ranting yang teratur. Kulit batang bersifat tebal dan kuat. Daunnya menyerupai jarum dengan ukuran yang dapat bervariasi menurut spesies, serta tersusun secara spiral pada ujung ranting. Bunganya berbentuk bulir dan muncul pada bagian ujung ranting, sedangkan buahnya berbentuk bulat hingga oval dengan kulit yang keras dan tebal (Ulfa *et al.*, 2023).

2.1.4.2 *Cupressus retusa*



Gambar 3. Tajuk Pohon Cemara Bundel (*Cupressus retusa*).

Tingkatan taksonomi tajuk pohon jenis *Cupressus retusa* sebagai berikut: (Tawfeek *et al.*, 2023)

Kingdom: Plantae

Division: Pinophyta

Class: Pinopsida

Order: Cupressales

Family: Cupressaceae

Genus: Cupressus

Species: Cupressus retusa

Cemara bundel (*Cupressus retusa*) merupakan salah satu spesies dalam genus *Cupressus* dari famili *Cupressaceae*, yaitu kelompok pohon konifer yang bersifat *evergreen* atau tetap hijau sepanjang tahun. Tanaman ini umumnya memiliki tajuk yang rapat dengan bentuk kerucut hingga kolumnar, serta daun berbentuk sisik kecil yang melekat pada ranting. Sebagai tumbuhan konifer, *Cupressus retusa* bereproduksi menggunakan strobilus (*cone*) sebagai organ generatif, yang menjadi ciri khas kelompok *gymnospermae*. Secara umum, spesies ini termasuk pohon berkayu yang dapat tumbuh baik di berbagai kondisi lingkungan dan sering

dimanfaatkan dalam penghijauan maupun sebagai bagian dari ekosistem hutan (Frezza *et al.*, 2022).

2.1.4.3 *Pinus merkusii*



Gambar 4. Tajuk Pohon Pinus Sumatra (*Pinus merkusii*).

Tingkatan taksonomi tajuk pohon jenis *Pinus merkusii* sebagai berikut: Akira *et al.*, (2024)

Kingdom: Plantae

Division: Pinophyta

Class: Pinopsida

Order: Pinales

Family: Pinaceae

Genus: Pinus

Species: Pinus merkusii

Pinus Sumatra (*Pinus merkusii*) merupakan salah satu spesies pohon konifer dari famili *Pinaceae* yang bersifat *evergreen* dan memiliki daun berbentuk jarum. Sebagai tumbuhan *gymnospermae*, spesies ini bereproduksi menggunakan strobilus (*cone*) sebagai organ generatif. *Pinus merkusii* diketahui sebagai satu-satunya jenis pinus yang tumbuh alami di wilayah selatan garis khatulistiwa serta merupakan spesies asli Indonesia yang memiliki nilai ekologis dan ekonomi tinggi, terutama

sebagai penghasil resin dan kayu dalam kegiatan kehutanan (Imanuddin *et al.*, 2020).

2.1.4.4 *Anthoshorea javanica*



Gambar 5. Tajuk Pohon Damar Mata-Kucing (*Anthoshorea javanica*).

Tingkatan taksonomi tajuk pohon jenis *Anthoshorea javanica* sebagai berikut: Ashton & Heckenhauer, (2022)

Kingdom: Plantae

Division: Eudicots

Class: Rosids

Order: Malvales

Family: Dipterocarpaceae

Genus: Anthoshorea

Species: Anthoshorea javanica

Damar mata kucing (*Anthoshorea javanica*) merupakan salah satu spesies pohon berkayu dari famili *Dipterocarpaceae* yang bersifat *evergreen* dan menjadi penyusun penting hutan hujan tropis. Spesies ini dikenal sebagai penghasil hasil hutan bukan kayu berupa damar (*resin*) yang memiliki nilai ekonomi tinggi dan telah lama dimanfaatkan oleh masyarakat, khususnya di wilayah Sumatra (Nur'aini *et al.*, 2020).

2.1.4.5 *Agathis dammara*



Gambar 6. Tajuk Pohon Damar Biasa (*Agathis dammara*).

Tingkatan taksonomi tajuk pohon jenis *Agathis dammara* sebagai berikut: Frezza *et al.*, (2020)

Kingdom: Plantae

Division: Pinophyta

Class: Pinopsida

Order: Araucariales

Family: Araucariaceae

Genus: Agathis

Species: Agathis dammara

Agathis dammara merupakan pohon runjung (*Gymnospermae*) asli Indonesia yang dapat mencapai tinggi hingga sekitar 65m. Batangnya berbentuk silindris, tegak, dan memiliki diameter yang besar. Pohon ini dikenal sebagai penghasil getah damar yang bernilai ekonomi. Persebaran alaminya meliputi wilayah kepulauan Indonesia seperti Maluku dan Sulawesi, serta sebagian area di Filipina. *Agathis dammara* juga dibudidayakan untuk keperluan produksi getah damar (Syahra *et al.*, 2021).

2.1.4.6 *Theobroma cacao*



Gambar 7. Tajuk Pohon Cokelat (*Theobroma cacao*).

Tingkatan taksonomi tajuk pohon jenis *Theobroma cacao* sebagai berikut: Colli-Silva *et al.*, (2024)

Kingdom: Plantae

Division: Eudicots

Class: Rosids

Order: Malvales

Family: Malvaceae

Genus: Theobroma

Species: Theobroma cacao

Theobroma cacao atau yang dikenal sebagai tanaman kakao merupakan tanaman perkebunan tahunan yang berasal dari wilayah Amerika Tengah dan Selatan, dan termasuk ke dalam famili yang diklasifikasikan sebagai *Malvaceae*. Tanaman ini tumbuh optimal di daerah beriklim tropis dengan kelembapan dan suhu yang sesuai. Kakao memiliki karakteristik berbunga dan berbuah pada batang utama (*cauliflory*) serta menghasilkan buah yang di dalamnya terdapat biji. Biji kakao setelah melalui proses fermentasi dan pengolahan menjadi bahan utama pembuatan cokelat. Kakao menjadi salah satu komoditas perkebunan penting di Indonesia yang banyak

dibudidayakan sebagai bahan baku industri pangan dan agroindustri (Farhanandi & Indah, 2022).

2.1.4.7 *Durio zibethinus*



Gambar 8. Tajuk Pohon Durian (*Durio zibethinus*).

Tingkatan taksonomi tajuk pohon jenis *Durio zibethinus* sebagai berikut: Khaksar *et al.*, (2024)

Kingdom: Plantae

Division: Eudicots

Class: Rosids

Order: Malvales

Family: Malvaceae

Genus: Durio

Species: Durio zibethinus

Durio zibethinus merupakan spesies pohon buah tropis dari genus *Durio* yang banyak dibudidayakan di kawasan Asia Tenggara. Buahnya memiliki ciri khas berupa ukuran yang besar, kulit penuh duri, daging buah tebal, serta aroma kuat yang sangat khas. Tanaman ini berasal dari wilayah Asia Tenggara seperti Indonesia, Malaysia, dan Kalimantan, serta menunjukkan keragaman morfologi

yang luas, termasuk perbedaan bentuk daun, ukuran dan rasa buah (Susilawati & Sabran, 2018).

2.1.4.8 *Havea brasiliensis*



Gambar 9. Tajuk Pohon Karet (*Havea brasiliensis*).

Tingkatan taksonomi tajuk pohon jenis *Havea brasiliensis* sebagai berikut: Puttaso *et al.*, (2020)

Kingdom: Plantae

Division: Eudicots

Class: Rosids

Order: Malpighiales

Family: Euphorbiaceae

Genus: Hevea

Species: Hevea brasiliensis

Hevea brasiliensis merupakan pohon berasal dari Amerika Selatan dan telah dikembangkan secara luas di berbagai daerah beriklim tropis, termasuk Indonesia. Keunggulan utama tanaman karet adalah kemampuannya menghasilkan lateks sebagai bahan baku utama industri karet alam. Berbagai produk olahan karet banyak digunakan pada sektor industri, seperti otomotif, kesehatan, dan manufaktur (Andriyanto *et al.*, 2019).

2.1.4.9 *Aleurites moluccana*



Gambar 10. Tajuk Pohon Kemiri (*Aleurites moluccana*).

Tingkatan taksonomi tajuk pohon jenis *Aleurites moluccana* sebagai berikut: Fitriani, (2024)

Kingdom: Plantae

Division: Eudicots

Class: Rosids

Order: Malpighiales

Family: Euphorbiaceae

Genus: Aleurites

Species: Aleurites moluccanus

Aleurites moluccanus merupakan pohon serbaguna yang berasal dari kawasan kepulauan Maluku dan Malaysia, dan kini telah dibudidayakan secara luas di berbagai negara. *Aleurites moluccanus* tersebar hampir di seluruh wilayah, terutama dimanfaatkan secara komersial maupun untuk kebutuhan subsisten masyarakat, khususnya di kawasan Indonesia bagian timur. Biji kemiri banyak digunakan sebagai bahan bumbu masakan, dan secara tradisional dipercaya memiliki manfaat kesehatan, seperti membantu sistem pencernaan, mengatasi infeksi jamur, menurunkan risiko penyakit jantung, mengurangi insomnia, serta mendukung kesehatan tulang dan sendi (Sutejo & Fajri, 2023).

2.1.4.10 *Dalbergia latifolia*



Gambar 11. Tajuk Pohon Sonokeling (*Dalbergia latifolia*).

Tingkatan taksonomi tajuk pohon jenis *Dalbergia latifolia* sebagai berikut: Yulita *et al.*, (2020)

Kingdom: Plantae

Division: Eudicots

Class: Rosids

Order: Fabales

Family: Fabaceae

Genus: Dalbergia

Species: Dalbergia latifolia

Dalbergia latifolia merupakan pohon yang memiliki kayu bernilai ekonomi tinggi yang tumbuh secara alami di wilayah Jawa Tengah dan Jawa Timur pada ketinggian kurang dari 600 meter di atas permukaan laut, terutama pada lahan berbatu dan cenderung kering. *Dalbergia latifolia* dikenal memiliki tekstur yang halus sehingga mudah diproses dalam tahap finishing, serta memiliki ketahanan yang baik dengan tampilan estetik menyerupai kayu jati. *Dalbergia latifolia* juga memiliki keterbatasan seperti kadar air yang relatif tinggi dan kurang cocok untuk finishing

berwarna terang. Pemanfaatannya banyak dijumpai pada industri mebel, kerajinan, serta perabot rumah tangga (Andriani *et al.*, 2023).

2.2 Aplikasi *Mobile*

Aplikasi *mobile* adalah perangkat lunak yang dirancang untuk beroperasi pada perangkat komputasi kecil seperti *smartphone* dan tablet, yang membuat Aplikasi *mobile* ini berkembang pesat selama sebelas tahun terakhir berkat kemajuan dalam perangkat keras, sistem operasi, dan alat pengembangan. Aplikasi *mobile* digunakan dalam berbagai sektor seperti pendidikan, kesehatan, dan perdagangan, berkat keunggulannya dalam portabilitas, aksesibilitas, serta fitur-fitur seperti notifikasi push, pembaruan data *real-time*, dan fungsionalitas yang meningkatkan pengalaman pengguna (Pedro *et al.*, 2018).

2.3 Pemindai *Real-Time*

Pemindai *real-time* adalah perangkat atau sistem yang mampu memproses dan menganalisis data secara langsung saat data tersebut ditangkap, tanpa adanya penundaan signifikan. Proses ini memungkinkan pemindai untuk memberikan hasil atau informasi secara instan. Pemindai *real-time* digunakan dalam aplikasi yang membutuhkan hasil cepat dan akurat, seperti dalam deteksi objek, analisis gambar, atau pemindaian *barcode*. Sistem tradisional umumnya menyimpan data terlebih dahulu untuk dianalisis kemudian, pemindai *real-time* memanfaatkan algoritma yang memproses masukan secara langsung, hal ini sangat berguna dalam bidang-bidang seperti keamanan, robotika, dan diagnostik medis, di mana respons yang cepat sangat penting untuk efisiensi dan pengambilan keputusan (Ashok & Yadav, 2019).

2.4 *Application Programming Interface (API)*

Application Programming Interface (API) adalah kode yang digunakan untuk menghubungkan satu aplikasi dengan data dan layanan dari aplikasi lain, dengan memberikan semua izin yang diperlukan dan memungkinkan dua program perangkat lunak untuk berkomunikasi satu sama lain (Rochim *et al.*, 2021). API memungkinkan pengembang untuk memanfaatkan layanan dan fungsionalitas dari aplikasi atau layanan lain tanpa harus memahami detail internalnya dan dicapai dengan memanggil *endpoints* yang disediakan oleh API menggunakan protokol seperti HTTP, di mana berbagai operasi dapat dilakukan seperti *GET* (mengambil data), *POST* (mengirim data), *PUT* (memperbarui data), atau *DELETE* (menghapus data). Penggunaan API semakin umum dalam pengembangan aplikasi modern karena memungkinkan integrasi yang mudah antar layanan serta pemisahan tugas yang lebih modular antar komponen sistem. Dalam konteks aplikasi yang memerlukan sistem login, API memungkinkan aplikasi untuk berkomunikasi dengan *server* guna mengautentikasi pengguna, memverifikasi kredensial, serta mengelola sesi pengguna dengan aman. API memungkinkan aplikasi untuk mengirimkan data *login* seperti nama pengguna dan kata sandi, lalu menerima respons dari *server* yang memvalidasi akses. API berperan penting dalam menjaga keamanan dan privasi data pengguna serta memastikan hanya pengguna yang terotorisasi yang dapat mengakses aplikasi. Penggunaan API dalam sistem *login* juga membantu menjaga efisiensi operasional dengan memisahkan proses autentikasi dari aplikasi utama.

2.4.1 *Firebase*

Firebase adalah sebuah layanan yang menyediakan pengembang aplikasi API yang memungkinkan data aplikasi disinkronisasi di klien dan disimpan di *cloud Firebase*. *Firebase* menyediakan *library* untuk berbagai *client platform* yang memungkinkan integrasi dengan Android, iOS, JavaScript, Java, Objective-C, dan Node.js. *Firebase* juga dapat disebut sebagai layanan DbaaS (*Database as a Service*) dengan konsep *real-time*. *Firebase* digunakan untuk mempermudah penambahan fitur-fitur yang akan dibangun oleh *developer*. *Database Real-time* merupakan basis data dalam *Firebase* yang berbasis *cloud* dan tidak memerlukan

query berbasis SQL untuk menyimpan dan mengambil data. Basis data ini terkenal sangat handal dan super cepat dalam proses *update* data dan sinkronisasi, sehingga data tetap dipertahankan bahkan ketika pengguna tidak terhubung dengan internet (Payara & Tanone, 2018). Fitur andalan dari *firebase* adalah *Firebase Authentication*, yang memudahkan pengembang untuk mengimplementasikan sistem *login* dan autentikasi pengguna dengan berbagai metode, termasuk *email*, Google, Facebook, dan lainnya. Dukungan penuh dari infrastruktur *Google Cloud*, *Firestore* memberikan skala dan performa yang tinggi, sekaligus menghadirkan kemudahan integrasi dengan layanan Google lainnya.

2.5 Python

Python merupakan bahasa pemrograman tingkat tinggi yang serbaguna dan digunakan secara luas dalam berbagai bidang, termasuk ilmu data, pengembangan web, dan otomatisasi. *Python* dikenal karena sintaksnya yang sederhana dan mudah dipahami, yang membuatnya cocok untuk pemula maupun profesional. *Python* menawarkan ekosistem pustaka yang luas seperti *Pandas*, *NumPy*, dan *scikit-learn*, yang memungkinkan pengguna untuk melakukan analisis data, pembelajaran mesin, serta manipulasi data dengan efisien (Takefuji, 2021). Sifat *open-source* dari *Python* menjadikannya pilihan populer dalam penelitian dan pengembangan perangkat lunak karena memungkinkan distribusi dan penggunaan yang lebih luas tanpa batasan finansial.

2.6 Tensorflow Lite

TensorFlow Lite adalah sebuah *library* yang dirancang untuk memudahkan pengembang dalam membuat dan menjalankan model kecerdasan buatan (AI) *TensorFlow* pada perangkat dengan daya komputasi terbatas, seperti perangkat *mobile*, mikrokontroler, dan perangkat Internet of Things (IoT). Tujuan utama dari *TensorFlow Lite* adalah untuk memungkinkan inferensi model AI secara efisien di

perangkat tepi (edge devices), sehingga tidak memerlukan koneksi ke *cloud* untuk memproses data (Dokic *et al.*, 2020).

2.7 Kotlin

Kotlin adalah bahasa pemrograman modern yang banyak digunakan dalam pengembangan *Android* karena kemampuannya berinteroperasi dengan *Java* dan efisiensinya dalam platform seluler. *Kotlin* menawarkan kinerja yang lebih baik serta fleksibilitas dalam aplikasi berbasis sensor jika dibandingkan dengan *Java* dan *Flutter*. Sintaksis *Kotlin* yang ringkas mengurangi kode berlebihan (*boilerplate code*), sehingga meningkatkan produktivitas (Wasilewski & Zabierowski, 2021). Integrasi *Kotlin* dengan sistem *Android* memungkinkan pengembangan aplikasi yang lebih lancar. *Kotlin* juga mendukung paradigma pemrograman berorientasi objek dan fungsional, memberikan fleksibilitas lebih bagi pengembang dalam menyusun aplikasi mereka.

2.8 Pengujian Perangkat Lunak

Pengujian perangkat lunak merupakan proses evaluasi sistematis terhadap suatu sistem perangkat lunak yang bertujuan untuk mendeteksi, mengidentifikasi, dan memperbaiki kesalahan atau cacat (*bugs*) yang mungkin terjadi selama proses pengembangan maupun pemeliharaan (Jia, 2023). Proses ini bertujuan untuk memastikan bahwa perangkat lunak telah memenuhi spesifikasi teknis serta kebutuhan dan ekspektasi pengguna akhir. Pengujian juga berperan penting dalam menjamin kualitas, keandalan, dan performa perangkat lunak sebelum digunakan secara luas atau dirilis ke pasar.

2.9 User Acceptance Testing (UAT)

User Acceptance Testing (UAT) adalah tahap akhir dalam siklus pengembangan perangkat lunak yang bertujuan untuk memastikan bahwa sistem yang dikembangkan memenuhi kebutuhan dan ekspektasi pengguna akhir sebelum diterapkan secara resmi (Zuluaga *et al.*, 2022). UAT dilakukan oleh pengguna akhir atau perwakilan bisnis dalam lingkungan yang menyerupai kondisi nyata, untuk memverifikasi bahwa sistem berfungsi sesuai dengan persyaratan bisnis yang telah ditetapkan. Proses ini penting untuk mengidentifikasi masalah atau kekurangan yang mungkin tidak terdeteksi pada tahap pengujian sebelumnya, seperti pengujian fungsional atau sistem, sehingga dapat meningkatkan kualitas dan kepuasan pengguna terhadap sistem yang dikembangkan.

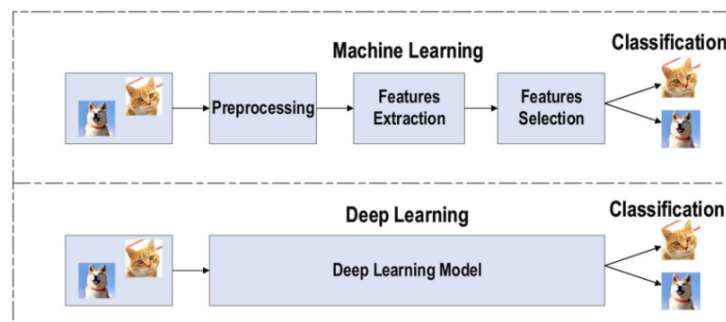
2.10 Skala *Likert*

Skala *Likert* adalah instrumen psikometrik yang umum digunakan untuk mengukur sikap, opini, atau persepsi individu dalam konteks penelitian. Skala ini menyajikan serangkaian pernyataan kepada responden, yang kemudian diminta untuk menunjukkan tingkat persetujuan atau ketidaksetujuan mereka terhadap setiap pernyataan tersebut (Koo & Yang, 2025). Skala ini terdiri dari lima hingga tujuh poin, dengan opsi respons yang simetris, seperti "Sangat Tidak Setuju" hingga "Sangat Setuju". Setiap poin pada skala mencerminkan tingkat persetujuan atau sentimen tertentu, memungkinkan peneliti untuk mengubah respons subjektif menjadi data kuantitatif yang dapat dianalisis secara statistik.

2.11 *Deep Learning*


Machine learning dan *deep learning* merupakan dua cabang dari kecerdasan buatan (AI), namun keduanya memiliki perbedaan dalam hal kompleksitas dan cara kerja. *Machine learning* adalah metode di mana algoritma dilatih untuk membuat prediksi atau keputusan berdasarkan data yang ada. Algoritma *machine learning* mengandalkan fitur-fitur yang ditentukan oleh manusia sementara *Deep learning*

adalah salah satu cabang dari *machine learning* yang meniru cara kerja otak manusia dalam memproses informasi. Sama seperti otak manusia yang mampu mengenali gambar, suara, gerakan, dan berbagai jenis informasi lainnya. *Deep learning* bekerja dengan memanfaatkan jaringan saraf tiruan (*neural networks*) yang tersusun dari beberapa lapisan. Setiap lapisan memberikan interpretasi yang berbeda terhadap data yang diterima. Semakin banyak data yang dilatih dalam model *deep learning*, semakin akurat sistem ini dalam mengidentifikasi objek. Data dalam jumlah besar diproses melalui beberapa lapisan untuk mengenali pola, menyimpan informasi, dan melakukan klasifikasi terhadap *input*. *Deep learning* seringkali mampu memberikan hasil yang lebih baik dibandingkan manusia dalam beberapa tugas. Model ini secara otomatis menemukan fitur dari data yang masuk, memrosesnya, dan kemudian mengklasifikasikannya menggunakan algoritma yang telah dioptimalkan. Algoritma *deep learning* memiliki beragam variasi yang dirancang untuk mengatasi berbagai jenis masalah. *Convolutional Neural Networks* (CNN) merupakan yang paling umum digunakan dalam pemrosesan citra dan video. CNN efektif dalam mendeteksi fitur visual pada gambar, seperti dalam aplikasi deteksi objek. *You Only Look Once* (YOLO), sebagai varian dari CNN, merupakan algoritma deteksi objek real-time yang unggul dalam kecepatan dan akurasi. *Recurrent Neural Networks* (RNN) digunakan untuk data sekuensial, seperti teks dan suara, dan sering diterapkan dalam pengenalan suara atau penerjemahan bahasa. Varian RNN, *Long Short-Term Memory* (LSTM), mengatasi kelemahan dalam memori jangka panjang, sehingga digunakan untuk pemrosesan teks yang lebih kompleks. *Generative Adversarial Networks* (GAN) menawarkan inovasi dalam menghasilkan gambar dan data sintetik dengan melibatkan dua jaringan yang bersaing, yaitu *generator* dan *discriminator* (Shiri et al., 2023).



Gambar 12. Perbedaan antara *Machine Learning* dan *Deep Learning* (Alzubaidi *et al.*, 2021).

Yann LeCun bersama timnya menerbitkan sebuah *paper* pada tahun 1989 yang memperkenalkan teknik *gradient-based learning* untuk pengenalan dokumen. Yann LeCun bersama timnya memperkenalkan LeNet-5, yang dianggap sebagai implementasi *Convolutional Neural Network* (CNN) pertama yang dikenal secara luas dan efektif. LeNet-5 dirancang untuk tugas pengenalan karakter tulisan tangan, yang mereka latih menggunakan dataset terkenal bernama MNIST (*Modified National Institute of Standards and Technology*), sebuah kumpulan data yang sering digunakan dalam pengenalan pola dan pengujian model *deep learning*. Karya ini menjadi landasan penting dalam pengembangan teknik CNN yang dikenal saat ini (Salehi *et al.*, 2023). CNN adalah jenis jaringan saraf tiruan yang terdiri dari beberapa lapisan yang dirancang khusus untuk memproses data berbentuk gambar, terutama melalui pemrosesan nilai piksel. CNN bekerja dengan menambahkan lapisan tersembunyi yang bertugas mengidentifikasi berbagai karakteristik dalam gambar. CNN mendeteksi fitur dasar seperti garis vertikal dan horizontal. Hasil dari lapisan pertama ini kemudian digunakan untuk mengenali pola yang lebih kompleks pada lapisan berikutnya. Kedalaman lapisan yang bertambah membuat CNN dapat mengidentifikasi karakteristik yang lebih rumit seperti warna dan bentuk dengan lebih detail, sehingga memungkinkan pengenalan objek secara lebih akurat (Zhu & Chen, 2023).



Gambar 13. Arsitektur CNN (Zhu & Chen, 2023).

CNN memiliki beberapa lapisan utama yang berperan dalam pengenalan dan klasifikasi gambar. Lapisan pertama adalah *convolutional layer (CONV)*, yang bertugas memproses data input dengan menerapkan filter untuk mendeteksi berbagai fitur dalam gambar, seperti tepi atau tekstur. *Pooling layer (POOL)* berfungsi untuk mengurangi dimensi data dengan menyusutkan ukuran gambar antara, seringkali melalui teknik *subsampling*, sehingga informasi penting tetap dipertahankan sambil mengurangi kompleksitas komputasi. *Fully connected layer (FCL)* yang mirip dengan lapisan *perceptron* tradisional, menghubungkan semua neuron dan membantu membuat keputusan berdasarkan fitur yang telah diekstraksi. *Classification layer (Softmax)* digunakan untuk memprediksi kelas dari gambar input, dengan memberikan probabilitas untuk setiap kelas berdasarkan data yang telah diproses oleh lapisan-lapisan sebelumnya (Liu *et al.*, 2021).

2.11.1 Feature Extraction Layer

Feature extraction layer adalah komponen kunci dalam arsitektur jaringan saraf tiruan, terutama dalam model *deep learning* seperti CNN. Tugas utamanya adalah mengidentifikasi dan mengekstrak fitur-fitur penting dari *data input*, seperti gambar, untuk menyederhanakan representasi visual sehingga lebih mudah diolah oleh lapisan-lapisan jaringan berikutnya (C. Y. Wang *et al.*, 2023). Gambar yang dimasukkan terdiri dari kumpulan nilai piksel yang diatur dalam *array* multidimensi, namun ukuran *array* ini sering kali sangat besar dan tidak efisien untuk diproses secara langsung (Bochkovskiy *et al.*, 2020). Selama proses ini, fitur

seederhana diubah menjadi representasi yang lebih abstrak di lapisan-lapisan jaringan berikutnya (C. Y. Wang *et al.*, 2023). Penyederhanaan ini bertujuan agar data yang sangat besar bisa diolah lebih efisien tanpa kehilangan informasi penting yang dibutuhkan untuk proses klasifikasi atau deteksi objek. Setiap filter secara efektif mengekstrak fitur yang berbeda, seperti pola warna, bentuk, atau tekstur, yang dioptimalkan untuk meningkatkan performa model (Bochkovskiy *et al.*, 2020). Proses ekstraksi fitur ini membantu jaringan memfokuskan pada fitur yang paling relevan untuk tugas tertentu, sambil mengurangi detail yang kurang penting sehingga jaringan saraf dapat memproses informasi secara lebih efisien, memungkinkan peningkatan akurasi dan kecepatan klasifikasi (C. Y. Wang *et al.*, 2023). Metode ini telah terbukti menjadi tulang punggung dari berbagai model *deep learning* modern yang digunakan dalam deteksi objek, segmentasi gambar, dan klasifikasi, termasuk dalam algoritma seperti YOLOv5, YOLOv8, dan YOLOv10, yang terus memperbarui teknik ekstraksi fitur untuk meningkatkan akurasi dan efisiensi komputasi.

2.11.2 *Convolutional layer*

Convolutional layer merupakan komponen inti dari arsitektur CNN yang berfungsi untuk menyederhanakan representasi nilai-nilai piksel dari gambar input sambil tetap mempertahankan karakteristik penting dari gambar tersebut (C. Y. Wang *et al.*, 2023). Gambar input biasanya tersusun dari kumpulan piksel yang membentuk sebuah array multidimensi. *Array* ini sering kali sangat besar dan sulit untuk diolah secara langsung, sehingga dalam lapisan konvolusi digunakan *filter* atau *kernel* yang bertujuan untuk mengekstraksi fitur utama dari gambar dengan cara melakukan operasi konvolusi, yaitu perkalian matriks antara nilai piksel gambar dan bobot filter yang sudah dilatih. Setiap filter memiliki tugas spesifik untuk mengekstraksi fitur tertentu, seperti tepi, sudut, tekstur, atau pola warna yang ada pada gambar. Hasil dari operasi konvolusi ini adalah *feature map*, yang menyimpan informasi penting dari objek di gambar, sambil menyederhanakan kompleksitas gambar asli (Bochkovskiy *et al.*, 2020). *Feature map* memberikan representasi yang lebih terstruktur dari gambar dan membantu jaringan untuk memfokuskan analisis pada aspek-aspek yang paling relevan bagi tugas yang sedang dikerjakan,

seperti klasifikasi atau deteksi objek sehingga jaringan saraf dapat lebih efisien dalam memahami informasi visual, karena hanya fitur yang penting dan relevan yang diolah dan dipertimbangkan untuk langkah-langkah selanjutnya. *Convolutional layer* membantu menyaring informasi yang tidak penting atau redundan, sehingga dapat meningkatkan efisiensi komputasi dan performa model secara keseluruhan (C. Y. Wang *et al.*, 2023). Lapisan ini memungkinkan model untuk secara otomatis belajar dari data gambar tanpa memerlukan ekstraksi fitur secara manual, membuatnya sangat kuat dalam berbagai aplikasi *vision-based AI*, seperti pengenalan wajah, klasifikasi gambar, dan segmentasi.


2.11.3 *Pooling Layer*

Pooling layer adalah komponen penting dalam CNN yang bertugas mengurangi ukuran *feature map* yang dihasilkan oleh *convolutional layer* tanpa kehilangan informasi penting. *Pooling* membantu jaringan untuk menyederhanakan dan mengurangi dimensi peta fitur, yang memungkinkan pemrosesan data secara lebih efisien dan mempercepat perhitungan komputasi (Gholamalinezhad & Khosravi, 2020). Operasi *pooling* juga berkontribusi pada penciptaan *translation invariance*, sehingga jaringan tetap dapat mengenali objek meskipun ada pergeseran kecil pada gambar input (Krizhevsky *et al.*, 2021). Ada dua metode *pooling* yang umum digunakan, yaitu *Max Pooling* dan *Average Pooling*. *Max Pooling* adalah nilai terbesar dalam setiap area yang telah dibagi secara teratur dari peta fitur dipilih, sehingga jaringan dapat lebih fokus pada fitur dominan, seperti tepi atau sudut objek. Ini sangat membantu dalam menjaga fitur-fitur kuat yang paling relevan untuk pengenalan objek dan mengurangi sensitivitas jaringan terhadap gangguan atau *noise* pada gambar (Zhou *et al.*, 2020). *Max Pooling* telah terbukti efektif dalam mencegah *overfitting* dengan mengurangi dimensi peta fitur secara signifikan. *Average Pooling* bekerja dengan menghitung nilai rata-rata dari setiap area yang dibagi, memberikan pendekatan yang lebih seimbang dengan mempertimbangkan keseluruhan distribusi fitur dalam area tersebut (Zhou *et al.*, 2020). *Average Pooling* mungkin tidak seefektif *Max Pooling* dalam menyoroti fitur-fitur paling dominan, metode ini berguna dalam menjaga distribusi fitur secara lebih halus dan merata pada gambar yang memiliki detail yang tersebar di berbagai

bagian. Kedua metode *pooling* ini penting dalam menyederhanakan data yang diproses, membantu jaringan saraf tiruan untuk fokus pada informasi yang paling penting, sekaligus mempercepat langkah-langkah selanjutnya dalam arsitektur jaringan.

2.11.4 *Fully-connected Layer*

Fully-connected layer merupakan bagian akhir dari CNN, lapisan ini memastikan bahwa setiap neuron di lapisan tersebut terhubung dengan semua neuron pada lapisan sebelumnya. *Feature map* multidimensi yang dihasilkan dari lapisan-lapisan sebelumnya diubah menjadi vektor satu dimensi melalui proses yang disebut *flattening* yang tujuannya adalah untuk mempersiapkan data agar bisa digunakan dalam tugas-tugas klasifikasi, di mana setiap neuron membawa informasi penting dari data yang telah diproses. Fungsi aktivasi yang umumnya digunakan dalam CNN adalah ReLU (*Rectified Linear Unit*) dan *Softmax Activation*. ReLU adalah fungsi aktivasi yang banyak digunakan pada CNN, terutama setelah lapisan konvolusi. Fungsi aktivasi ReLU bekerja dengan mengeluarkan nilai nol jika input yang diterima adalah nol atau kurang dari nol, sedangkan untuk input positif, fungsi ini mengeluarkan nilai input tersebut tanpa perubahan (Wao & Soni, 2021). Hal ini memungkinkan jaringan untuk menangani data dengan pola yang lebih kompleks, serta mencegah masalah seperti *vanishing gradient* yang sering muncul pada jaringan yang lebih dalam. Kelebihan ReLU terletak pada kemampuannya untuk mempercepat proses pelatihan, karena kesederhanaannya dalam perhitungan.

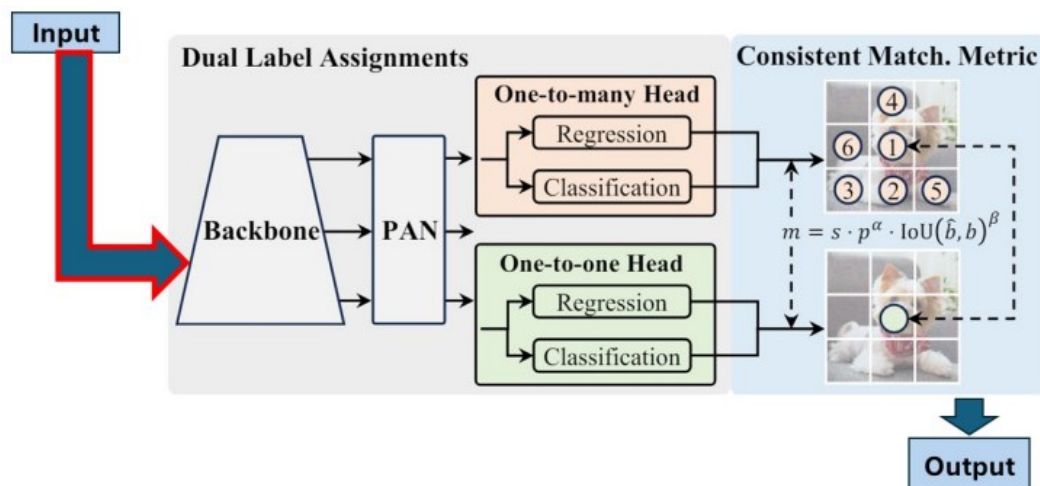


Gambar 14. Grafik representasi ReLU (Wao & Soni, 2021).

Softmax merupakan fungsi aktivasi yang sering digunakan pada lapisan akhir jaringan saraf, terutama dalam tugas-tugas klasifikasi multikelas. Fungsi ini sangat berguna ketika jaringan saraf harus membedakan lebih dari satu kelas output, karena ia mengubah nilai keluaran menjadi probabilitas untuk setiap kelas yang tersedia (Shatravin *et al.*, 2023).

2.12 YOLOv10

YOLOv10 merupakan versi terkini dari rangkaian model deteksi objek YOLO, yang terus berkembang dari versi awalnya, seperti YOLOv8, YOLO NAS, hingga YOLOv9 (Vijayakumar *et al.*, 2024). Model ini memperkenalkan beberapa peningkatan penting dibandingkan pendahulunya, seperti peningkatan kecepatan dan akurasi, terutama dalam menangani adegan yang lebih kompleks. Fitur utama YOLOv10 adalah kemampuannya untuk melakukan deteksi objek secara *end-to-end*, tanpa memerlukan langkah pasca-pemrosesan seperti *non-maximum suppression* (NMS) yang membuat YOLOv10 berhasil mengurangi latensi, sehingga YOLOv10 sangat efektif untuk aplikasi *real-time*.



Gambar 15. Arsitektur YOLOv10 (Sapkota *et al.*, 2024).

Pada Gambar 5, model ini menggambarkan arsitektur jaringan saraf tiruan yang digunakan untuk mendeteksi objek, dengan fokus pada sistem *dual label assignments*. Bagian *Backbone* bertugas sebagai lapisan ekstraksi fitur yang memproses gambar input. Gambar yang dimasukkan dianalisis untuk mengidentifikasi ciri-ciri penting, seperti tepi, bentuk, dan tekstur. *Backbone* ini bisa menggunakan arsitektur populer seperti *ResNet* atau *CSPDarknet* untuk meningkatkan efektivitas ekstraksi fitur. Fitur yang diekstraksi oleh *backbone* diteruskan ke *Path Aggregation Network (PAN)*. PAN berperan dalam menggabungkan fitur dari berbagai lapisan jaringan, yang memungkinkan model mendeteksi objek dengan ukuran berbeda, baik yang besar maupun yang kecil, dengan lebih akurat. *Dual Label Assignments* memiliki dua jalur deteksi yang berbeda, yaitu *One-to-many head* dan *One-to-one head*. Pada *one-to-many head*, model melakukan regresi dan klasifikasi dengan memberikan beberapa *bounding box* atau kotak deteksi kepada setiap objek di dalam gambar, hal ini bertujuan untuk memastikan bahwa semua kemungkinan lokasi objek dapat terdeteksi. *One-to-one head* berfokus hanya pada satu *bounding box* untuk setiap objek, sehingga deteksi menjadi lebih tepat dengan menghilangkan prediksi yang berlebihan. *Consistent Match Metric* digunakan untuk menghitung konsistensi antara hasil deteksi dan objek asli yang terdapat dalam gambar (*ground truth*). Proses ini melibatkan perhitungan skor keyakinan (s), probabilitas prediksi (p), serta *IoU (Intersection over Union)*, yaitu ukuran tumpang tindih antara kotak deteksi dan kotak asli dari objek. Parameter α dan β digunakan untuk menyeimbangkan pengaruh antara probabilitas dan *IoU*, memastikan bahwa deteksi yang dihasilkan akurat dan relevan. Hasil dari seluruh proses ini akan menghasilkan output berupa deteksi objek dengan posisi dan klasifikasi yang tepat, yang ditunjukkan oleh *bounding box* dan label pada gambar.

2.13 Preprocessing Data

Preprocessing Data adalah langkah awal yang penting dalam *machine learning*, di mana data yang mentah dibersihkan dan diolah agar sesuai dengan kebutuhan

model. Hal-hal seperti penanganan data yang hilang (*missing values*), normalisasi, pengkodean variabel kategorikal, dan penghapusan outlier dilakukan yang tujuannya adalah untuk meningkatkan kualitas data sehingga model dapat belajar dengan lebih efektif. Data yang diproses dengan baik akan membantu model mencapai performa yang lebih baik, karena meminimalkan *noise* yang dapat mengganggu proses pelatihan (*training*). Proses *preprocessing* juga memastikan bahwa input data memiliki format yang konsisten, sesuai dengan yang dibutuhkan model untuk melakukan inferensi yang akurat (Long *et al.*, 2021).

2.13.1 *Resizing* gambar

Resizing gambar merupakan teknik dasar dalam pengolahan gambar yang digunakan untuk menyesuaikan ukuran gambar input dengan dimensi yang diinginkan oleh model *deep learning*. Hal ini penting karena sebagian besar arsitektur CNN membutuhkan ukuran gambar input yang konsisten, misalnya 224x224 piksel atau 640x640 piksel, tergantung dari spesifikasi model. *Resizing* dilakukan untuk menurunkan resolusi gambar yang besar atau memperkecil ukuran gambar tanpa mengubah aspek rasio terlalu banyak (Talebi & Milanfar, 2021).

2.13.2 Augmentasi data

Augmentasi data adalah proses penting dalam pembelajaran mesin dan visi komputer yang bertujuan menciptakan variasi dari data yang ada untuk meningkatkan jumlah dan keragaman data pelatihan tanpa perlu mengumpulkan data baru. Teknik augmentasi ini sering digunakan pada data gambar, namun juga dapat diterapkan pada data teks, suara, dan lainnya. Transformasi yang umum digunakan mencakup rotasi, *flipping* (baik secara *horizontal* maupun *vertikal*), penyesuaian kontras atau kecerahan, serta penambahan *noise*. Teknik ini membantu model untuk lebih tahan terhadap berbagai kondisi yang mungkin terjadi di dunia nyata, sehingga dapat meningkatkan generalisasi model ketika diaplikasikan pada data baru. Gambar yang dilatih dengan augmentasi rotasi akan membantu model mengenali objek dari berbagai sudut, sedangkan penambahan *noise* membantu model untuk menangani data yang tidak bersih atau mengandung gangguan (Shorten & Khoshgoftaar, 2019). Penggunaan augmentasi data telah berkembang

dalam beberapa tahun terakhir dengan munculnya teknik-teknik yang lebih maju, seperti *Cutout*, *Mixup*, dan *CutMix*, yang memperkenalkan variasi yang lebih kompleks pada data pelatihan (Yun *et al.*, 2019). *CutMix* mengambil dua gambar dan menggabungkannya dengan cara memotong sebagian dari satu gambar dan menempelkannya ke gambar lainnya, yang secara efektif meningkatkan kemampuan model untuk mengenali objek di lingkungan yang tumpang tindih atau *occluded*.

Fungsi dari adanya augmentasi data di mana masalah *overfitting* model terlalu terpaku pada pola spesifik dari data pelatihan dan tidak dapat bekerja baik pada data baru dapat diminimalisasi. Hal ini karena augmentasi menciptakan variasi yang lebih luas dari data pelatihan, yang memperkuat kemampuan generalisasi model. Penelitian terbaru menunjukkan bahwa augmentasi data mampu meningkatkan performa model secara signifikan, terutama dalam kondisi ketika jumlah data pelatihan terbatas (J. Wang & Perez, 2017). Pada tugas deteksi objek atau klasifikasi gambar, augmentasi data memungkinkan model untuk belajar menghadapi berbagai variasi objek, seperti perubahan sudut pandang, pencahayaan, atau skala, yang sering kali ditemukan pada kondisi nyata.

2.14 *Hyperparameter*

Hyperparameter adalah parameter penting dalam pembelajaran mesin yang nilainya ditetapkan sebelum proses pelatihan model dimulai dan tidak berubah selama pelatihan berlangsung. Contoh umum dari *hyperparameter* mencakup jumlah *epoch* yaitu jumlah kali seluruh dataset dilalui selama pelatihan, *batch-size* yaitu jumlah sampel data yang diproses secara bersamaan, jenis *optimizer* yaitu algoritma yang digunakan untuk memperbarui bobot model, dan *learning-rate* yaitu seberapa besar perubahan bobot yang dilakukan pada setiap iterasi. Pemilihan *hyperparameter* yang tepat sangatlah krusial karena memengaruhi seberapa baik model mampu belajar dari data, kecepatan model dalam mencapai konvergensi, dan juga mencegah masalah seperti *overfitting* atau *underfitting* (Elsken *et al.*, 2019). Proses pencarian *hyperparameter* optimal sering disebut sebagai *hyperparameter tuning*, yang dapat dilakukan secara manual atau otomatis. Secara manual ini

melibatkan eksperimen berulang dengan menguji berbagai kombinasi hyperparameter dan menilai performa model pada setiap kombinasi. Metode otomatis yang lebih canggih, seperti *grid search*, secara sistematis mencoba setiap kombinasi dari rentang nilai hyperparameter yang telah ditentukan, sementara *random search* memilih nilai hyperparameter secara acak dalam ruang pencarian.

2.14.1 Epoch

Epoch menandakan satu kali proses pelatihan pada seluruh dataset. Bobot model diinisialisasi ketika pelatihan dimulai dan diperbarui setiap kali epoch selesai pada dataset yang sama (Das & Das, 2023). Ketika model mengalami *overfitting*, model akan mempelajari noise yang tidak diinginkan, sementara model yang *underfitting* tidak akan mempelajari pola secara menyeluruh (Afaq & Rao, 2020). Proses ini terdiri dari melatih model pada semua data dalam dataset kemudian menghitung pembaruan parameter model berdasarkan kesalahan yang diamati. Dalam konteks pembelajaran mendalam, penggunaan epoch bertujuan untuk mengurangi kesalahan dan meningkatkan akurasi prediksi melalui iterasi berulang. Setiap epoch memungkinkan model untuk belajar dari pola yang ada di dataset, namun jumlah epoch yang tidak tepat dapat menyebabkan *overfitting* atau *underfitting*. *Overfitting* terjadi ketika model belajar terlalu banyak pada detail spesifik data latih, sementara *underfitting* terjadi jika model tidak belajar cukup banyak untuk menangkap pola yang mendasar dalam data (K. L. Du *et al.*, 2022).

2.14.2 Batch-size

Batch-size dalam pembelajaran mesin mengacu pada jumlah contoh pelatihan yang diproses secara bersamaan dalam satu iterasi sebelum model diperbarui. *Batch-size* merupakan *hyperparameter* penting yang mempengaruhi dinamika pelatihan, seperti konsumsi memori, kecepatan konvergensi, dan kemampuan generalisasi model (Hwang *et al.*, 2024). Ukuran *batch* yang lebih kecil biasanya memberikan pembaruan gradien yang lebih akurat, sehingga dapat meningkatkan kemampuan model untuk menggeneralisasi, meskipun memerlukan lebih banyak iterasi karena waktu pelatihan yang lebih lama. Sebaliknya, ukuran batch yang lebih besar dapat mempercepat pelatihan dengan memungkinkan perhitungan yang lebih cepat, tetapi

berisiko mengalami *overfitting* karena mungkin tidak menangkap variasi dalam data secara efektif. Pemilihan *Batch-size* yang optimal sangat mempengaruhi kinerja model, tergantung pada karakteristik masalah dan dataset.

2.14.3 *Optimizer*

Optimizer adalah algoritma yang berperan penting dalam pembelajaran mesin, bertujuan untuk menyesuaikan bobot jaringan guna meminimalkan fungsi kesalahan (*loss function*). *Optimizer* bekerja dengan memperbarui parameter model secara iteratif sehingga dapat mencapai solusi optimal dalam waktu yang efisien. Berbagai jenis *optimizer* seperti *Stochastic Gradient Descent* (SGD), Adam, dan RMSprop, memiliki metode unik untuk memperbarui bobot berdasarkan gradien serta *learning-rate*, yang secara langsung mempengaruhi kecepatan dan efektivitas pelatihan model. SGD mengandalkan pembaruan secara stokastik untuk mengurangi *overfitting* dengan memperkecil langkah perubahan parameter, sedangkan Adam menggabungkan kecepatan adaptif untuk meningkatkan konvergensi pada model non-stasioner. Penggunaan *optimizer* juga dipengaruhi oleh kompleksitas permasalahan yang dihadapi, di mana teknik optimasi evolusioner sering digunakan dalam menghadapi masalah yang kompleks karena kemampuannya untuk keluar dari *local optima* dengan biaya komputasi yang lebih rendah (L. Yang *et al.*, 2022).

2.14.4 *Learning-rate*

Learning-rate dalam *deep learning* merupakan salah satu hyperparameter paling penting yang mengontrol seberapa besar perubahan bobot pada setiap iterasi pembaruan jaringan saraf. Nilai dari *learning-rate* yang tepat sangat menentukan efektivitas proses pelatihan model. Nilai *learning-rate* yang terlalu kecil mengakibatkan proses pelatihan akan menjadi sangat lambat dan rentan terjebak di titik-titik minimum lokal (*saddle points*) (Deng *et al.*, 2021). Sebaliknya, jika *learning-rate* terlalu besar, model bisa gagal mencapai konvergensi karena perubahan bobot yang terlalu besar menyebabkan pembelajaran menjadi tidak stabil.

2.15 Confusion Matrix

Confusion Matrix berperan dalam memberikan gambaran visual tentang performa model klasifikasi dengan menunjukkan seberapa baik model memprediksi kelas-kelas tertentu. Matriks ini membantu mengidentifikasi kesalahan yang dibuat oleh model dan mengukur seberapa akurat model dalam membedakan antara kelas objek. Matriks ini menampilkan jumlah prediksi yang benar dan salah untuk setiap kelas, *Confusion Matrix* memberikan informasi penting tentang ukuran evaluasi seperti akurasi, *precision*, *recall*, dan *F1-Score*. Matriks ini terdiri dari empat komponen utama: *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*, yang menunjukkan kesalahan ketika model gagal mendeteksi kelas positif yang sebenarnya. Informasi yang disajikan dalam matriks ini sangat penting untuk mengevaluasi secara komprehensif kinerja model klasifikasi dalam situasi yang berbeda dan memperbaiki kelemahan dalam proses prediksi (Maxwell *et al.*, 2021).

Tabel 1. Nilai matriks utama dari *Confusion Matrix*

Nilai Prediksi		Nilai Sebenarnya	
		Positive TP	Negative FP
	Positive		
	Negative	FN	TN

Keterangan:

1. *True Positive*: mengacu pada jumlah kasus yang secara benar diklasifikasikan sebagai positif oleh model.
2. *False Positive*: mengacu pada jumlah kasus yang secara salah diklasifikasikan sebagai positif oleh model.
3. *True Negative*: mengacu pada jumlah kasus yang secara benar diklasifikasikan sebagai negatif oleh model
4. *False Negative*: mengacu pada jumlah kasus yang secara salah diklasifikasikan sebagai negatif oleh model

2.15.1 *F1-Score*

F1-score adalah ukuran kinerja yang digunakan untuk menilai kualitas suatu sistem klasifikasi, terutama ketika ada ketidakseimbangan antara kelas positif dan negatif. *F1-score* merupakan rata-rata harmonik dari *precision* dan *recall*, sehingga memberikan keseimbangan antara keduanya. *Precision* menunjukkan seberapa banyak prediksi positif yang benar-benar relevan, sementara *recall* menunjukkan seberapa banyak data relevan yang berhasil terdeteksi oleh sistem (Y. Yang, 1999). Kondisi di mana *precision* dan *recall* memiliki nilai yang sama, nilai tersebut dikenal sebagai titik keseimbangan (*break-even point*), namun jika nilai *precision* dan *recall* tidak bisa dibuat persis sama, maka digunakan interpolasi untuk mendapatkan nilai rata-rata terdekat sebagai titik keseimbangan yang disesuaikan. Masalah dengan pendekatan ini adalah jika nilai *precision* dan *recall* yang terdekat sangat berjauhan, maka nilai interpolasi mungkin tidak mencerminkan perilaku sistem yang sebenarnya.

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

2.15.2 *Accuracy*

Accuracy adalah ukuran kinerja yang menunjukkan proporsi prediksi yang benar dari keseluruhan prediksi. Akurasi dihitung sebagai jumlah kasus benar (baik positif benar maupun negatif benar) dibagi dengan total jumlah sampel. Akurasi sering digunakan untuk mengevaluasi kinerja sistem klasifikasi, metrik ini memiliki kelemahan ketika diterapkan pada kasus tertentu, seperti klasifikasi teks dengan banyak kategori (Y. Yang, 1999).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

2.15.3 *Recall*

Recall mengukur seberapa banyak kategori yang relevan atau benar ditemukan oleh sistem dibandingkan dengan total kategori yang sebenarnya benar. *Recall*

menunjukkan kemampuan sistem dalam mendeteksi semua kategori yang relevan. Semakin tinggi nilai *recall*, semakin baik sistem dalam mengenali semua kategori yang relevan (Y. Yang, 1999).

$$Recall = \frac{TP}{TP+FN}$$

2.15.4 Precision

Precision mengukur seberapa banyak kategori yang ditemukan oleh sistem benar-benar relevan dibandingkan dengan total kategori yang ditemukan. *Precision* mengindikasikan seberapa akurat sistem dalam menghasilkan prediksi yang benar. Semakin tinggi nilai *precision*, semakin baik kemampuan sistem dalam memastikan bahwa hasil yang ditemukan memang relevan (Y. Yang, 1999).

$$Precision = \frac{TP}{TP+FP}$$

III. METODE PENELITIAN

3.1 Waktu dan Tempat

Waktu dan tempat penelitian ini adalah sebagai berikut:

3.1.1 Waktu Penelitian

Penelitian dilakukan dari November tahun 2024 sampai dengan November tahun 2025. Waktu penelitian dijelaskan dengan tabel 2 dibawah ini.

Tabel 2. Jadwal Penelitian

Nama Kegiatan	2024/2025 s.d 2025/2026												
	November	Desember	Januari	Februari	Maret	April	Mei	Juni	Juli	Agustus	September	Oktober	November
Pengumpulan Dataset	█												
Pemrograman Model YOLOv10		█	█	█	█								
Pengujian Dataset						█							
Pengembangan Aplikasi	█	█	█	█	█	█	█	█	█	█	█	█	█
Penulisan Laporan													█

3.1.2 Tempat Penelitian

Penelitian ini dilaksanakan di gedung Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), blok tradisional Unit Pelaksana Teknis Daerah Kesatuan Pengelolaan Hutan Konservasi (UPTD KPHK) Tahura WAR Kelurahan Sumber Agung,

Kecamatan Kemiling, Kota Bandar Lampung, Lampung, dan Youth Camp Tahura WAR Desa Hurun, Kecamatan Teluk Pandan, Kabupaten Pesawaran, Lampung.

3.2 Alat dan Bahan

Beberapa bahan dan alat yang dipakai dalam penelitian ini diantaranya:

3.2.1 Alat Penelitian

Peralatan yang dipakai untuk penelitian ini adalah:

3.2.1.1 Perangkat Lunak

Perangkat lunak (*software*) yang dipakai sebagai pendukung dalam proses penelitian pengembangan aplikasi *mobile* pemindai *real-time* untuk identifikasi kerapatan dan transparansi tajuk pohon menggunakan YOLOv10 adalah sistem operasi *Windows 11 Home Single 64-bit*, *Visual Studio Code*, *Google Colab*, *Anaconda*, dan *Google Drive*.

3.2.1.2 Perangkat Keras

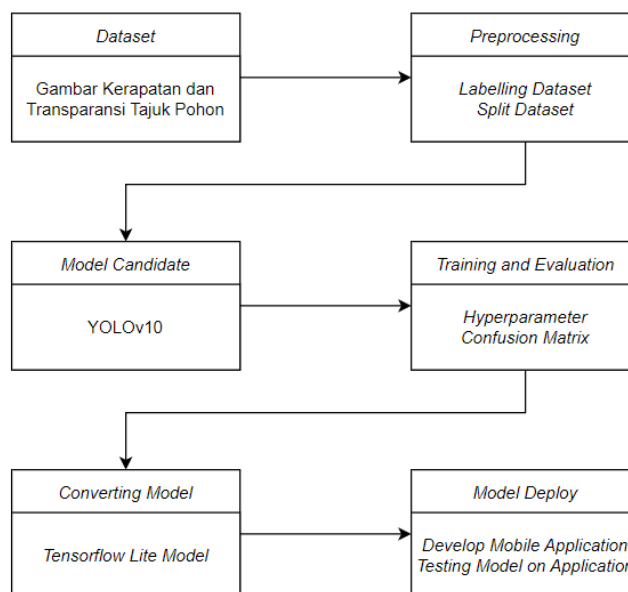
Perangkat keras (*hardware*) yang dipakai sebagai pendukung dalam proses penelitian pengembangan aplikasi *mobile* pemindai *real-time* untuk identifikasi kerapatan dan transparansi tajuk pohon menggunakan YOLOv10 adalah Laptop Lenovo Ideapad Gaming 3 dengan spesifikasi RAM 16 GB, SSD 1.5 TB, *processor* Ryzen 5 4600H, VGA GTX 1650 VRAM 4 GB, *Personal Computer* dengan spesifikasi RAM 32 GB, SSD 4 TB, *processor* Ryzen 5 7600X, VGA RTX 3060 VRAM 12 GB, Laptop ASUS ROG Flow X13 dengan spesifikasi RAM 16 GB, SSD 512 GB, *processor* Ryzen 9 5900HS, VGA RTX 3050 VRAM 4 GB, *Handphone* Redmi Note 7, dan *Handphone* Poco F4.

3.2.2 Bahan Penelitian

Penelitian ini memanfaatkan *dataset* dari beberapa penelitian sebelumnya oleh; Tarigan *et al.*, (2023), Octarina *et al.*, (2023), Sriaatna *et al.*, (2024), dan Sofiyana *et al.*, (2023) dan ditambah 2 *dataset* tambahan berupa 1.000 citra yang diambil di Youth Camp Tahura WAR Desa Hurun, Kecamatan Teluk Pandan, Kabupaten

Pesawaran, Lampung. Penelitian ini menggunakan sepuluh jenis variasi pohon yang digunakan, di mana setiap variasi terdiri dari lima ratus gambar, masing-masing dibagi menjadi sepuluh kategori yang berbeda berdasarkan kelas kerapatan dan transparansi tajuk pohon, dimana setiap kategori mengandung lima puluh gambar.

3.3 Metode Penelitian



Gambar 16. Metode Penelitian (Carvalho *et al.*, 2022).

Metode penelitian yang dilakukan dalam penelitian ini mengambil referensi dari penelitian terdahulu oleh (Carvalho *et al.*, 2022) tentang pengembangan aplikasi *mobile* pemetaan spesies pohon berbasis *Deep Learning*. Tahapan yang dilakukan pada penelitian ini dapat dilihat pada gambar 6 dan dijelaskan sebagai berikut:

3.3.1 Dataset

Dataset digunakan untuk melatih mesin untuk memahami karakteristik tiap kelas kerapatan dan transparansi tajuk pohon. *Dataset* yang terkumpul berjumlah 5.000 citra kerapatan dan transparansi tajuk pohon dengan 10 kelas parameter yang terdapat 500 gambar di tiap kelasnya. Kelas tersebut meliputi:

- Level 1 = CD 5% - FT 95%
- Level 2 = CD 15% - FT 85%

- Level 3 = *CD 25% - FT 75%*
- Level 4 = *CD 35% - FT 65%*
- Level 5 = *CD 45% - FT 55%*
- Level 6 = *CD 55% - FT 45%*
- Level 7 = *CD 65% - FT 35%*
- Level 8 = *CD 75% - FT 25%*
- Level 9 = *CD 85% - FT 15%*
- Level 10 = *CD 95% - FT 5%*

Penamaan CD dan FT pada kelas kelas ditujukan untuk meringkas nama dua parameter yang digunakan dalam penelitian ini yaitu *Crown Density* (CD) dan *Foliage Transparency* (FT) (Olson *et al.*, 2026). Kelas kelas diatas mewakili persentasi kerapatan dan transparansi pohon yang terdapat dalam *Dataset* semakin besar FT maka akan semakin kecil CD, dan sebaliknya.

3.3.2 Preprocessing

Preprocessing adalah tahapan yang mengolah data mentah ke dalam bentuk yang lebih mudah dipahami. Tahapan ini diawali dengan penyisihan dataset secara *random* dengan menggunakan metode *Under Sampling* untuk mengurangi jumlah data yang berlebihan demi mempertahankan keseimbangan data dikarenakan ada ketidakseimbangan jumlah pada data mentah. Tahapan selanjutnya adalah penyamaan ukuran gambar untuk memiliki ukuran yang sama yaitu 224x224. Tahapan selanjutnya adalah augmentasi data, dalam penelitian ini akan dilakukan augmentasi dengan beberapa teknik yaitu *flip*, *zoom*, dan *rotate*. Tahapan terakhir dilakukan dengan menggunakan *website* CVAT dengan melakukan *Labelling Dataset* dan dilanjutkan ke proses *Split Dataset*.

3.3.2.1 Labelling Dataset

Labelling Dataset adalah tahapan pemberian label yang sama pada sekumpulan *pixel* pembentuk objek yang membentuk suatu citra. *Labelling Dataset* pada citra bertujuan untuk memberikan *Bounding Box* pada citra guna mempermudah mesin menganalisa objek pada citra. *Labelling Dataset* dapat dilihat pada gambar 7.



Gambar 17. Proses *Labelling Data*.

3.3.2.2 Split Dataset

Split Dataset adalah tahapan untuk membagi data menjadi 3 bagian, yaitu data *Training*, data *Validation*, dan data *Testing*. *Split Dataset* diperlukan sebagai bahan utama dalam melatih data. 70% dari seluruh *dataset* digunakan sebagai data *Training*. Data *Validation* diperlukan untuk mempermudah langkah selama pelatihan data menggunakan data *Training*. Data yang sudah dilatih divalidasi menggunakan data *Validation*. 10% dari seluruh *dataset* digunakan sebagai data *Validation*. Data *Testing* digunakan untuk menguji model yang sudah dilatih. 20% dari seluruh *dataset* digunakan sebagai data *Testing*.

3.3.3 Model Candidate

Penelitian ini akan menggunakan YOLOv10 sebagai model algoritma. YOLOv10 akan digunakan sebagai model untuk mendeteksi kerapatan dan transparansi tajuk pohon secara *real-time*.

3.3.4 Training and Evaluation

Penelitian ini akan membagi langkah selanjutnya menjadi dua bagian, yaitu:

3.3.4.1 Training Model

Training Model dilakukan dengan mengolah sebanyak 70% dari total *dataset*, dengan resolusi 224x224 *pixel*. *Tools* yang akan digunakan dalam pelatihan model adalah *Anaconda Prompt* sebagai *Virtual Environment Python* dan *Google Colab* sebagai media untuk konversi model ke dalam *Tensorflow Lite*. *Hyperparameter* yang akan digunakan dalam pelatihan dapat dilihat pada tabel 3.

tabel 3. Tabel *Hyperparameter*

No	Nama Parameter	Nilai
1	<i>Epoch</i>	100
2	<i>Batch-size</i>	8
3	<i>Optimizer</i>	SGD
4	<i>Learning-rate</i>	0.001
5	<i>Automatic Mixed Precision (AMP)</i>	<i>True</i>

Keterangan tabel:

Epoch berjumlah 100 didasari oleh pengujian sebelumnya dengan hasil yang kurang optimal yaitu dengan *Epoch* 10, peningkatan *Epoch* digunakan untuk menguji apakah hasil yang didapatkan sesuai dengan harapan. *Batch-size* berjumlah 8 digunakan untuk mempercepat proses *Training Model*. Penggunaan *Optimizer* SGD dan *Learning-rate* berdasarkan pengamatan yang telah dilakukan selama penelitian yang menunjukkan hasil yang lebih optimal dan konsisten.

3.3.4.2 Evaluation Model

Evaluation Model dilakukan dengan melihat *Confusion Matrix*. *Confusion Matrix* didapat setelah pelatihan model selesai. Pengujian model akan menggunakan data *Testing* untuk menunjukkan keberhasilan model dalam memprediksi suatu objek. Hasil dari keberhasilan model dapat dianalisa menggunakan *Confusion Matrix* dengan menentukan besar *Accurary*, *F1-score*, *recall*, dan *Precision*.

3.3.5 Converting Model

Converting Model adalah tahapan untuk mengkonversi model yang sudah dilatih ke format *Tensorflow Lite*, tahapan ini dilakukan agar model dapat digunakan pada aplikasi *mobile* tanpa melalui sebuah perantara. Tahapan ini dilakukan dengan memanfaatkan *Library Tensorflow* pada *Python*.

3.4 Model Deploy

Model Deploy adalah tahapan untuk membuat aplikasi *mobile* dapat menjalankan model yang sudah dikonversi dalam format *Tensorflow Lite*. Tahapan ini akan dilakukan dalam 2 proses yaitu *Develop Mobile Application* dan *Testing Model on Mobile Application*.

3.4.1 Develop Mobile Application

Develop Mobile Application adalah tahapan pengembangan aplikasi *mobile*. Aplikasi ini akan dikembangkan dengan bahasa pemrograman *Kotlin*. Tahapan ini berfokus pada aplikasi yang dapat menampilkan hasil deteksi dari model YOLOv10. Tahapan ini memerlukan hasil konversi model ke dalam *Tensorflow Lite*. *Package* ini dapat membuat model YOLOv10 dapat berjalan di aplikasi *mobile*. Tahapan ini dimulai dengan menentukan tujuan dari pengembangan aplikasi tersebut yaitu mempermudah dalam pendeteksian kerapatan dan transparansi tajuk pohon. Kebutuhan fungsional dari aplikasi dapat dilihat pada tabel 4.

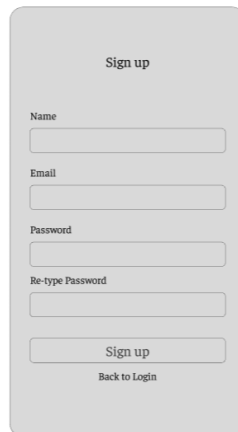
tabel 4. Tabel Kebutuhan Fitur

No	Fitur	Deskripsi
1	<i>Register</i>	Fitur ini memungkinkan pengguna baru untuk membuat akun dengan memasukkan informasi pribadi seperti nama, <i>email</i> , dan kata sandi.

No	Fitur	Deskripsi
2	<i>Login</i>	Pengguna dapat masuk ke aplikasi dengan kredensial yang sudah terdaftar untuk mengakses fitur-fitur lainnya.
3	<i>Forgot Password</i>	Fitur ini membantu pengguna yang lupa kata sandinya dengan mengirimkan tautan pemulihan melalui <i>email</i> .
4	<i>Session</i>	Mengelola sesi pengguna yang sedang aktif untuk menjaga keamanan dan menjaga aktivitas pengguna selama menggunakan aplikasi.
5	<i>Logout</i>	Pengguna dapat keluar dari akun mereka dengan aman untuk mengakhiri sesi penggunaan.
6	<i>Detector</i>	Fitur utama aplikasi untuk memindai dan mendeteksi kerapatan serta transparansi tajuk pohon secara <i>real-time</i> .
7	<i>Export</i>	Fitur ini memungkinkan pengguna mengeksport data hasil pemindaian.
8	<i>Gallery</i>	Menyimpan dan menampilkan hasil pemindaian sebelumnya agar pengguna dapat mengaksesnya kapan saja.
9	<i>FAQ</i>	Bagian yang berisi jawaban atas pertanyaan-pertanyaan yang sering diajukan terkait penggunaan aplikasi.
10	<i>About</i>	Menyediakan informasi tentang pengembang aplikasi

Prototype aplikasi dilakukan untuk mempermudah proses pengembangan aplikasi sehingga lebih terarah dan memiliki gambaran saat proses pengembangan dilakukan. *Prototype* aplikasi dirujuk dari kebutuhan fungsional pada tabel 4. *Prototype* terdiri dari 10 fitur utama yaitu:

3.4.1.1 Register

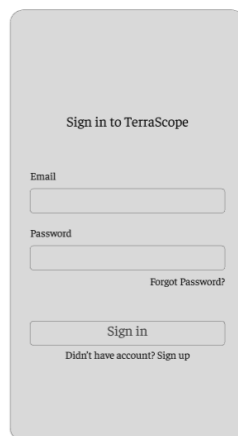


The image shows a mobile application registration screen. At the top, it says "Sign up". Below this, there are four input fields: "Name", "Email", "Password", and "Re-type Password". Each field is represented by a rounded rectangular box. At the bottom of the form, there is a "Sign up" button and a link that says "Back to Login".

Gambar 18. Tampilan *Register*.

Tampilan *Register* pada gambar 8 merupakan halaman yang menampilkan borang pendaftaran untuk pengguna yang baru pertama kali menggunakan aplikasi.

3.4.1.2 Login

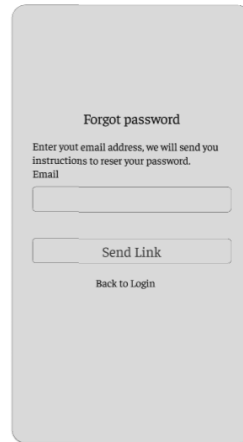


The image shows a mobile application login screen. At the top, it says "Sign in to TerraScope". Below this, there are two input fields: "Email" and "Password". Each field is represented by a rounded rectangular box. To the right of the "Password" field, there is a link that says "Forgot Password?". At the bottom of the form, there is a "Sign in" button and a link that says "Didn't have account? Sign up".

Gambar 19. Tampilan *Login*.

Tampilan *Login* pada gambar 9 merupakan halaman yang menampilkan borang *Login* untuk pengguna yang sudah terdaftar pada *database* aplikasi.

3.4.1.3 *Forgot Password*



Forgot password

Enter your email address, we will send you instructions to reset your password.

Email

Send Link

[Back to Login](#)


Gambar 20. Tampilan *Forgot Password*.

Tampilan *Forgot Password* pada gambar 10 merupakan halaman yang menampilkan borang *Forgot Password* untuk pengguna yang lupa *password* dari akun mereka.

3.4.1.4 *Session*

Session tidak memerlukan antarmuka pengguna (UI) karena *Session* adalah bagian dari pengelolaan autentikasi dan otorisasi di sisi server yang terjadi di latar belakang. Fungsinya untuk melacak aktivitas dan status pengguna selama mereka masuk ke dalam aplikasi, tanpa memerlukan interaksi langsung dari pengguna. Fokus *Session* lebih kepada keamanan dan kinerja, memastikan bahwa pengguna yang telah autentikasi tetap memiliki akses yang benar selama sesi berlangsung. Fitur *Session* pengelolaannya secara otomatis, sehingga tidak ada elemen visual yang perlu dihadirkan kepada pengguna.

3.4.1.5 Logout



Gambar 21. Tombol *Logout*.

Tombol *Logout* pada gambar 11 merupakan tombol yang akan mengakhiri sesi dari akun pengguna yang pernah *login* di sebuah perangkat.

3.4.1.6 Detector




Gambar 22. Tampilan *Detector*.

Tampilan *Detector* pada gambar 12 merupakan halaman yang menampilkan fitur utama dari aplikasi ini yaitu sebagai pendeteksi kerapatan dan transparansi tajuk pohon. Terdapat *bounding box* untuk menangkap prediksi objek yang tertangkap kamera secara *real-time* dan terdapat fitur *zoom-in* dan *zoom-out* sebagaimana fitur umum dalam sebuah kamera, *Inference Time* sebagai penanda berapa detik objek

tersebut dapat terdeteksi, *Location* sebagai penanda lokasi objek dideteksi, dan *Taken at* sebagai penanda kapan foto tersebut diambil.


3.4.1.7 *Export*



Gambar 23. Tombol *Export*.

Tombol *Export* pada gambar 13 berfungsi untuk mengunduh data hasil pemindaian yang telah dilakukan oleh pengguna dalam bentuk gambar.

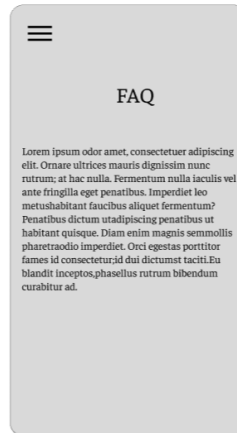
3.4.1.8 *Gallery*



Gambar 24. Tampilan *Gallery*.

Tampilan *Gallery* pada gambar 14 merupakan fitur yang menampilkan hasil pemindaian, sehingga pengguna dapat mengaksesnya kapan saja.

3.4.1.9 FAQ



Gambar 25. Tampilan *FAQ*.

Tampilan *FAQ* pada gambar 15 menyediakan informasi terkait pertanyaan yang sering diajukan oleh pengguna mengenai cara menggunakan aplikasi.

3.4.1.10 About



Gambar 26. Tampilan *About*.

Tampilan *About* pada gambar 16 berisi informasi mengenai pengembang aplikasi, termasuk tujuan pengembangan dari aplikasi.

3.4.2 Testing Model on Mobile Application

Proses ini adalah tahapan pengujian yang akan dilakukan terhadap aplikasi apakah aplikasi yang sudah dikembangkan dapat memberikan *Output* yang sesuai dengan *Output* yang sebenarnya. Tahapan ini dilakukan pada sistem operasi *Android* dan proses ini dilakukan untuk mengetahui apakah model yang sudah dilatih dapat bekerja dengan baik selama melakukan *testing*.

V. SIMPULAN DAN SARAN

5.1 Simpulan

Penelitian ini berhasil mengembangkan aplikasi *mobile* pemindai *real-time* untuk mengidentifikasi kerapatan dan transparansi tajuk pohon menggunakan algoritma YOLOv10. Aplikasi yang dihasilkan berfungsi sesuai dengan tujuan penelitian, yaitu mampu melakukan proses identifikasi secara langsung melalui perangkat *mobile*. Hasil pengujian menunjukkan bahwa aplikasi berjalan dengan baik dan dapat digunakan sebagai alat bantu dalam kegiatan pemantauan tajuk pohon di lapangan.

5.2 Saran

Penelitian ini dapat dikembangkan lebih lanjut melalui peningkatan variasi dataset untuk memperluas kemampuan model dalam mengenali berbagai kondisi tajuk pohon di lapangan. Peningkatan pada aspek antarmuka pengguna (UI) dan pengalaman pengguna (UX) juga perlu dipertimbangkan agar aplikasi lebih optimal, intuitif, serta mudah digunakan pada berbagai perangkat.

DAFTAR PUSTAKA

- Adhi, A. R. (2017). Model Pertumbuhan Jati Asal Kebun Benih Klon di KPH Ngawi. Tesis S2, Universitas Gajah Mada, Program Studi Ilmu Kehutanan, Yogyakarta.
- Abas, A. (2023). A systematic literature review on the forest health biomonitoring technique: A decade of practice, progress, and challenge. In *Frontiers in Environmental Science*. frontiersin.org.
<https://doi.org/10.3389/fenvs.2023.970730>
- Afaq, S., & Rao, S. (2020). Significance of epochs on training a neural network. In *Int. J. Sci. Technol. Res.*
- Akira, A. A., Fadila, A. A., Emnur, A. K., Aini, F. Q., Satira, G., & Fitriyyah, I. (2024). Struktur Internal Organ Reproduksi Tumbuhan Berbiji (Angiospermae dan Gymnospermae). *Mikroba: Jurnal Ilmu*
<https://journal.asritani.or.id/index.php/Mikroba/article/view/178>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. In *Journal of big Data*. Springer.
<https://doi.org/10.1186/s40537-021-00444-8>
- Andriani, M., Wahyuningsih, E., & Sutriyono, R. (2023). POLA SEBARAN DAN POTENSI SONOKELING (*Dalbergia latifolia*) DI BLOK HL KPH SEJORONG MATAIYANG NTB. *Jurnal Rimba Lestari*.
<https://journal.unram.ac.id/index.php/rimbalestari/article/view/684>
- Andriyanto, M., Wijaya, A., & Rachmawan, A. (2019). Produksi tanaman karet (*Hevea brasiliensis*) pada waktu pengumpulan lateks yang berbeda. *Jurnal Agro Estate*. <https://www.ejurnal.itsi.ac.id/index.php/JAE/article/view/61>
- Ansori, D. P., Safe'i, R., & Kaskoyo, H. (2020). Penilaian Indikator Kesehatan Hutan Rakyat pada Beberapa Pola Tanam (Studi Kasus di Desa Buana Sakti

- Kecamatan Batang Hari Kabupaten Lampung Timur). In *Jurnal Perennial*. core.ac.uk. <https://core.ac.uk/download/pdf/326775382.pdf>
- Aristoteles, A., Safe'i, R., Muludi, K., & Pratama, D. (2018). Sistem Informasi Penilaian Kesehatan Hutan Berbasis Web Dengan Framework Laravel. *Prosiding Seminar Hasil Penelitian*. <http://repository.lppm.unila.ac.id/12716/>
- Arwanda, E. R., & Safe'i, R. (2021). Assessment of forest health status of panca indah lestari community plantation forest (case study in bukit layang village, bakam district, bangka regency, Bangka Belitung Province). *IOP Conference Series: Earth and Environmental Science*. <https://doi.org/10.1088/1755-1315/918/1/012031>
- Ashok, V., & Yadav, A. (2019). A protection scheme for cross-country faults and transforming faults in dual-circuit transmission line using real-time digital simulator: a case study of Chhattisgarh state Transmission Utility. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*. <https://doi.org/10.1007/s40998-019-00202-w>
- Ashton, P. S., & Heckenbauer, J. (2022). Tribe shoreae (Dipterocarpaceae subfamily dipterocarpoideae) finally dissected. In *Kew Bulletin*. Springer. <https://doi.org/10.1007/s12225-022-10057-w>
- Bochkovski, A., Wang, C. Y., & Liao, H. Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. *ArXiv Preprint ArXiv:2004.10934*. <https://arxiv.org/abs/2004.10934>
- Carvalho, M. de A., Junior, J. M., Martins, J. A. C., Zamboni, P., Costa, C., Siqueira, H., Araújo, M., Gonçalves, D., Furuya, D., Osco, L., Ramos, A., Li, J., de Castro, A., & Gonçalves, W. (2022). A deep learning-based mobile application for tree species mapping in RGB images. In *International Journal of Applied Earth Observation and Geoinformation*. Elsevier. <https://www.sciencedirect.com/science/article/pii/S1569843222002333>
- Colli-Silva, M., Richardson, J. E., Bossa-Castro, A. M., & Pirani, J. (2024). Phylogenetic evidence reshapes the taxonomy of Cacao and its allies (Theobroma and Herrania; Malvaceae, Byttnerioideae). *Brittonia*.

<https://doi.org/10.1007/s12228-024-09783-1>

- da Silva, D. de A., de Freitas, E. D. G., Abud, H. F., & Gomes, D. G. (2024). Applying YOLOv8 and X-ray Morphology Analysis to Assess the Vigor of *Brachiaria brizantha* cv. Xaraés Seeds. In *AgriEngineering* (Vol. 6, Issue 2, pp. 869–880). mdpi.com. <https://doi.org/10.3390/agriengineering6020050>
- Dan, S., & Iskandar, T. (2018). TY - BOOK AU - Lumbantoruan, M TI - Penilaian Kesehatan Hutan Taman Hutan Raya Sultan Syarif Hasyim Minas Menggunakan Teknik Forest Health Monitoring (FHM) PB - repository.unilak.ac.id UR - <https://repository.unilak.ac.id/3899/> UR - <https://repository.uni>. In *Jurnal Silvikultur Tropika*.
- Das, N., & Das, S. (2023). Epoch and accuracy based empirical study for cardiac MRI segmentation using deep learning technique. In *PeerJ*. peerj.com. <https://peerj.com/articles/14939/>
- Deng, J., Gong, H., Liu, M., Xie, T., Cheng, X., Wang, X., & Liu, M. (2021). RALR: Random Amplify Learning Rates for Training Neural Networks. In *Applied Sciences*. mdpi.com. <https://www.mdpi.com/2076-3417/12/1/268>
- Dokic, K., Martinovic, M., & Mandusic, D. (2020). Inference speed and quantisation of neural networks with TensorFlow Lite for Microcontrollers framework. *2020 5th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (2020)*. <https://ieeexplore.ieee.org/abstract/document/9221846/>
- Doria, C., Safe'i, R., Iswandar, D., & Kaskoyo, H. (2021). Fauna biodiversity as one of Repong Damar forest health indicators. *IOP Conference Series: Earth and Environmental Science, Volume 886, 2nd Biennial Conference of Tropical Biodiversity*. <https://doi.org/10.1088/1755-1315/886/1/012036>
- Du, H., Ran, J. H., Feng, Y. Y., & Wang, X. Q. (2020). The flattened and needlelike leaves of the pine family (Pinaceae) share a conserved genetic network for adaxial-abaxial polarity but have diverged for photosynthetic adaptation. In *BMC Evolutionary Biology*. Springer. <https://doi.org/10.1186/s12862-020-01694-5>

- Du, K. L., Leung, C. S., Mow, W. H., & Swamy, M. N. S. (2022). Perceptron: Learning, generalization, model selection, fault tolerance, and role in the deep learning era. In *Mathematics*. mdpi.com. <https://www.mdpi.com/2227-7390/10/24/4730>
- Ecke, S., Stehr, F., Frey, J., Tiede, D., Dempewolf, J., Klemmt, H. J., Endres, E., & Seifert, T. (2024). Towards operational UAV-based forest health monitoring: Species identification and crown condition assessment by means of deep learning. In *Computers and Electronics in Agriculture*. Elsevier. <https://www.sciencedirect.com/science/article/pii/S0168169924001765>
- Eilmann, B., Bbertin, M., & Rigling, A. (2013). Growth response of Scots pine with different crown transparency status to drought release. *Annals of Forest Science*. <https://doi.org/10.1007/s13595-013-0310-z>
- Farhanandi, B. W., & Indah, N. K. (2022). Karakteristik morfologi dan anatomi tanaman kakao (*Theobroma cacao* L.) yang tumbuh pada ketinggian berbeda. *LenteraBio: Berkala Ilmiah Biologi*. <https://journal.unesa.ac.id/index.php/lenterabio/article/view/16436>
- Fassnacht, F. E., White, J. C., Wulder, M. A., & Næsset, E. (2024). Remote sensing in forestry: current challenges, considerations and directions. *Forestry: An International Journal of Forest Research, Volume 97, Issue 1, January 2024, Pages 11–37*. <https://academic.oup.com/forestry/article-abstract/97/1/11/7159227>
- FITRIANI, M. (2024). REVIEW ARTIKEL: KARAKTERISTIK DAUN KEMIRI (*Aleurites moluccana* L.) SEBAGAI OBAT TRADISIONAL. *Makassar Natural Product Journal (MNPJ)*. <https://journal.farmasi.umi.ac.id/index.php/mnpj/article/view/231>
- Frezza, C., Venditti, A., Vita, D. De, Toniolo, C., Franceschin, M., Ventrone, A., Tomassini, L., Foddai, S., Guiso, M., Nicoletti, M., Bianco, A., & Serafini, M. (2020). Phytochemistry, chemotaxonomy, and biological activities of the Araucariaceae family—A review. In *Plants*. mdpi.com. <https://www.mdpi.com/2223-7747/9/7/888>

- Frezza, C., Vita, D. De, Sciubba, F., Toniolo, C., & ... (2022). There Is Not Only *Cupressus sempervirens* L.: A Review on the Phytochemistry and Bioactivities of the Other *Cupressus* L. Species. In *Applied Sciences*. mdpi.com. <https://www.mdpi.com/2076-3417/12/14/7353>
- Gandadipoera, F. H. M., Andrian, R., & Safe'i, R. (2024). Tree Damage Type Classification Based on Forest Health Monitoring Using Mobile-Based Convolutional Neural Network. *Indonesian Journal of Artificial Intelligence and Data Mining*. <https://garuda.kemdikbud.go.id/documents/detail/3979208>
- Gao, C., Zhang, Q., Tan, Z., Zhao, G., Gao, S., Kim, E., & Shen, T. (2024). Applying optimized YOLOv8 for heritage conservation: enhanced object detection in Jiangnan traditional private gardens. In *Heritage Science* (Vol. 12, Issue 1). Springer. <https://doi.org/10.1186/s40494-024-01144-1>
- Gessler, A., Ferretti, M., & Schaub, M. (2022). Forest monitoring to assess forest functioning under air pollution and climate change. In *Front. For. Glob. Change, 18 July 2022 Sec. Forests and the Atmosphere*. frontiersin.org. <https://doi.org/10.3389/ffgc.2022.952232>
- Gholamalinezhad, H., & Khosravi, H. (2020). Pooling methods in deep neural networks, a review. *ArXiv Preprint ArXiv:2009.07485*. <https://arxiv.org/abs/2009.07485>
- Haikal, F. F., Safe'i, R., Kaskoyo, H., & Darmawan, A. (2020). Pentingnya pemantauan kesehatan hutan dalam pengelolaan hutan kemasyarakatan (studi kasus HKm Beringin Jaya yang di kelola oleh KTH Lestari Jaya 8). *Jurnal Hutan Pulau-Pulau Kecil* (2020) 4(1) 31-43. <http://repository.lppm.unila.ac.id/id/eprint/26327>
- Hwang, J. S., Lee, S. S., Gil, J. W., & Lee, C. K. (2024). Determination of Optimal Batch Size of Deep Learning Models with Time Series Data. In *Sustainability*. mdpi.com. <https://www.mdpi.com/2071-1050/16/14/5936>
- Imanuddin, R., Hidayat, A., Rachmat, H. H., Turjaman, M., & ... (2020). Reforestation and Sustainable Management of *Pinus merkusii* Forest Plantation in Indonesia: A Review. In *Forests*. mdpi.com.

<https://www.mdpi.com/1999-4907/11/12/1235>

- Indriani, Y., Safe'i, R., Kaskoyo, H., & Darmawan, A. (2020). Vitalitas sebagai salah satu indikator kesehatan hutan konservasi. *Jurnal Perennial* (2020) 16(2) 40-46. <http://repository.lppm.unila.ac.id/25309/>
- Iskandar, T. (2018). Penilaian Kesehatan Kebun Benih Semai Pinus Merkusii Dengan Metode Fhm (Forest Health Monitoring) Di Kph Sumedang Health Assessment for Seedling Seed Orchard of Pinus merkusii Using FHM (Forest Health Monitoring) Method in KPH Sumedang. In *Journal of Tropical Silviculture*. <https://core.ac.uk/download/pdf/294854764.pdf>
- Jia, X. (2023). The Role and Importance of Software Testing in Software Quality Management. In *Journal of Industry and Engineering Management*. [stemmpress.com](http://www.stemmpress.com).
<http://www.stemmpress.com/uploadfile/202403/7ef8e3cd379f559.pdf>
- Khaksar, G., Kasemcholathan, S., & Sirikantaramas, S. (2024). Durian (*Durio zibethinus* L.): Nutritional Composition, Pharmacological Implications, Value-Added Products, and Omics-Based Investigations. In *Horticulturae*. [mdpi.com. https://www.mdpi.com/2311-7524/10/4/342](https://www.mdpi.com/2311-7524/10/4/342)
- Koo, M., & Yang, S. W. (2025). Likert-Type Scale. In *Encyclopedia*. [mdpi.com. https://www.mdpi.com/2673-8392/5/1/18](https://www.mdpi.com/2673-8392/5/1/18)
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2021). ImageNet Classification with Deep Convolutional Neural Networks. 2017. In *Communications of the ACM* (2017) 60(6) 84-90.
- Kumari, I., Sharma, C., Mujat, H. M. K., Das, R., Ghosh, P., & Mohanty, J. P. (2024). *Araucaria heterophylla*: A comprehensive review. In *academia.edu*. https://www.academia.edu/download/113553615/5_1_10_260.pdf
- Liu, Y., Pu, H., & Sun, D. W. (2021). Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices. *Trends in Food Science & Technology*. <https://www.sciencedirect.com/science/article/pii/S0924224421003022>

- Long, J., Wang, X., Zhou, W., Zhang, J., Dai, D., & Zhu, G. (2021). A comprehensive review of signal processing and machine learning technologies for UHF PD detection and diagnosis (I): Preprocessing and localization approaches. *IEEE Access*.
<https://ieeexplore.ieee.org/abstract/document/9422716/>
- Mangold, R. D. (2000). Overview of the forest health monitoring program. *United States Department of Agriculture Forest ...*
<https://research.fs.usda.gov/treearch/15807>
- Marchin, R. M., Esperon-Rodriguez, M., Tjoelker, M. G., & Ellsworth, D. S. (2022). Crown dieback and mortality of urban trees linked to heatwaves during extreme drought. In *Sci Total Environ. 2022 Dec 1;850:157915*. Elsevier.
<https://www.sciencedirect.com/science/article/pii/S0048969722050148>
- Maxwell, A. E., Warner, T. A., & Guillén, L. A. (2021). Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—Part 2: Recommendations and best practices. In *Remote Sensing*. mdpi.com.
<https://www.mdpi.com/2072-4292/13/13/2591>
- Meng, J., Xu, L., Li, S., Wang, W., Liu, Q., Xie, S., & Ma, W. (2016). Mapping forest health using spectral and textural information extracted from SPOT-5 satellite images. In *Remote Sensing*. mdpi.com. <https://www.mdpi.com/2072-4292/8/9/719>
- Montzka, C., Bayat, B., Tewes, A., Mengen, D., & Vereecken, H. (2021). Sentinel-2 analysis of spruce crown transparency levels and their environmental drivers after summer drought in the Northern Eifel (Germany). *Frontiers in Forests and Global Change*.
<https://doi.org/10.3389/ffgc.2021.667151>
- Morales-Gallegos, L. M., Martínez-Trinidad, T., & ... (2023). Tree health condition in urban green areas assessed through crown indicators and vegetation indices. In *Forests*. mdpi.com. <https://www.mdpi.com/1999-4907/14/8/1673>

- Muncie, G. (2024). *Solar panel damage identification using tensorflow lite*. scholar.utc.edu. <https://scholar.utc.edu/theses/871/>
- Nguyen, Q. T. (2022). Detrimental starfish detection on embedded system: a case study of YOLOv5 deep learning algorithm and TensorFlow lite framework. *Journal of Computer Sciences Institute*. <https://ph.pollub.pl/index.php/jcsi/article/view/2896>
- Nur'aini, H., Zuhud, E. A. M., & ... (2020). Conservation of Damar Mata Kucing (*Shorea javanica*): A Review on the Aspect of Trade System. *Journal of Tropical ...*. <https://search.ebscohost.com/login.aspx?direct=true&profile=ehost&scope=site&authtype=crawler&jrnl=20870469&AN=147614089&h=9BkcxECCWDRCEIi%2FJD0oAdktMEPqWLqmu1YBTXHMEng5lvyDp6O2szfgbC8%2FA7Z%2FTr%2F3NCgrHNNc5oQgW%2FZDCA%3D%3D&crl=c>
- Octarina, N. A., Andrian, R., & Safei, R. (2023). Classification of crown density and foliage transparency scale for broadleaf tree using VGG-16. *Journal of Soft Computing Exploration*. <https://www.shmpublisher.com/index.php/joscecx/article/view/251>
- Olson, L. G., Coops, N. C., Moreau, G., & ... (2026). The application of intra-canopy photogrammetry for assessing crown health attributes in sugar maple (*Acer saccharum* Marsh.). ... *Journal of Forest ...*. <https://academic.oup.com/forestry/article-abstract/99/2/cpag006/8484129>
- Pangestu, A. Y., Safe'i, R., & Kaskoyo, H. (2020). Evaluasi Usability pada Web GIS Pemantauan Kesehatan Hutan Menggunakan Metode System Usability Scale (SUS). *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer* (2020) 20(1) 19-26. <http://repository.lppm.unila.ac.id/id/eprint/29816>
- Payara, G. R., & Tanone, R. (2018). Penerapan Firebase Realtime Database Pada Prototype Aplikasi Pemesanan Makanan Berbasis Android. *Jurnal Teknik Informatika Dan Sistem Informasi* (2018) 4(3) 397-406. <https://journal.maranatha.edu/index.php/jutisi/article/view/1476>

- Pedro, L., Barbosa, C., & Santos, C. M. N. (2018). A critical review of mobile learning integration in formal educational contexts. In *International Journal of Educational Technology in Higher Education*. Springer.
<https://doi.org/10.1186/s41239-018-0091-4>
- Pertiwi, D., Safe'i, R., & Kaskoyo, H. (2019). Identifikasi kondisi kerusakan pohon menggunakan metode forest health monitoring di tahura war provinsi lampung. *Jurnal Perennial*. <http://repository.lppm.unila.ac.id/15530/>
- Pisani, C., Bock, C. H., & Randall, J. (2023). Visual rating and the use of image analysis for assessing canopy density in a pecan provenance collection during leaf fall. In *Journal of Forestry Research*. Springer.
<https://doi.org/10.1007/s11676-023-01635-0>
- Potter, K. M., & Conkling, B. L. (2022). *Forest health monitoring: national status, trends, and analysis 2021*. cabidigitallibrary.org.
<https://doi.org/10.5555/20220282636>
- Puspita, E. N., Safe'i, R., Hari Kaskoyo, & Rudi Hilmanto. (2021). Penilaian indikator kesehatan hutan rakyat pada pola tanam agroforestry. *Indonesian Journal of Conservation*, 10(1), 27–33.
<https://journal.unnes.ac.id/nju/ijc/article/view/28894>
- Putra, E. I., Nugraha, L. R., Helmanto, H., Rachmadiyanto, A. N., Usman, U., Rusniarsyah, L., & Sukendro, A. (2023). Analisis Kesehatan Tajuk Pohon pada Famili Fabaceae di Kebun Raya Bogor. In *Journal of Tropical Silviculture* (Vol. 14, Issue 01, pp. 9–14). <https://doi.org/10.29244/j-siltrop.14.01.9-14>
- Putri, K. P., Supriyanto, S., & Syaufina, L. (2016). Penilaian kesehatan sumber benih Shorea spp. di KHDTK Haurbentes dengan metoda forest health monitoring. *Jurnal Penelitian Hutan Tanaman*.
<https://ejournal.aptklhi.org/index.php/JPHT/article/view/866>
- Puttaso, P., Namanusart, W., Thumanu, K., Kamolmanit, B., Brauman, A., & Lawongsa, P. (2020). Assessing the Effect of Rubber (*Hevea brasiliensis* (Willd. ex A. Juss.) Muell. Arg.) Leaf Chemical Composition on Some Soil

- Properties of Differently Aged Rubber Tree Plantations. In *Agronomy*.
mdpi.com. <https://www.mdpi.com/2073-4395/10/12/1871>
- Rahmadanty, A., Handayani, I., & Najicha, F. U. (2021). Kebijakan pembangunan kesatuan pengelolaan hutan di Indonesia: suatu terobosan dalam menciptakan pengelolaan hutan lestari. *Al-Adl*.
<https://www.neliti.com/publications/362594/kebijakan-pembangunan-kesatuan-pengelolaan-hutan-di-indonesia-suatu-terobosan-da>
- Rahmayanti, L. (2023). Literature review: Analisis potensi pengelolaan Kawasan Taman Nasional Gunung Merapi (TNGM) berdasarkan zona untuk pelestarian ekosistem daratan. *Jurnal Sains Edukatika Indonesia (JSEI)*.
<https://jurnal.uns.ac.id/jsei/article/view/70932>
- Ramadhani, D. H. (2023). *Studi Keanekaragaman Burung Diurnal Dan Pemanfaatan Tajuk Pohon Pada Rph Bedagung Bkph Lawu Selatan KPH Lawu Ds di Magetan Jawa Timur*. <http://repository.unas.ac.id/id/eprint/8841>
- Randolph, K. D. C., & Thompson, M. T. (2010). Descriptive statistics of tree crown condition in the United States Interior West. *Gen. Tech. Rep. SRS-127*. <https://research.fs.usda.gov/treearch/35858>
- Raptis, D., Kazana, V., Kazaklis, A., & Stamatiou, C. (2018). A crown width-diameter model for natural even-aged black pine forest management. In *Forests*. mdpi.com. <https://www.mdpi.com/1999-4907/9/10/610>
- Recchia, V., Andresini, G., Appice, A., Fontana, G., & Malerba, D. (2024). An Attention-Based CNN Approach to Detect Forest Tree Dieback Caused by Insect Outbreak in Sentinel-2 Images. In *Discovery Science. DS 2024. Lecture Notes in Computer Science()*, vol 15244. Springer, Cham. Springer.
https://doi.org/10.1007/978-3-031-78980-9_12
- Ritz, A. L., Wynne, R. H., Thomas, V. A., Wagner, F. H., Green, P. C., Schroeder, T. A., & Saatchi, S. (2025). Applying a convolutional neural network (CNN) to Virginia's forests: how forest type and age can impact individual tree segmentation. *International Journal of Remote Sensing*, 1–28.
<https://doi.org/10.1080/01431161.2025.2598075>

- Rochim, A. F., Wijaya, T. N., & Eridani, D. (2021). A Citation Data Collector Tool of Author's Profiles in Scopus Based on Web and Application Programming Interface (API). *IOP Conference Series: Materials Science and Engineering (2021) 1077(1) 012017*. <https://doi.org/10.1088/1757-899X/1077/1/012017>
- Sadono, R. (2018). Prediksi lebar tajuk pohon dominan pada pertanaman jati asal kebun benih klon di Kesatuan Pemangkuan Hutan Ngawi, Jawa Timur. *Jurnal Ilmu Kehutanan*. <https://journal.ugm.ac.id/jikfkt/article/view/40143>
- Safe'i, R. (2014). Value of vitality status in monoculture and agroforestry planting systems of the community forests. *International Journal of Sciences: Basic and Applied Research (IJSBAR)*, 18 (2). Pp. 340-353. ISSN 2307-4531. <http://repository.lppm.unila.ac.id/4090/>
- Safe'i, R. (2018). PENILAIAN VITALITASPOHONJATI DENGANFOREST HEALTH MONITORINGDIKPH BALAPULANG. *Jurnal Ecogreen*. <http://repository.lppm.unila.ac.id/id/eprint/8288>
- Safe'i, R., Ardiansyah, F., Banuwa, I. S., Yuwono, S. B., Maulana, I. R., & Muslih, A. M. (2021). Analysis of internal factors affecting the health condition of mangrove forests in the coastal area of East Lampung Regency. *IOP Conference Series: Earth and Environmental Science, Volume 912, 3rd International Conference on Natural Resources and Technology 24-25 August 2021, Medan, Indonesia*. <https://doi.org/10.1088/1755-1315/912/1/012070>
- Safe'i, R., Dewi, B. S., Ardiansyah, F., & Latumahina, F. S. (2021). Short Communication: Assessing the state and change of forest health of the proposed arboretum in Wan Abdul Rachman Grand Forest Park, Lampung, Indonesia. In *Biodiversitas*.
- Safe'i, R., Kaskoyo, H., Ardiansyah, F., & Pangestu, A. Y. (2022). Pelatihan penggunaan sistem informasi pemantauan kesehatan hutan Di KPH IX Kota Agung Utara Kabupaten Tanggamus. In *Dharma Raflesia : Jurnal Ilmiah Pengembangan dan Penerapan IPTEKS (2022) 20(1) 38-52*.

- Safe'i, R., Wulandari, C., & Kaskoyo, H. (2019). Penilaian kesehatan hutan pada berbagai tipe hutan di Provinsi Lampung. *Jurnal Sylva Lestari*.
<http://repository.lppm.unila.ac.id/id/eprint/26323>
- Salehi, A. W., Khan, S., Gupta, G., Alabdullah, B. I., Almjally, A., Alsolai, H., Siddiqui, T., & Mellit, A. (2023). A study of CNN and transfer learning in medical imaging: Advantages, challenges, future scope. In *Sustainability*.
mdpi.com. <https://www.mdpi.com/2071-1050/15/7/5930>
- Sapkota, R., Calero, M. F., Qureshi, R., Badgujar, C., Nepal, U., Poulouse, A., Zeno, P., Vaddevolu, U. B. P., Khan, S., Shoman, M., Yan, H., & Karkee, M. (2024). Yolov10 to its genesis: A decadal and comprehensive review of the you only look once series. *ArXiv:2406.19407*.
<https://arxiv.org/abs/2406.19407>
- Schomaker, M. E., Zarnoch, S. J., Bechtold, W. A., Latelle, D. J., Burkman, W. G., & Cox, S. M. (2007). Crown-condition classification: a guide to data collection and analysis (No. SRS-GTR-102). In *United States Department of Agriculture Forest Service*.
- Schratz, P., Muenchow, J., Iturritxa, E., Cortés, J., Bischl, B., & Brenning, A. (2021). Monitoring forest health using hyperspectral imagery: Does feature selection improve the performance of machine-learning techniques? In *Remote Sensing*. mdpi.com. <https://www.mdpi.com/2072-4292/13/23/4832>
- Shatravin, V., Shashev, D., & Shidlovskiy, S. (2023). Implementation of the SoftMax Activation for Reconfigurable Neural Network Hardware Accelerators. In *Applied Sciences*. mdpi.com. <https://www.mdpi.com/2076-3417/13/23/12784>
- Shiri, F. M., Perumal, T., Mustapha, N., & Mohamed, R. (2023). A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU. *ArXiv:2305.17473*.
<https://arxiv.org/abs/2305.17473>
- Siregar, B. N. T. (2014). *Evaluasi Kesehatan Pohon Peneduh di Kota Bandar Lampung Berbasis Sonic Tomography*.

- Sofiyana, F., Andrian, R., & Safei, R. (2023). MobileNet untuk Identifikasi Skala Kerapatan dan Transparansi Tajuk Pohon Daun Lebar. *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 4(3), 1850–1859.
<http://djournals.com/klik/article/view/1476>
- Sriatna, D. A., Andrian, R., & Safei, R. (2024). Implementation of Convolutional Neural Network for Classification of Density Scale and Transparency of Needle Leaf Types. *Indonesian Journal of Artificial Intelligence and Data Mining (IJAIDM)*. <http://ejournal.uin-suska.ac.id/index.php/IJAIDM/article/view/26258>
- Stăncioiu, P. T., Șerbescu, A. A., & Dutcă, I. (2021). Live Crown Ratio as an Indicator for Tree Vigor and Stability of Turkey Oak (*Quercus cerris* L.): A Case Study. In *Forests*. mdpi.com. <https://www.mdpi.com/1999-4907/12/12/1763>
- Susilawati, M. S., & Sabran, M. (2018). Karakterisasi morfologi durian (*Durio zhibetinus*) lokal asal Kabupaten Katingan. In *Bul. Plasma Nutfah*.
- Sutejo, A., & Fajri, R. (2023). Optimasi Kecepatan Putar dalam Peningkatan Mutu Biji Kemiri pada Mesin Pemecah Cangkang Biji Kemiri (*Aleurites moluccana* Willd.). *Jurnal Agricultural Biosystem Engineering*.
<https://jurnal.fp.unila.ac.id/index.php/ABE/article/view/6751>
- Syakra, K. A., Hasanuddin, H., Wardiah, W., Samingan, S., & Andayani, D. (2021). Analysis Of Plant Vegetation In The Forest Park Of Langsa City. In *Jurnal Ilmiah Mahasiswa Keguruan dan Ilmu Pendidikan Unsyiah*.
- Takefuji, Y. (2021). Python programming in PyPI for translational medicine. In *International Journal of Translational Medicine*. mdpi.com.
<https://www.mdpi.com/2673-8937/1/3/19>
- Talebi, H., & Milanfar, P. (2021). Learning to Resize Images for Computer Vision Tasks. arXiv. In *arXiv preprint arXiv:2103.09950*.
- Tao, Y., Li, B., Li, P., Qian, J., & Qi, L. (2025). Improved Lightweight YOLOv11 Algorithm for Real-Time Forest Fire Detection. In *Electronics*. mdpi.com.

<https://www.mdpi.com/2079-9292/14/8/1508>

Tapasya, S., Safe'i, R., Tsani, M. K., & Puspasari, E. (2023). Penilaian Kesehatan Hutan Berdasarkan Indikator Biodiversitas pada Blok Pemanfaatan TAHURA WAR. *Jurnal Sylva Scientiae*.

<https://ppjp.ulm.ac.id/journals/index.php/jss/article/view/10060>

Tarigan, F. R., Andrian, R., & Safe'i, R. (2023). Klasifikasi Skala Kerapatan dan Transparansi Tajuk Jenis Daun Jarum dengan VGG16. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 3(2), 253–263. <https://doi.org/10.57152/malcom.v3i2.940>

Tawfeek, N., Fikry, E., Mahdi, I., Ochieng, M. A., Bakrim, W. B., Taarji, N., Mahmoud, N. F., & Sobeh, M. (2023). Cupressus arizonica Greene: Phytochemical Profile and Cosmeceutical and Dermatological Properties of Its Leaf Extracts. In *Molecules*. mdpi.com. <https://www.mdpi.com/1420-3049/28/3/1036>

Ulfa, S. W., Marhamah, A., Rahayu, P., & Aqmarina, T. N. (2023). Identifikasi ciri morfologis tumbuhan tingkat tinggi pada ordo berbeda di Kampus II UIN Sumatera Utara. *BIOSFER, J.Bio. & Pend.Bio. Vol.8, No.2, Desember 2023*. <https://journal.unpas.ac.id/index.php/biosfer/article/view/11144>

Vijayakumar, A., Vairavasundaram, S., Koilraj, J. A. S., Rajappa, M., Kotecha, K., & Kulkarni, A. (2024). Real-time visual intelligence for defect detection in pharmaceutical packaging. In *Scientific Reports*. nature.com. <https://www.nature.com/articles/s41598-024-69701-z>

Wang, C. Y., Bochkovski, A., & Liao, H. (2023). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (2023) 2023-June 7464-7475*. http://openaccess.thecvf.com/content/CVPR2023/html/Wang_YOLOv7_Trainable_Bag-of-Freebies_Sets_New_State-of-the-Art_for_Real-Time_Object_Detectors_CVPR_2023_paper.html

Wang, J., & Perez, L. (2017). The effectiveness of data augmentation in image

classification using deep learning. In *Convolutional Neural Networks Vis ...*
vision.stanford.edu.

<http://vision.stanford.edu/teaching/cs231n/reports/2017/pdfs/300.pdf>

Wao, A. A., & Soni, B. K. (2021). Performance analysis of sigmoid and relu activation functions in deep neural network. *Intelligent Systems: Proceedings of SCIS 2021*. https://doi.org/10.1007/978-981-16-2248-9_5

Waruwu, E., Firdara, E. K., Octavianus, R., & Triyadi, A. (2021). EVALUASI KESEHATAN POHON MENGGUNAKAN INDIKATOR FOREST HEALTH MONITORING PADA RUANG TERBUKA HIJAU UNIVERSITAS PALANGKA RAYA: Evaluation of Tree Health Using Forest Health Monitoring Indicators in Palangka Raya University Green Space Area. In *Hutan Tropika*. e-journal.upr.ac.id. <https://e-journal.upr.ac.id/index.php/JHT/article/download/2964/3905>

Wasilewski, K., & Zabierowski, W. (2021). A comparison of java, flutter and kotlin/native technologies for sensor data-driven applications. In *Sensors*. mdpi.com. <https://www.mdpi.com/1424-8220/21/10/3324>

Xu, L., Shi, Y., Fang, H., Zhou, G., Xu, X., Zhou, Y., Tao, J., Ji, B., Xu, J., Li, C., & Chen, L. (2018). Vegetation carbon stocks driven by canopy density and forest age in subtropical forest ecosystems. *Sci Total Environ*. 2018 Aug 1;631-632:619-626. <https://www.sciencedirect.com/science/article/pii/S0048969718308349>

Yan, J., Lou, B., & He, X. (2025). Forest Ecosystem Health Assessment: Frameworks, Challenges, and Strategies for the Future. In *Ecosystem Health and Sustainability*. spj.science.org. <https://doi.org/10.34133/ehs.0414>

Yang, L., Xu, Z., Liu, Y., & Tian, G. (2022). An improved equilibrium optimizer with a decreasing equilibrium pool. In *Symmetry*. mdpi.com. <https://www.mdpi.com/2073-8994/14/6/1227>

Yang, Y. (1999). An evaluation of statistical approaches to text categorization. *Information Retrieval*. <https://doi.org/10.1023/A:1009982220290>

- Yang, Z., Duan, G., Sharma, R. P., Peng, W., Zhou, L., Fan, Y., & Zhang, M. (2024). Predicting Individual Tree Mortality of *Larix gmelinii* var. *Principisrupprechtii* in Temperate Forests Using Machine Learning Methods. In *Forests*. mdpi.com. <https://www.mdpi.com/1999-4907/15/2/374>
- Yao, S., Hao, Z., Post, C. J., Mikhailova, E. A., & Lin, L. (2024). Individual Tree Crown Detection and Classification of Live and Dead Trees Using a Mask Region-Based Convolutional Neural Network (Mask R-CNN). In *Forests*. mdpi.com. <https://www.mdpi.com/1999-4907/15/11/1900>
- Yulita, K. S., Atikah, T. D., & Wardani, W. (2020). Unraveling genetic variations of *Dalbergia latifolia* (Fabaceae) from Yogyakarta and Lombok Island, Indonesia. In *Biodiversitas Journal of Biological Diversity*. <https://www.academia.edu/download/72437693/3691.pdf>
- Yun, S., Han, D., Oh, S. J., Chun, S., Choe, J., & Yoo, Y. (2019). Cutmix: Regularization strategy to train strong classifiers with localizable features. *Proceedings of the IEEE International Conference on Computer Vision (2019)* 6022-6031. http://openaccess.thecvf.com/content_ICCV_2019/html/Yun_CutMix_Regularization_Strategy_to_Train_Strong_Classifiers_With_Localizable_Features_ICCV_2019_paper.html
- Zarnoch, S. J., Bechtold, W. A., & Stolte, K. (2004). Using crown condition variables as indicators of forest health. *Canadian Journal of Forest Research* (2004) 34(5) 1057-1070. <https://doi.org/10.1139/x03-277>
- Zhao, H., Morgenroth, J., Pearse, G., & Schindler, J. (2023). A systematic review of individual tree crown detection and delineation with convolutional neural networks (CNN). *Current Forestry Reports*. <https://doi.org/10.1007/s40725-023-00184-3>
- Zhou, X., Koltun, V., & Krähenbühl, P. (2020). Tracking objects as points. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (2020) 12349 LNCS 474-490. https://doi.org/10.1007/978-3-030-58548-8_28

Zhou, X., Zhang, X., Zhao, R., Chen, Y., & Liu, X. (2023). Navigation line extraction method for broad-leaved plants in the multi-period environments of the high-ridge cultivation mode. In *Agriculture*. mdpi.com.

<https://www.mdpi.com/2077-0472/13/8/1496>

Zhu, Y., & Chen, Y. (2023). Adaptive Growth: Real-time CNN Layer Expansion.

ArXiv Preprint ArXiv:2309.03049. <https://arxiv.org/abs/2309.03049>

Zuluaga, C. A., Aristizábal, L. M., Rúa, S., Franco, D. A., Osorio, D. A., & Vásquez, R. E. (2022). Development of a modular software architecture for underwater vehicles using systems engineering. In *Journal of Marine Science and Engineering*. mdpi.com.

<https://www.mdpi.com/2077-1312/10/4/464>