

**PERBANDINGAN KINERJA ARSITEKTUR *MOBILENETV2* DAN
RESNET50 PADA KLASIFIKASI TUMBUHAN HERBAL BERBASIS
CITRA DAUN**

(SKRIPSI)

Oleh

**SITI AYUNI
NPM 2117051068**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

**PERBANDINGAN KINERJA ARSITEKTUR *MOBILENETV2* DAN
RESNET50 PADA KLASIFIKASI TUMBUHAN HERBAL BERBASIS
CITRA DAUN**

Oleh

SITI AYUNI

SKRIPSI

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

Pada

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



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRAK

PERBANDINGAN KINERJA ARSITEKTUR *MOBILENETV2* DAN *RESNET50* PADA KLASIFIKASI TUMBUHAN HERBAL BERBASIS CITRA DAUN

Oleh

SITI AYUNI

Indonesia sebagai negara tropis memiliki kekayaan hayati yang melimpah, termasuk berbagai jenis tumbuhan herbal yang berpotensi dalam pengobatan tradisional. Namun, klasifikasi tumbuhan herbal berdasarkan morfologi daun masih banyak bergantung pada metode visual tradisional yang rentan kesalahan akibat keterbatasan pengetahuan dan kemiripan bentuk daun antarspesies. Penelitian ini menerapkan pendekatan *deep learning* dengan membandingkan kinerja arsitektur *MobileNetV2* dan *ResNet50* dalam klasifikasi citra daun herbal sebagai solusi atas keterbatasan tersebut. *Dataset* yang digunakan terdiri dari 3000 citra daun tunggal dari 10 jenis tumbuhan herbal yang dikelompokkan ke dalam dua bentuk morfologi utama, yaitu *cordate* (jantung) dan *ovate* (bulat telur). Tahapan penelitian mencakup pengumpulan data, *preprocessing* (*resize*, normalisasi, dan pembagian *dataset*), pelatihan model dengan *transfer learning*, serta evaluasi kinerja menggunakan *confusion matrix*. Hasil menunjukkan bahwa *MobileNetV2* memiliki kinerja terbaik dalam klasifikasi citra daun herbal, sedangkan *ResNet50* memerlukan penyesuaian untuk mencapai hasil yang optimal. *MobileNetV2* memperoleh akurasi tertinggi sebesar 99,33%, sementara *ResNet50* mencapai 99% pada skenario terbaiknya. Selain itu, *MobileNetV2* menunjukkan waktu pelatihan yang lebih efisien dibandingkan *ResNet50*. Kedua model kemudian diimplementasikan dalam bentuk aplikasi *web* menggunakan *framework* Streamlit untuk mendukung proses klasifikasi secara otomatis. Penelitian ini diharapkan dapat mendorong pemanfaatan teknologi dalam pelestarian dan pemanfaatan tumbuhan herbal.

Kata kunci: klasifikasi citra, daun herbal, *deep learning*, *MobileNetV2*, *ResNet50*.

ABSTRACT

PERFORMANCE COMPARISON OF MOBILENETV2 AND RESNET50 ARCHITECTURES IN HERBAL PLANT CLASSIFICATION BASED ON LEAF IMAGES

By

SITI AYUNI

Indonesia, as a tropical country, possesses abundant biodiversity, including various types of herbal plants with great potential in traditional medicine. However, the classification of herbal plants based on leaf morphology still largely relies on traditional visual methods, which are prone to errors due to limited expertise and morphological similarities among species. This study applies a deep learning approach by comparing the performance of the MobileNetV2 and ResNet50 architectures in classifying images of herbal leaves as a solution to these limitations. The dataset used consists of 3,000 single-leaf images from 10 types of herbal plants, grouped into two main morphological shapes: cordate (heart-shaped) and ovate (egg-shaped). The research stages include data collection, preprocessing (resizing, normalization, and dataset splitting), model training using transfer learning, and performance evaluation using a confusion matrix. The results show that MobileNetV2 outperforms ResNet50 in classifying herbal leaf images. MobileNetV2 achieved the highest accuracy of 99.33%, while ResNet50 reached 99% in its best-performing scenario. In addition, MobileNetV2 demonstrated more efficient training time compared to ResNet50. Both models were subsequently implemented in a web-based application using the Streamlit framework to support automatic classification. This research is expected to encourage the use of technology in the preservation and utilization of herbal plants.

Keywords: image classification, herbal leaves, deep learning, MobileNetV2, ResNet50.

Judul Skripsi

: PERBANDINGAN KINERJA ARSITEKTUR
MOBILENETV2 DAN RESNET50 PADA
KLASIFIKASI TUMBUHAN HERBAL
BERBASIS CITRA DAUN

Nama Mahasiswa

: Siti Ayuni

Nomor Pokok Mahasiswa

: 2117051068

Program Studi

: S1 Ilmu Komputer

Jurusan

: Ilmu Komputer

Fakultas


: Matematika dan Ilmu Pengetahuan Alam

MENYETUJUI

1. Komisi Pembimbing




Yunda Heningtyas, M.Kom.
NIP. 19890108 201903 2 014



Wartariyus, S.Kom., M.T.I.
NIP. 19730122 200604 1 002

2. Mengetahui

Ketua Jurusan Ilmu Komputer
FMIPA Universitas Lampung



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

Ketua Program Studi Ilmu Komputer
FMIPA Universitas Lampung



Tristiyanto, S.Kom., M.I.S., Ph.D.
NIP. 19810414 200501 1 0001


MENGESAHKAN

1. Tim Penguji

Ketua : Yunda Heningtyas, M.Kom.

Sekretaris : Wartariyus, S.Kom., M.T.I.

Penguji Utama : Dr. rer. nat. Akmal Junaidi, M.Sc.



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: 20 Juni 2025

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Siti Ayuni

NPM : 2117051068

Menyatakan bahwa skripsi saya yang berjudul **“Perbandingan Kinerja Arsitektur *MobileNetV2* dan *Resnet50* pada Klasifikasi Tumbuhan Herbal Berbasis Citra Daun”** merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil penjiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang telah saya terima.

Bandar Lampung, 18 Juli 2025



Siti Ayuni
NPM. 2117051068

RIWAYAT HIDUP



Penulis dilahirkan pada tanggal 25 Oktober 2002 di Kota Metro, Provinsi Lampung, sebagai anak pertama dari pasangan Bapak Sanwani dan Ibu Aminah. Penulis memulai pendidikan formal di Taman Kanak-kanak (TK) Al Jihad yang diselesaikan pada tahun 2009. Penulis melanjutkan pendidikan ke SD Negeri 6 Metro Pusat dan lulus pada tahun 2015, kemudian melanjutkan ke jenjang menengah pertama di SMP Negeri 4 Metro yang diselesaikan pada tahun 2018. Pendidikan menengah atas ditempuh penulis di SMAN 3 Metro dengan mengambil jurusan Ilmu Pengetahuan Alam (IPA) dan diselesaikan pada tahun 2021.

Pada tahun 2021, penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis melakukan beberapa kegiatan antara lain:

1. Menjadi Anggota Muda Ilmu Komputer (ADAPTER) Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2021/2022.
2. Menjadi Legislator Muda Dewan Perwakilan Mahasiswa Universitas Lampung pada periode 2021/2022.
3. Menjadi anggota Biro Kesekretariatan Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2021/2022.
4. Menjadi anggota Bidang Keilmuan Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2022/2023.
5. Menjadi Asisten Dosen Jurusan Ilmu Komputer pada mata kuliah Logika dan Struktur Data dan Algoritma tahun ajaran 2022/2023.

6. Melaksanakan kerja praktik periode 2023/2024 di Divisi Operasi PT PLN (Persero) UP2D Lampung.
7. Berpartisipasi dalam penelitian dosen Ilmu Komputer terkait pengembangan Sistem Temu Kembali Informasi Publikasi Ilmiah Dosen Universitas Lampung.
8. Mengikuti program *Talent Scouting Academy* (TSA) di bidang *Machine Learning and Data Mining in Data Science Capabilities* pada tahun 2023.
9. Menjadi panitia pelaksana seminar nasional di Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung pada tahun 2023.
10. Mengikuti program MSIB *Batch* 6 bersama Startup Campus dan memperoleh sertifikat di bidang *Data Science* dan *Artificial Intelligence* pada tahun 2024.
11. Menjadi UI/UX *Designer* pada proyek E-Voting di Lembaga Riset Cipta Ilmu Indonesia pada tahun 2024.
12. Melaksanakan program Kuliah Kerja Nyata (KKN) di Desa Negeri Katon, Kecamatan Marga Tiga, Kabupaten Lampung Timur pada bulan Juni hingga Agustus 2024, sebagai bentuk pengabdian kepada masyarakat.

MOTTO

"... dan Allah adalah sebaik-baik perencanaan."

(QS. Ali Imran [3]: 54)

"Tidaklah mungkin bagi matahari mengejar bulan dan malam pun tidak dapat mendahului siang. Masing-masing beredar pada garis edarnya."

(QS. Yasin [36]: 40)

"You can delay, but time won't wait — use every day to grow and improve."

(Kim Taehyung)

"Jika kamu tidak dapat melakukan hal-hal hebat, lakukan hal-hal kecil dengan cara yang hebat."

(Napoleon Hill)

"Bahkan, jika kamu tersandung dan jatuh, hal yang terpenting adalah kamu harus bangun kembali."

(Min Yoongi)

"Hargai dan cintai dirimu yang kemarin, sekarang, dan yang akan datang."

(Bangtan Sonyeondan)

PERSEMBAHAN

Segala puji dan syukur penulis panjatkan kehadiran Allah Subhanahu wa Ta'ala atas limpahan rahmat, taufik, dan hidayah-Nya, sehingga penulis dapat melalui berbagai proses dan tantangan dalam menyusun skripsi ini hingga selesai.

Shalawat dan salam semoga senantiasa tercurah kepada Nabi Muhammad Shallallahu 'Alaihi Wasallam. Dengan penuh rasa cinta, hormat, dan terima kasih yang mendalam, karya ini penulis persembahkan kepada:

Kedua Orang Tuaku Tercinta

dan

Keluargaku Tersayang

Sumber kekuatan dan inspirasi terbesar dalam hidup penulis. Setiap langkah dan pencapaian yang penulis torehkan tidak lepas dari bimbingan, kasih sayang, dan didikan penuh kesabaran yang selama ini Bapak dan Ibu tanamkan. Tidak ada balasan yang sepadan untuk segala pengorbanan yang diberikan, semoga karya ini menjadi bukti cinta dan terima kasih yang tulus dari penulis.

Seluruh Keluarga besar Ilmu Komputer 2021

Rekan-rekan seperjuangan yang telah menjadi bagian dalam setiap proses perjalanan akademik senantiasa memberikan dukungan dan motivasi.

Serta

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

Tempat penulis bertumbuh dan menimba ilmu yang menjadi bekal untuk menghadapi perjalanan kehidupan di masa depan.

SANWACANA

Segala puji bagi Allah Subhanahu wa Ta'ala atas limpahan nikmat, rahmat, dan karunia-Nya. Shalawat dan salam semoga senantiasa tercurah kepada Nabi Muhammad Shallallahu 'Alaihi Wasallam. Berkat pertolongan-Nya, penulis dapat menyelesaikan skripsi yang berjudul “Perbandingan Kinerja Arsitektur *MobileNetV2* Dan *ResNet50* pada Klasifikasi Tumbuhan Herbal Berbasis Citra Daun” dengan baik.

Pada kesempatan ini, penulis menyampaikan rasa terima kasih kepada seluruh pihak yang telah memberikan dukungan, bimbingan dan bantuan dalam proses penyusunan skripsi ini, yaitu:

1. Allah Subhanahu wa Ta'ala, Tuhan Yang Maha Esa, yang telah menganugerahkan berkah, rahmat, dan petunjuk-Nya selama proses penyusunan skripsi sehingga penulis dapat menyelesaikannya dengan lancar hingga akhir.
2. Kedua orang tua tercinta, Bapak Sanwani dan Ibu Aminah serta adik tersayang, Muhammad Sandika, yang senantiasa menjadi penguat dalam setiap langkah penulis melalui doa, semangat, dukungan baik moral maupun material yang nilainya tidak bisa diukur dengan apapun.
3. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
4. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer Universitas Lampung.
5. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D. selaku Ketua Program Studi S1 Ilmu Komputer FMIPA Universitas Lampung.
6. Bapak Bambang Hermanto, S.Kom., M.Cs. selaku Dosen Pembimbing Akademik selama penulis menempuh perkuliahan.
7. Ibu Yunda Heningtyas, M.Kom., selaku Sekretaris Jurusan Ilmu Komputer sekaligus Dosen Pembimbing Utama, yang senantiasa memberikan bimbingan, arahan, kritik, serta saran yang sangat bermanfaat bagi penulis baik dalam proses penyusunan skripsi maupun dalam hal-hal di luar skripsi.

8. Bapak Wartariyus, S.Kom., M.T.I. selaku Dosen Pembimbing Kedua yang senantiasa memberikan bimbingan, arahan, kritik, dan saran terkait penulisan skripsi.
9. Bapak Dr. rer. nat. Akmal Junaidi, M.Sc. sebagai Dosen Pembahas yang telah memberikan masukan serta saran yang bermanfaat untuk perbaikan skripsi ini.
10. Ibu Anie Rose Irawati, S.T., M.Cs. yang telah memberikan bimbingan dan petunjuk berharga selama penulis menjalani masa perkuliahan.
11. Bapak dan Ibu Dosen Jurusan Ilmu Komputer Universitas Lampung yang telah membagikan ilmu, pengetahuan serta pengalaman berharga selama penulis menempuh masa studi.
12. Seluruh Staf Jurusan Ilmu Komputer, khususnya Ibu Ade Nora Maela, yang telah membantu penulis dalam segala urusan administrasi sejak awal hingga akhir masa perkuliahan.
13. Vidya Sinta Billkis, yang tidak hanya hadir sebagai rekan penelitian, tetapi juga sebagai sahabat yang senantiasa memberikan dukungan tulus di setiap fase perjalanan ini. Penulis sangat menghargai setiap waktu, energi, dan perhatian yang telah dicurahkan dengan sepenuh hati. Terima kasih telah menjadi bagian penting dari perjalanan ini. Semoga kebersamaan, kerja sama, dan persahabatan yang telah terjalin dapat terus tumbuh dan membawa kebaikan di masa mendatang.
14. Sahabat karib “Harta Tahta Nilai A” dan “Temennya Cahya”, Abiyyi, Jihan, Cindy, Vidya, Shafa, Nabillah, Ikhsan dan Roy yang telah menemani penulis sejak awal perkuliahan. Terima kasih selalu memberikan doa, dukungan, semangat dan kebersamaan sampai saat ini. Penulis berharap agar persahabatan yang telah terjalin senantiasa terjaga dan terus memberikan makna dalam perjalanan kehidupan ke depan.
15. Sahabat seperjuangan, Kurnia, Salsa, Rivanza, dan Kartika yang senantiasa memberikan dukungan, semangat, motivasi, dan kebersamaan yang setia mengiringi setiap langkah penulis dalam menyelesaikan penelitian serta menjalani berbagai fase dalam perjalanan pendidikan ini.
16. Sahabat penulis, Sahara, Amilati, Renisya, Ihya (Alm), Marisha, Dellayla, Widiya (Alm) dan Ainun yang telah menjadi bagian dari hidup penulis. Terima kasih atas setiap doa, dukungan, dan bantuan serta kesediaan kalian menjadi tempat berbagi cerita dan keluh kesah penulis dalam menyelesaikan setiap proses termasuk penyusunan skripsi ini.
17. Teman-teman KKN, Shifa, Sayyida, Desrita, Keyza, Hermas, Zulfikar, dan keluarga desa Negeri Katon yang telah memberikan doa, dukungan, dan semangat kepada penulis selama KKN hingga saat ini.
18. Keluarga Ilmu Komputer 2021 yang telah menjadi bagian penting dalam perjalanan penulis selama menempuh pendidikan. Terima kasih telah menjadi

teman satu kelompok, *partner* diskusi sekaligus teman seperjuangan selama menempuh perjalanan akademik di Jurusan Ilmu Komputer, Universitas Lampung.

19. Seluruh pihak yang turut memberikan bantuan dan dukungan, baik secara langsung maupun tidak langsung, selama masa perkuliahan hingga proses penyusunan skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna. Namun, penulis mengharapkan karya ini dapat memberikan manfaat bagi perkembangan ilmu pengetahuan, khususnya bagi seluruh civitas akademik Jurusan Ilmu Komputer Universitas Lampung.

Bandar Lampung, 18 Juli 2025

Siti Ayuni
NPM. 2117051068

DAFTAR ISI

	Halaman
DAFTAR TABEL	ix
DAFTAR GAMBAR.....	x
DAFTAR KODE	xii
I. PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah.....	4
1.3. Batasan Masalah	5
1.4. Tujuan Penelitian	5
1.5. Manfaat Penelitian	6
II. TINJAUAN PUSTAKA.....	7
2.1. Penelitian Terdahulu	7
2.1.1. Klasifikasi Citra Daun Tumbuhan Obat Menggunakan Deteksi Tepi <i>Canny</i> dan Metode <i>K-Nearest Neighbor</i> (KNN).....	9
2.1.2. Perbandingan Arsitektur <i>MobileNetV2</i> dan <i>ResNet50</i> untuk Klasifikasi Jenis Buah Kurma	10
2.1.3. <i>Deep Learning based Ensemble Model for Accurate Tomato Leaf Disease Classification by Leveraging ResNet50 and MobileNetV2 Architectures</i>	10
2.1.4. <i>Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks</i>	11
2.1.5. Peningkatan Kinerja Arsitektur <i>ResNet50</i> untuk Menangani Masalah <i>Overfitting</i> dalam Klasifikasi Penyakit Kulit	12
2.2. Tumbuhan Herbal	13
2.2.1. Binahong (<i>Anredera cordifolia</i>).....	14
2.2.2. Sirih Hijau (<i>Piper betle</i> Linn).....	15

2.2.3. Kejibeling (<i>Serycocalyx crispus</i> L)	17
2.2.4. Pulai (<i>Alstonia scholaris</i>)	18
2.2.5. Kelor (<i>Moringa oleifera</i> Lam).....	19
2.2.6. Bidara (<i>Ziziphus mauritiana</i>)	20
2.2.7. Cincau Hijau (<i>Cyclea barbata</i> L. Miers).....	21
2.2.8. Salam (<i>Eugenia polyantha</i> Wight).....	22
2.2.9. Sambung Nyawa (<i>Gynura procumbens</i>)	23
2.2.10. Ketapang (<i>Terminalia catappa</i>)	24
2.3. Deep Learning	25
2.4. Convolution Neural Network	25
2.4.1. Input Layer	26
2.4.2. Convolutional Layer.....	27
2.4.3. Pooling Layer	29
2.4.4. Flatten Layer	30
2.4.5. Fully Connected Layer	31
2.5. Dropout	32
2.6. Activation Functions	32
2.6.1. ReLu (Rectified Linear Unit).....	33
2.6.2. Softmax	33
2.7. Transfer Learning	34
2.8. MobileNetV2	35
2.9. Residual Neural Network50 (ResNet50)	37
2.10. Dataset.....	39
2.11. Preprocessing	43
2.12. Training Model.....	45
2.12.1. Epoch.....	46
2.12.2. Batch Size	46
2.12.3. Optimizer	47

2.12.4. <i>Learning Rate</i>	47
2.12.5. <i>Early Stopping</i>	48
2.13. <i>Confusion Matrix</i>	49
2.13.1. Akurasi	51
2.13.2. Presisi	51
2.13.3. <i>Recall</i>	52
2.13.4. <i>F1-Score</i>	52
2.14. <i>Streamlit</i>	52
2.15. <i>Black Box Testing</i>	53
III. METODOLOGI PENELITIAN	54
3.4. Tempat dan Waktu Penelitian	54
3.2.1. Tempat Penelitian	54
3.2.2. Waktu Penelitian	54
3.3. Perangkat Penelitian	55
3.3.1. Perangkat Keras	55
3.3.2. Perangkat Lunak	55
3.4. Tahapan Penelitian	56
3.4.1. Studi Literatur	58
3.4.2. Pengumpulan <i>Dataset</i>	58
3.4.3. <i>Preprocessing</i>	60
3.4.4. <i>Modelling MobileNetV2</i>	62
3.4.5. <i>Modelling ResNet50</i>	65
3.4.6. Evaluasi	68
3.4.7. Pengembangan Sistem	68
IV. HASIL DAN PEMBAHASAN	73
4.1. Pengumpulan <i>Dataset</i>	73
4.2. <i>Preprocessing</i>	75
4.3. <i>Modelling MobileNetV2</i>	80
4.4. <i>Modelling ResNet50</i>	93

4.5. Evaluasi.....	104
4.6. Pengembangan Sistem	105
4.7. Pembahasan.....	108
V. SIMPULAN DAN SARAN.....	113
5.1. Simpulan	113
5.2. Saran	113
DAFTAR PUSTAKA	115
LAMPIRAN.....	127

DAFTAR TABEL

Tabel	Halaman
1. Penelitian terdahulu	7
2. Parameter pada <i>early stopping</i>	48
3. <i>Confusion matrix</i>	50
4. Jadwal penelitian.....	54
5. Lokasi pengambilan <i>dataset</i>	59
6. Pembagian <i>dataset</i>	61
7. <i>Hyperparameter training</i> arsitektur <i>MobileNetV2</i>	64
8. <i>Hyperparameter training</i> arsitektur <i>ResNet50</i>	67
9. Rancangan pengujian	71
10. <i>Dataset</i> penelitian terdahulu	73
11. <i>Dataset</i> pengambilan langsung	75
12. Ukuran gambar sebelum dan sesudah <i>resize</i>	77
13. Arsitektur <i>MobileNetV2</i>	82
14. <i>Hyperparameter tuning</i> model <i>MobileNetV2</i>	84
15. Hasil metrik evaluasi <i>MobileNetV2</i> skema 80:10:10.....	88
16. Hasil metrik evaluasi <i>MobileNetV2</i> skema 70:20:10.....	91
17. Arsitektur <i>ResNet50</i>	95
18. <i>Hyperparameter</i> model <i>ResNet50</i>	97
19. Hasil metrik evaluasi pada <i>ResNet50</i> skema 80:10:10.	100
20. Hasil perhitungan <i>confusion matrix</i> model <i>ResNet50</i>	103
21. Perbandingan kinerja model <i>MobileNetV2</i> dan <i>ResNet50</i>	104
22. Uji coba <i>preprocessing</i> pada <i>ResNet50</i>	110
23. Perbandingan <i>ResNet50</i> (tanpa normalisasi) augmentasi dan non augmentasi	111

DAFTAR GAMBAR

Gambar	Halaman
1. Daun binahong	15
2. Daun sirih.....	16
3. Daun kejibeling	17
4. Daun pulai	18
5. Daun kelor.....	20
6. Daun bidara	20
7. Daun cincau hijau	21
8. Daun salam.....	22
9. Daun sambung nyawa	23
10. Daun ketapang	24
11. Ilustrasi arsitektur CNN	26
12. Proses konvolusi	27
13. Ilustrasi proses <i>pooling</i>	30
14. Metode <i>pooling</i>	30
15. Ilustrasi flatten layer	31
16. Ilustrasi <i>fully connected</i> layer	31
17. Ilustrasi <i>dropout</i>	32
18. <i>Transfer Learning</i>	34
19. Rincian arsitektur <i>MobileNetV2</i>	35
20. <i>Bottleneck</i> pada <i>MobileNetV2</i>	36
21. Ilustrasi arsitektur <i>MobileNetV2</i>	37
22. <i>Residual neural network (ResNet)</i>	38
23. <i>Residual block</i>	38
24. Ilustrasi arsitektur <i>ResNet50</i>	39
25. Ilustrasi augmentasi rotasi.....	40
26. Ilustrasi augmentasi <i>zoom</i>	41
27. Ilustrasi augmentasi <i>flipping</i>	41
28. Ilustrasi augmentasi <i>shift</i>	42
29. Ilustrasi augmentasi <i>shear</i>	42
30. Ilustrasi <i>fill mode</i> pada augmentasi data.	43
31. Alur penelitian.	57
32. Arsitektur <i>MobileNetV2</i>	63
33. Arsitektur <i>ResNet50</i>	66
34. <i>Use case diagram</i>	69
35. <i>Activity diagram</i> petunjuk penggunaan.....	69

36. <i>Activity diagram</i> klasifikasi.	70
37. Ilustrasi pengambilan gambar.	74
38. Sampel <i>dataset</i>	75
39. Variasi ukuran <i>dataset</i>	76
40. Representasi gambar setelah <i>resize</i>	77
41. Hasil dari proses normalisasi.	78
42. Grafik akurasi dan <i>loss</i> pada proses <i>training</i> dan validasi skema 80:10:10. .	86
43. Grafik akurasi dan <i>loss</i> pada proses <i>training</i> dan validasi skema 70:20:10. .	87
44. <i>Confusion matrix</i> <i>MobileNetV2</i> skema 80:10:10.	88
45. Kesalahan klasifikasi pada <i>MobileNetV2</i> skema 80:10:10.	90
46. Kemiripan daun binahong dengan cincau.	90
47. Kemiripan daun cincau dengan ketapang.	90
48. <i>Confusion matrix</i> model <i>MobileNetV2</i> skema 70:20:10.	91
49. Kesalahan klasifikasi pada <i>MobileNetV2</i> skema 70:20:10.	92
50. Kemiripan daun cincau dan sambung nyawa.	93
51. Grafik akurasi dan <i>loss</i> pada <i>ResNet50</i> skema 80:10:10.	99
52. Grafik akurasi dan <i>loss</i> pada <i>ResNet50</i> skema 80:10:10.	99
53. <i>Confusion matrix</i> pada <i>ResNet50</i> skema 80:10:10.	101
54. Kesalahan klasifikasi pada <i>Resnet50</i> skema 80:10:10.	102
55. <i>Confusion matrix</i> <i>ResNet50</i> skema 70:20:10.	103
56. Tampilan halaman petunjuk sistem.	107
57. Tampilan halaman klasifikasi pada sistem.	107
58. Tampilan sistem berhasil klasifikasi.	107

DAFTAR KODE

Kode	Halaman
1. <i>Resize</i> gambar.	76
2. Normalisasi data.....	78
3. <i>Splitting</i> data skema 80:10:10.....	79
4. <i>Splitting</i> data skema 70:20:10.....	80
5. Inisialisasi model <i>MobileNetV2</i>	81
6. <i>Training MobileNetV2</i>	85
7. Inisialisasi model <i>ResNet50</i>	94
8. <i>Training</i> model <i>ResNet50</i>	97

I. PENDAHULUAN

1.1. Latar Belakang

Hubungan antara manusia dan tumbuhan telah menjadi hal yang tidak terpisahkan, di mana tumbuhan menjadi sumber utama untuk memenuhi kebutuhan hidup manusia. Ketergantungan ini menunjukkan betapa pentingnya kehadiran tumbuhan dalam kehidupan manusia, sebagaimana tercermin dalam etnobotani yang mempelajari bagaimana manusia memanfaatkan tumbuhan sebagai sumber bahan makanan dan naungan (Rahman dkk., 2019). Seiring waktu, manfaat tumbuhan tidak hanya terbatas pada hal tersebut, tetapi juga telah dimanfaatkan secara luas dalam pengobatan tradisional yang berlangsung turun-temurun (Lovadi dkk., 2021).

Pengobatan tradisional masih menjadi bagian aktif dalam upaya menjaga kesehatan. World Health Organization (WHO) mengungkapkan bahwa sekitar 80% penduduk dunia memanfaatkan metode pengobatan ini. Dari total 194 negara di dunia, sebanyak 179 negara masih menggunakan pengobatan tradisional dalam praktik kesehatan (WHO, 2022). Selaras dengan data global, di Indonesia sekitar 32% penduduk memanfaatkan pengobatan tradisional, termasuk pemanfaatan tumbuhan sebagai bahan herbal (Ardiansyah, 2022). Hal ini relevan mengingat Indonesia merupakan salah satu negara tropis dengan kekayaan hayati yang luar biasa atau dikenal sebagai negara megabiodiversitas. Indonesia memiliki sekitar 30.000 hingga 50.000 jenis tumbuhan, dengan sekitar 25% diantaranya berpotensi memiliki khasiat sebagai obat atau herbal (Azizan dkk., 2023).

Tumbuhan herbal dikenal sebagai sumber alami senyawa aktif seperti diterpenoid, flavonoid, gingerol, dan senyawa lainnya yang dapat digunakan untuk pencegahan maupun pengobatan berbagai penyakit (Setyaningsih & Febriyanti, 2023). Senyawa-senyawa ini terdapat di sebagian besar organ tumbuhan, termasuk daunnya (Putra dkk., 2024). Daun tumbuhan herbal telah digunakan sejak dahulu dalam pengobatan tradisional karena mudah didapat dan memiliki efek samping yang lebih rendah dibandingkan obat sintesis. Meskipun dianggap lebih aman dibandingkan obat sintesis, penggunaan daun ini tetap memerlukan perhatian terhadap cara pemakaian dan pemilihan sesuai dengan penyakit yang dialami (Silalahil, 2020). Namun, pada kenyataannya sebagian masyarakat masih memiliki pengetahuan terbatas mengenai jenis tumbuhan herbal dan manfaatnya. Hal ini disebabkan oleh berbagai faktor, termasuk keterbatasan kemampuan kognitif manusia dalam mengingat berbagai jenis tumbuhan dan kemiripan morfologi antar spesies tumbuhan.

Karakteristik morfologi daun menjadi panduan penting dalam menentukan jenis tumbuhan. Akan tetapi, beberapa bentuk daun, seperti bentuk jantung (*cordata*) serta bentuk bulat telur (*ovata*) umum dijumpai pada jenis tumbuhan yang berbeda, sehingga menyulitkan proses identifikasi (Nurdiana, 2020). Saat ini, sebagian besar masyarakat juga masih mengandalkan metode manual untuk mengenali tumbuhan yang memerlukan keahlian serta ketelitian khusus dan sering kali memakan waktu. Selain itu, metode tersebut berisiko menghasilkan kesalahan (Mardiana dkk., 2023). Kesalahan dalam mengenali tumbuhan herbal dapat menimbulkan dampak buruk, mulai dari reaksi alergi ringan hingga keracunan fatal yang mengancam jiwa (Dudi & Rajesh, 2019). Di sisi lain, ribuan tumbuhan herbal di Indonesia berpotensi terbuang karena dianggap sebagai tumbuhan liar dan budaya pemanfaatan tumbuhan herbal semakin terkikis seiring penurunan pengetahuan masyarakat sehingga potensi penggunaannya tidak maksimal (Maturahmah dkk., 2024). Permasalahan ini

dapat diatasi melalui penggunaan teknologi dalam klasifikasi citra daun tumbuhan herbal (Riska dkk., 2023).

Teknologi yang dapat dimanfaatkan untuk klasifikasi citra yaitu kecerdasan buatan dengan metode pembelajaran mesin, khususnya *deep learning*. Algoritma *deep learning* yang banyak digunakan dalam klasifikasi citra adalah *convolutional neural network* (CNN). *Convolutional neural network* (CNN) merupakan perkembangan dari *Multilayer perceptron* (MLP) yang dirancang khusus untuk memproses data dua dimensi (Nugraha dkk., 2023). Algoritma ini memiliki beberapa macam arsitektur diantaranya *MobileNetV2* dan *ResNet50*.

MobileNetV2 merupakan arsitektur *convolutional neural network* (CNN) yang dikembangkan oleh Google sebagai pengembangan pertama dari arsitektur *MobileNet* yang lebih dulu dikembangkan (Anhar & Putra, 2023). Pada versi ini terdapat dua fitur tambahan yang terdiri dari *linier bottleneck* dan *inverted residual blocks*. Arsitektur ini dikenal dengan efisiensi penggunaan sumber daya yang ringan serta kemampuannya mencapai akurasi optimal (Marpaung dkk., 2024). Selain arsitektur *MobileNetV2*, arsitektur *Residual Network* (ResNet) juga banyak diterapkan dalam klasifikasi citra. *ResNet* merupakan arsitektur yang diperkenalkan pada tahun 2015 oleh Kaiming He, Xiangyu Zhang, Shaoqing Ren dan Jian Sun yang mampu mencapai tingkat akurasi lebih tinggi dengan kesalahan pelatihan yang lebih rendah dibandingkan arsitektur CNN lainnya (He dkk., 2016). Ada beberapa tipe arsitektur *ResNet*, salah satunya yaitu *ResNet50*. Perbedaan utama antar tipe ini terletak pada jumlah *layer* yang digunakan, di mana *ResNet50* memiliki 50 *layer* sesuai dengan namanya.

Dalam penelitian yang dilakukan oleh Agyl Restu Hermanto, Abdul Aziz dan Sudianto pada tahun 2024 terkait perbandingan arsitektur *MobileNetV2* dan *RestNet50* untuk klasifikasi jenis buah kurma. *Dataset* yang digunakan dalam penelitian ini terdiri dari 300 gambar kurma, yang diklasifikasikan ke dalam tiga kelas, yaitu Ajwa, Alqassim, dan Khenaizi. Hasil penelitian

menunjukkan bahwa model *MobileNetV2* memberikan kinerja terbaik dengan akurasi sebesar 95%, sedangkan model *ResNet50* memperoleh akurasi 85% (Hermanto dkk., 2024). Akan tetapi, perbandingan kedua model ini masih jarang dilakukan pada *dataset* citra daun herbal, sehingga kinerja dalam klasifikasi tumbuhan herbal perlu dikaji lebih lanjut.

Berdasarkan uraian tersebut, penelitian ini akan membandingkan kinerja arsitektur *MobileNetV2* dan *ResNet50* untuk klasifikasi citra daun tumbuhan herbal. Penelitian ini juga merupakan pengembangan dari skripsi Hani Cita Lestari yang sebelumnya menggunakan metode deteksi tepi *Canny* dan *K-Nearest Neighbor* (KNN) dengan hasil akurasi sebesar 81,33%. Penelitian ini bertujuan untuk mengevaluasi kinerja model dalam mengklasifikasikan citra daun tumbuhan herbal dengan membandingkan dua arsitektur serta menambahkan variasi pada *dataset*. Kemiripan morfologi antar daun dalam *dataset* menjadi tantangan tersendiri dalam proses klasifikasi. Hasil penelitian ini akan diimplementasikan dalam bentuk aplikasi berbasis *web* yang mampu mengidentifikasi jenis tumbuhan herbal secara otomatis. Dengan demikian, penelitian ini diharapkan dapat memberikan wawasan baru dalam klasifikasi serta pemanfaatan tumbuhan herbal yang memiliki potensi terapeutik.

1.2. Rumusan Masalah

Berdasarkan pemaparan pada latar belakang maka rumusan masalah dalam penelitian ini, yaitu:

- a. Pengembangan model *MobileNetV2* dan *ResNet50* pada klasifikasi tumbuhan herbal berbasis citra daun masih terbatas.
- b. Perbandingan tingkat akurasi dari model *MobileNetV2* dan *ResNet50* pada klasifikasi tumbuhan herbal berbasis citra daun belum diketahui.

- c. Pengembangan aplikasi berbasis *web* yang memungkinkan pengguna mengunggah citra daun tumbuhan herbal dan menampilkan hasil klasifikasi secara informatif masih terbatas.

1.3. Batasan Masalah

Adapun batasan masalah dalam penelitian ini yaitu sebagai berikut:

- a. *Dataset* citra dalam penelitian ini terdiri dari 10 kelas daun, yaitu daun sirih (*Piper betle Linn*), daun binahong (*Anredera cordifolia*), dan daun cincau hijau (*Cyclea barbata L. Miers*, daun kejibeling (*Serycocalyx crispus L.*), daun pulai (*Alstonia scholaris*), daun kelor (*Moringa oleifera Lam*), daun bidara (*Ziziphus mauritiana*), daun salam (*Eugenia polyantha Wight*), daun sambung nyawa (*Gynura procumbens*), dan daun ketapang (*Terminalia catappa*).
- b. *Dataset* penelitian terbatas pada representasi daun tunggal dengan latar belakang berwarna putih.
- c. Unggahan gambar pada sistem yang dikembangkan dalam penelitian ini hanya menerima *file* dengan format ekstensi .jpg, .jpeg dan .png.

1.4. Tujuan Penelitian

Penelitian ini memiliki beberapa tujuan, yaitu:

- a. Mengembangkan model *MobileNetV2* dan *ResNet50* yang dapat mengklasifikasikan tumbuhan herbal berbasis citra daun.
- b. Mengetahui perbandingan tingkat akurasi model *MobileNetV2* dan *ResNet50* dalam mengklasifikasikan tumbuhan herbal berbasis citra daun.
- c. Mengembangkan aplikasi berbasis *web* yang memungkinkan pengguna mengunggah citra daun tumbuhan herbal serta menampilkan hasil klasifikasi citra daun secara informatif.

1.5. Manfaat Penelitian

Manfaat penelitian ini adalah memberikan wawasan mengenai pengembangan dan evaluasi kinerja arsitektur *MobileNetV2* dan *ResNet50* dalam klasifikasi tumbuhan herbal. Selain itu, hasil penelitian ini memberikan manfaat dalam memudahkan pengguna untuk mengenali tumbuhan herbal, meningkatkan pengetahuan serta membuka peluang untuk penelitian lebih lanjut.

II. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penelitian terdahulu mengenai klasifikasi tumbuhan berdasarkan citra telah dilakukan oleh beberapa peneliti sebelumnya. Hasil dari berbagai penelitian tersebut memberikan wawasan berharga yang menjadi dasar pengembangan klasifikasi tumbuhan herbal berbasis citra daun dalam penelitian ini. Ringkasan dari penelitian terdahulu dapat dilihat pada Tabel 1 berikut.

Tabel 1. Penelitian terdahulu

Penulis	Judul	Metode	Hasil
Lestari, 2023	Klasifikasi Citra Tepi daun Tumbuhan Obat Menggunakan Deteksi Tepi <i>Canny</i> Dan Metode <i>K-Nearest Neighbor</i> (KNN)	<i>Canny</i> dan <i>K-Nearest Neighbor</i> (KNN)	Model berhasil mencapai rata-rata akurasi sebesar 81,33% pada nilai $k = 4$, dengan akurasi terbaik ditemukan pada <i>fold</i> ke-5 yaitu 83,33%.
Hermanto dkk., 2024	Perbandingan Arsitektur <i>MobileNetV2</i> dan <i>ResNet50</i> untuk Klasifikasi Jenis Buah Kurma	<i>MobileNetV2</i> dan <i>ResNet50</i>	Kedua arsitektur berhasil mencapai akurasi terbaik pada percobaan dengan jumlah <i>epoch</i> 60. Arsitektur <i>MobileNetV2</i> menunjukkan performa terbaik dengan akurasi mencapai 95%. Sementara, <i>ResNet50</i> memperoleh akurasi sebesar 85%.

Tabel 1. Lanjutan

Penulis	Judul	Metode	Hasil
Sharma dkk., 2025	<i>Deep Learning ResNet50 dan based Ensemble MobileNetV2 Model for Accurate Tomato Leaf Disease Classification by Leveraging ResNet50 and MobileNetV2 Architectures</i>	dan	Model yang dikembangkan berhasil mencapai akurasi pengujian sebesar 99,91%, yang menunjukkan kemampuan model dalam mengklasifikasikan penyakit daun tomat dengan sangat baik. Selain itu, nilai <i>precision</i> sebesar 99,92%, <i>recall</i> sebesar 99,90%, dan <i>F1-score</i> sebesar 99,91% memperkuat bahwa model ini mampu mengenali semua kelas penyakit secara akurat dan konsisten.
Arnandito & Sasongko, 2024	<i>Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks</i>	dan	Kedua model berhasil mendapatkan akurasi sebesar 98% dalam mengidentifikasi jenis tumbuhan herbal yang merepresentasikan bahwa model memiliki performa yang baik
Pangestu & Kusrini, 2024	Peningkatan Kinerja Arsitektur <i>ResNet50</i> untuk Menangani Masalah <i>Overfitting</i> dalam Klasifikasi Penyakit Kulit	<i>ResNet50</i>	Penambahan lapisan dense dan <i>fine-tuning</i> terbukti efektif meningkatkan akurasi klasifikasi penyakit kulit, dengan peningkatan akurasi hingga 94%.

Berdasarkan Tabel 1 terdapat beberapa penelitian terdahulu yang telah dilakukan sebelumnya sebagai acuan dalam melakukan penelitian ini. Penjelasan terkait penelitian terdahulu yang digunakan adalah sebagai berikut.

2.1.1. Klasifikasi Citra Daun Tumbuhan Obat Menggunakan Deteksi Tepi *Canny* dan Metode *K-Nearest Neighbor* (KNN)

Penelitian yang dilakukan oleh Hani Citra Lestari pada tahun 2023 menerapkan metode deteksi tepi *Canny* dan algoritma *K-Nearest Neighbor* (KNN) untuk melakukan klasifikasi citra daun tumbuhan obat. Permasalahan utama dalam penelitian ini terletak pada kesulitan dalam membedakan jenis daun yang memiliki kemiripan bentuk secara visual, sehingga diperlukan metode klasifikasi berdasarkan fitur bentuk untuk meningkatkan akurasi pengenalan. *Dataset* yang digunakan terdiri atas 900 citra daun yang terbagi ke dalam tiga kelas, yaitu daun sirih (*Piper betle*), daun binahong (*Anredera cordifolia*), dan daun kejibeling (*Strobilanthes crispus*), dengan proporsi pembagian 80% untuk data latih dan 20% untuk data uji.

Tahapan penelitian ini meliputi konversi citra ke dalam format *grayscale*, reduksi *noise* menggunakan filter *Gaussian*, penerapan deteksi tepi *Canny*, serta ekstraksi berbagai fitur, seperti luas area, rasio aspek, jumlah tepi, dan total panjang tepi. Fitur-fitur yang diperoleh selanjutnya digunakan sebagai *input* pada algoritma KNN untuk proses klasifikasi menggunakan perhitungan jarak *Euclidean* sebagai dasar penentuan kedekatan antar data. Evaluasi kinerja model dilakukan menggunakan metode *5-Fold Cross Validation*, yang menunjukkan bahwa nilai parameter *k* terbaik adalah 4, dengan rata-rata akurasi klasifikasi sebesar 81,33% (Lestari, 2023).

2.1.2. **Perbandingan Arsitektur *MobileNetV2* dan *ResNet50* untuk Klasifikasi Jenis Buah Kurma**

Penelitian yang telah dilakukan oleh Agyl Restu Hermanto, Abdul Aziz dan Sudianto pada tahun 2024 ini bertujuan untuk membandingkan kinerja dua arsitektur *transfer learning*, yaitu *MobileNetV2* dan *ResNet50*, dalam mengklasifikasikan tiga jenis buah kurma, yakni Ajwa, Alqassim, dan Khenaizi. Perbandingan ini dilakukan untuk mengetahui model mana yang lebih optimal dalam hal akurasi dan efisiensi ketika diterapkan pada *dataset* dengan jumlah data terbatas. *Dataset* yang digunakan terdiri atas 300 citra, yang dibagi dengan rasio 80% untuk data pelatihan dan 20% untuk data validasi. Pada tahap pelatihan, kedua model memanfaatkan *pre-trained weights* dari ImageNet dengan beberapa modifikasi pada lapisan akhir. Model dikompilasi menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,001 dan *loss function* *categorical crossentropy*, serta dilatih masing-masing selama 20, 40, dan 60 *epoch* dengan *batch size* 32. Hasil penelitian menunjukkan bahwa *MobileNetV2* mencapai akurasi tertinggi sebesar 95% pada 60 *epoch*, sedangkan *ResNet50* hanya mencapai akurasi 85% (Hermanto dkk., 2024).

2.1.3. ***Deep Learning based Ensemble Model for Accurate Tomato Leaf Disease Classification by Leveraging ResNet50 and MobileNetV2 Architectures***

Penelitian yang dilakukan oleh J Sharma dkk pada tahun 2025 ini bertujuan untuk mengatasi permasalahan dalam klasifikasi penyakit daun tomat yang memiliki tingkat kemiripan visual yang tinggi antarkategori, sehingga menyulitkan proses identifikasi. Identifikasi yang kurang akurat dapat menyebabkan kesalahan dalam penanganan penyakit dan berdampak pada penurunan hasil

produksi pertanian. Untuk mendukung proses diagnosis yang lebih cepat dan akurat, penelitian ini mengusulkan metode klasifikasi berbasis *deep learning* dengan pendekatan *transfer learning* dan *ensemble* model. *Dataset* yang digunakan berasal dari sumber publik Kaggle, yang terdiri atas 11.000 citra daun tomat dengan 10 kategori penyakit. *Dataset* tersebut dibagi dengan proporsi 80% untuk data pelatihan, 10% untuk data validasi, dan 10% untuk data pengujian. Dua model arsitektur *pre-trained* berbasis ImageNet diterapkan dan disesuaikan melalui teknik *fine-tuning*, kemudian dikombinasikan dalam satu model *ensemble* guna meningkatkan akurasi klasifikasi. Hasil eksperimen menunjukkan bahwa model *ensemble* yang diusulkan mampu mencapai akurasi tertinggi sebesar 99,1%, dengan performa klasifikasi yang hampir sempurna pada seluruh kategori penyakit (Sharma dkk., 2025).

2.1.4. Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks

Penelitian yang dilakukan oleh Seno Arnandito dan Theopilus Bayu Sasongko pada tahun 2024 ini bertujuan untuk membandingkan kinerja dua arsitektur *deep learning*, yaitu *EfficientNetB7* dan *MobileNetV2* dalam melakukan klasifikasi citra daun tumbuhan herbal. Perbandingan dilakukan untuk mengevaluasi perbedaan performa antara arsitektur yang kompleks dan berkapasitas besar (*EfficientNetB7*) dengan arsitektur ringan dan efisien (*MobileNetV2*), khususnya dalam konteks akurasi klasifikasi. *Dataset* yang digunakan berasal dari Kaggle dan terdiri atas 1.000 citra daun dari sepuluh jenis tumbuhan herbal, yaitu daun jambu biji, daun kari, daun kemangi, daun kunyit, daun sirih, daun mint, daun pepaya, daun sirsak, lidah buaya, dan teh hijau. *Dataset* ini dibagi ke dalam tiga bagian, yaitu 70% untuk data

pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Untuk meningkatkan kemampuan generalisasi model, diterapkan teknik augmentasi citra berupa rotasi, penskalaan, dan translasi hingga 20%, serta penggunaan *fill mode* untuk menjaga kualitas citra setelah proses transformasi. Evaluasi model dilakukan menggunakan *confusion matrix*, dan hasil yang diperoleh menunjukkan bahwa model mencapai akurasi klasifikasi sebesar 98%, yang mengindikasikan performa sangat baik dalam mengidentifikasi jenis-jenis daun tumbuhan herbal secara otomatis (Arnandito & Sasongko, 2024).

2.1.5. Peningkatan Kinerja Arsitektur *ResNet50* untuk Menangani Masalah *Overfitting* dalam Klasifikasi Penyakit Kulit

Penelitian yang dilakukan oleh Handoko Adji Pangestu dan Kusrini pada tahun 2024 bertujuan untuk mengevaluasi efektivitas penerapan berbagai strategi klasifikasi penyakit kulit dengan memanfaatkan pendekatan *transfer learning* arsitektur *ResNet50*. Evaluasi ini diperlukan untuk menilai tingkat efektivitas arsitektur *ResNet50* dalam tugas klasifikasi citra penyakit kulit, sekaligus mengidentifikasi konfigurasi model yang paling optimal dalam mengatasi tantangan berupa kemiripan visual antarkelas dan keterbatasan jumlah data medis yang digunakan. Adapun tahapan penelitian mencakup *preprocessing* data, perancangan model dengan variasi jumlah lapisan *dense*, penerapan teknik *fine-tuning*, serta penambahan *dropout* sebagai upaya regularisasi. Hasil evaluasi menunjukkan bahwa penerapan *fine-tuning* dan penambahan lapisan *dense* secara individual maupun gabungan mampu meningkatkan akurasi model. Model dasar tanpa lapisan tambahan menghasilkan akurasi sekitar 90%, *fine-tuning* saja mencapai hingga 94%, sementara kombinasi *fine-tuning* dan lapisan *dense* menghasilkan akurasi sekitar 92%. Temuan ini

menunjukkan bahwa penyesuaian arsitektur dan pelatihan lanjutan pada model *pre-trained* dapat secara signifikan meningkatkan performa klasifikasi penyakit kulit (Pangestu & Kusriani, 2024).

2.2. Tumbuhan Herbal

Kajian mengenai tumbuhan herbal memiliki keterkaitan erat dengan etnobotani. Secara etimologis, istilah etnobotani berasal dari penggabungan dua kata, yaitu “etno” yang mengacu pada masyarakat dan “botani” yang berhubungan dengan tumbuhan. Etnobotani dapat diartikan sebagai cabang ilmu yang mempelajari interaksi antara masyarakat dan tumbuhan, termasuk tumbuhan herbal (Royyani dkk., 2024).

Tumbuhan herbal merupakan jenis tumbuhan yang memiliki khasiat obat dan digunakan dalam upaya penyembuhan maupun pencegahan berbagai penyakit (Haris dkk., 2024). Tumbuhan herbal dapat digunakan sebagai obat dengan berbagai cara, seperti diminum, ditempel, atau dihirup. Metode penggunaannya dirancang untuk mendukung kerja reseptor sel dalam menerima senyawa kimia atau rangsangan tertentu. Tumbuhan herbal umumnya diolah oleh masyarakat Indonesia menjadi jamu tradisional yang dibuat berdasarkan resep yang diwariskan secara turun temurun. Berbagai bagian tumbuhan berpotensi dimanfaatkan sebagai bahan herbal, termasuk daun (Kumontoy dkk., 2023).

Daun merupakan organ tumbuhan yang berperan sebagai alat hara dan hanya tumbuh pada batang. Secara morfologi, daun pada tumbuhan memiliki berbagai bentuk yang beragam, seperti bentuk jantung, bulat telur, dan lanset. Variasi bentuk tersebut menjadikan daun mudah dikenali dan memiliki fungsi yang beragam pula (Nurdiana, 2020). Daun sering dimanfaatkan karena mudah didapatkan, selalu tersedia, dan penggunaannya tidak mengganggu pertumbuhan tumbuhan (Hastuti dkk.,

2023; Isman dkk., 2021). Hasil uji klinis menunjukkan bahwa daun mengandung vitamin, mineral, dan antioksidan yang secara alami bermanfaat untuk menjaga kesehatan tubuh manusia (Herdiansah dkk., 2022). Berdasarkan Keputusan Menteri Kesehatan Nomor HK.01.07/Menkes/187/2017, beberapa jenis daun telah diakui sebagai bahan dalam ramuan obat tradisional Indonesia karena terbukti aman dan berkhasiat (Kementerian Kesehatan, 2017). Selaras dengan ketentuan yang telah ditetapkan, penelitian ini menggunakan sejumlah jenis daun dari tumbuhan herbal yang telah ditentukan sebelumnya. Jenis-jenis tumbuhan herbal yang digunakan dalam penelitian ini dijelaskan sebagai berikut.

2.2.1. Binahong (*Anredera cordifolia*)

Anredera cordifolia atau dikenal dengan binahong merupakan tumbuhan merambat dengan sifat perenial, yang berarti memiliki umur panjang dan dapat bertahan hidup selama bertahun-tahun. Binahong memiliki berbagai sebutan dalam bahasa lain, yaitu Piahong, *Hearleaf mederavine madevine* (Inggris), *Dheng san Chi* (Cina), dan Gondola (Indonesia) (Sari, 2024). Hampir seluruh bagian tumbuhan ini dapat dimanfaatkan sebagai bahan herbal, dengan daun sebagai bagian yang paling sering digunakan dalam pengobatan.

Daun binahong mengandung berbagai senyawa metabolit sekunder, seperti saponin, flavonoid, alkaloid, tanin, dan polifenol yang berperan sebagai antibiotik dan memiliki sifat antioksidan. Selain itu, daun ini juga dapat digunakan sebagai obat luka bakar, luka pasca operasi (Ramdha & Azizah, 2021), analgesik, menurunkan kadar kolesterol bahkan mampu meningkatkan fungsi ginjal yang telah rusak (Hasbullah, 2016). Manfaat daun binahong yang beragam memungkinkan penggunaannya dalam berbagai

cara, seperti dikonsumsi langsung, direbus, atau diolah lebih lanjut menjadi simplisia, serbuk, maupun kapsul (Sari, 2024).

Secara morfologi, daun binahong memiliki ciri khas berupa daun tunggal dengan tangkai yang sangat pendek, tersusun secara berseling, berwarna hijau, dan berbentuk seperti jantung dengan panjang sekitar 5 - 10 cm dan lebar berkisar antara 3 - 7 cm. Daun binahong memiliki struktur yang tipis dan lentur, ujung meruncing, pangkal yang berlekuk, tepi rata, serta permukaan halus dan berkilau (Sanjaya dkk., 2021). Representasi bentuk daun binahong ditampilkan pada Gambar 1.



Gambar 1. Daun binahong (Sartika, 2024).

2.2.2. Sirih Hijau (*Piper betle* Linn)

Sirih hijau (*Piper betle* Linn) merupakan tumbuhan herbal dari famili *Piperaceae* yang tersebar luas di kawasan tropis, termasuk Indonesia. Sirih dikenal dengan berbagai sebutan lokal yang berbeda di berbagai daerah di Indonesia meliputi suruh (Jawa), sere (Madura), seureuh (Sunda), belo (Batak Karo), sedah (Bali), ranub (Aceh) dan lainnya (Kementerian Kesehatan, 2017). Tumbuhan ini sering dimanfaatkan dalam pengobatan tradisional, terutama daunnya yang memiliki beragam khasiat. Daun sirih secara empiris terbukti memiliki manfaat dalam pengobatan berbagai penyakit.

Daun sirih hijau mengandung minyak atsiri, flavonoid, saponin, fenol, dan tanin. Senyawa-senyawa ini memiliki kemampuan sebagai antimikroba terhadap kuman dan jamur, serta bertindak sebagai antioksidan yang dapat mempercepat proses penyembuhan luka (Sadiyah dkk., 2022). Daun sirih hijau juga memiliki berbagai manfaat lainnya, seperti obat kumur untuk kesehatan gigi dan mulut, mencegah faringitis (Silviani dkk., 2024), meredakan pembengkakan payudara (Maulani & Nababan, 2022) serta mengurangi gejala infeksi saluran pernapasan atas (ISPA) (Apidianti & Widia, 2022).

Sementara itu, perbedaan antar jenis sirih dapat dibedakan melalui morfologi daunnya, meliputi bentuk, ukuran, warna, serta tekstur daun yang khas pada setiap jenis sirih. Daun sirih hijau memiliki daun tunggal sempurna berpelepah, berbentuk jantung, berwarna hijau di kedua sisi, dengan permukaan atas licin, bawah halus, serta berukuran panjang 14,5 cm, lebar 9,2 cm, dan tangkai 6 cm. Adapun penggunaan daun sirih dapat dilakukan dengan cara direbus, dikunyah, dilumatkan, atau dioleskan sesuai kebutuhan untuk mendukung berbagai pengobatan alami (Ramdhani dkk., 2024). Daun sirih hijau dapat diamati melalui Gambar 2 berikut.



Gambar 2. Daun sirih (Putri dkk., 2023).

2.2.3. Kejibeling (*Serycocalyx crispus* L)

Kejibeling (*Serycocalyx crispus* L) adalah tumbuhan herbal berhabitus semak dengan batang beruas, bulat, berbulu kasar, dan bercabang monopodial. Batangnya hijau berbintik saat muda, berubah cokelat saat tua. Daunnya tunggal, berhadapan, berbentuk bulat telur hingga lonjong, tepi beringgit, ujung dan pangkal meruncing, pertulangan menyirip, permukaan berbulu halus, dan berwarna hijau (Ambarwati dkk., 2024). Daun kejibeling dapat diamati melalui Gambar 3 berikut.



Gambar 3. Daun kejibeling (Nariswari, 2023).

Di wilayah Jawa, kejibeling juga dikenal dengan nama picah beling, enyoh kelo, dan kecibeling (Kementerian Kesehatan, 2017). Tumbuhan ini kaya akan senyawa bioaktif, seperti alkaloid, saponin, tanin, dan flavonoid, yang berpotensi sebagai antibakteri, antidiabetes, antikanker, antioksidan, dan lain sebagainya (Fardiyah dkk., 2020). Konsumsi air rebusan tumbuhan ini juga memiliki manfaat lain meliputi melancarkan buang air kecil, menghancurkan batu empedu, ginjal, dan sembelit (Kariani dkk., 2024).

2.2.4. Pulai (*Alstonia scholaris*)

Pulai (*Alstonia scholaris*), atau dikenal juga sebagai pule, merupakan tumbuhan asli Indonesia berupa pohon yang sering digunakan untuk penghijauan dan pengobatan tradisional. Pohon ini dapat tumbuh hingga 10 meter, dengan batang hijau gelap berdiameter 60 cm, akar tunggang cokelat, serta kulit kayu pahit yang menghasilkan getah cukup banyak. Daun pulai tersusun secara melingkar terdiri atas 4 - 9 helai dengan pertulangan menyirip, berwarna hijau, dan berbentuk bulat telur hingga lanset dengan ujung meruncing (Mayor & Wattimena, 2022). Daun pulai dapat dilihat pada Gambar 4.



Gambar 4. Daun pulai (Mayor & Wattimena, 2022).

Dalam pengobatan tradisional, pulai dimanfaatkan melalui perendaman atau ekstraksi. Bagian yang sering digunakan adalah kulit batang, daun, dan getahnya. Getah tumbuhan ini dapat menyembuhkan luka, tumor, dan rematik, sementara daunnya dapat mengobati beri-beri, masalah hati (Salim dkk., 2022), serta dapat dijadikan disinfektan alami (Maya dkk., 2022). Sedangkan, kulit batang pulai diketahui memiliki potensi sebagai antidiabetes (Wibisono & Martino, 2023).

2.2.5. Kelor (*Moringa oleifera* Lam)

Kelor (*Moringa oleifera* Lam) merupakan pohon kecil yang berasal dari daerah sub-Himalaya, dikenal sebagai *The Miracle Tree* karena terbukti sebagai sumber gizi dengan khasiat obat yang tinggi (Marhaeni, 2021). Di Indonesia, tumbuhan kelor memiliki berbagai nama lokal yang berbeda di setiap wilayah, yaitu murong atau munggai (Sumatera), kelor (Jawa, Bali, Lampung, Sunda), marongghi (Madura), parongge atau kawona (Nusa Tenggara) dan kelo (Maluku). Tumbuhan kelor memiliki berbagai kandungan yang bermanfaat bagi kesehatan. Senyawa aktif dalam tumbuhan ini sebagian besar terkonsentrasi pada bagian daunnya (Kementerian Kesehatan, 2017).


Daun kelor kaya nutrisi seperti vitamin C, polifenol, beta-sitosterol, dan flavonoid yang bermanfaat untuk menekan kadar kolesterol (Tjong dkk., 2021). Selain itu, daun kelor juga mengandung alkaloid dapat meningkatkan kualitas ASI (Latif & Damayanti, 2024), serta membantu menjaga dan meningkatkan kesehatan kulit (Marhawati dkk., 2023). Secara morfologi, daun kelor memiliki ciri bersirip tidak sempurna dengan bentuk bulat telur atau bundar telur terbalik. Warna daunnya bervariasi dari hijau hingga hijau kecokelatan, berukuran panjang 1 - 3 cm dan lebar 4 mm - 1 cm, dengan ujung tumpul, pangkal membulat, dan tepi rata (Adisti dkk., 2024). Representasi bentuk daun kelor dapat dilihat pada Gambar 5 berikut.



Gambar 5. Daun kelor (Adeliansyah, 2024).

2.2.6. Bidara (*Ziziphus mauritiana*)

Bidara (*Ziziphus mauritiana*) merupakan tumbuhan dari keluarga *Rhamnaceae* yang bermanfaat dalam pengobatan tradisional. Bidara termasuk pohon perdu berduri yang dapat tumbuh setinggi 15 m dengan diameter batang mencapai 40 cm. Cabang-cabangnya tumbuh menyebar, sering menggantung, saling melilit membentuk semak. Daun bidara berukuran panjang 2,5 - 3,2 cm dan lebar 1,8 - 3,8 cm, dengan tepi bergigi halus. Permukaan atas daun berwarna hijau tua cerah, sedangkan permukaan bawahnya berwarna hijau pucat hingga abu-abu. Daunnya memiliki bentuk bulat telur dengan ujung tumpul serta tiga urat memanjang yang terlihat pada pangkalnya (Prawira dkk., 2021). Visualisasi daun bidara dapat diamati pada Gambar 6.



Gambar 6. Daun bidara (Makarim, 2023).

Daun bidara diketahui mengandung berbagai senyawa kimia yang memberikan manfaat bagi kesehatan. Masyarakat umumnya memanfaatkan daun ini dalam bentuk rebusan, ekstrak, atau produk olahan lainnya untuk memperoleh khasiatnya, seperti sifat antioksidan alami dan anti mikroba (Wahyudi dkk., 2022). Berdasarkan penelitian yang dilakukan oleh Komaruddin dan rekan-rekannya mengungkapkan bahwa ekstrak daun bidara dengan konsentrasi 10% hingga 20% juga efektif digunakan sebagai pengawet alami pada daging ayam broiler (Komaruddin dkk., 2019). Daun bidara juga dapat menghasilkan busa ketika diremas dan mengeluarkan aroma wangi, sehingga berpotensi dimanfaatkan sebagai bahan dasar alami untuk pembuatan sabun (Nanda dkk., 2024).

2.2.7. Cincau Hijau (*Cyclea barbata* L. Miers)

Cincau hijau (*Cyclea barbata* L. Miers) adalah tumbuhan rambat yang berhabitus semak. Tumbuhan ini dikenal sebagai bahan baku minuman yang kaya akan senyawa bioaktif. Bagian yang dimanfaatkan dari tanaman ini adalah daunnya, yang berwarna hijau kecoklatan, berbentuk jantung, dengan ujung runcing, tepi bergerigi halus, dan pangkal tumpul (Jamal dkk., 2022) yang dapat diamati pada Gambar 7.




Gambar 7. Daun cincau hijau (Lathifah, 2024).

Daun cincau hijau memiliki khasiat untuk mengobati sakit perut atau lambung, radang, demam, panas dalam (Cahyanti dkk., 2024), serta dapat membantu menurunkan tekanan darah (Andora & Haryanti, 2021). Selain itu, cincau hijau bermanfaat untuk kecantikan wajah, seperti mencegah penuaan dini, mencerahkan kulit, dan mengurangi peradangan jerawat (Sabahiyah dkk., 2024).

2.2.8. Salam (*Eugenia polyantha* Wight)

Salam (*Eugenia polyantha* Wight) merupakan tumbuhan yang biasa digunakan sebagai bumbu masakan karena memiliki aroma khas yang dapat meningkatkan cita rasa makanan. Tumbuhan ini berupa pohon tahunan setinggi hingga 25 m yang tumbuh di ketinggian 5 -1000 m di atas permukaan laut. Daunnya berbentuk bulat telur, sementara bunganya berwarna putih dengan aroma harum yang khas. Berbagai bagian tanaman salam, termasuk daunnya, dapat dimanfaatkan dalam pengobatan tradisional (Kementerian Kesehatan Republik Indonesia, 2015). Daun salam dapat dilihat pada Gambar 8.



Gambar 8. Daun salam (Suprpto, 2020).

Daun salam mengandung berbagai senyawa yang diketahui mampu menurunkan kadar asam urat (Ayundari & Rahman, 2023). Tumbuhan ini juga dapat dimanfaatkan sebagai pengobatan untuk berbagai penyakit, termasuk diabetes, hipertensi, kencing manis serta sebagai agen antiinflamasi. Pengobatan menggunakan daun salam dapat dilakukan dengan beberapa cara meliputi teh herbal, kapsul, dan aplikasi topikal sebagai kompres (Misyilla dkk., 2023).

2.2.9. Sambung Nyawa (*Gynura procumbens*)

Sambung nyawa (*Gynura procumbens*) merupakan salah satu tumbuhan yang memiliki beragam potensi manfaat dalam dunia kesehatan. Bagian utama dari tanaman sambung nyawa yang dimanfaatkan secara luas adalah daunnya. Daun sambung nyawa memiliki bentuk tunggal, bervariasi dari bulat telur hingga lanset, dengan tepi rata, bergelombang, atau bergigi. Daunnya memiliki panjang berkisar 3,5 hingga 12,5 cm dan lebar 1 hingga 5,5 cm, dengan permukaan atas dan bawah yang berbulu halus (Kementerian Kesehatan Republik Indonesia, 2015). Representasi daun ini dapat dilihat pada Gambar 9 berikut.



Gambar 9. Daun sambung nyawa (Nasrullah, 2024).

Daun sambung nyawa kaya senyawa bioaktif yang mampu mengatasi berbagai masalah kesehatan seperti menghambat pertumbuhan bakteri *P. acnes* penyebab jerawat (Soe dkk., 2024). Daun sambung nyawa juga dapat membantu mengatasi hipertensi dengan berbagai cara konsumsi, seperti dimakan mentah sebagai lalapan atau direbus (Simamora & Hasibuan, 2021).

2.2.10. Ketapang (*Terminalia catappa*)

Ketapang (*Terminalia catappa*) merupakan tumbuhan yang dapat tumbuh subur di Indonesia dan dikenal sebagai pohon tepi pantai karena daunnya yang rindang. Pohon ini dapat tumbuh setinggi 10 - 40 m, dengan batang berbentuk bulat (teres) dan bercabang secara monopodial. Cabang-cabang ketapang tersusun bertingkat secara horizontal, membentuk kanopi yang dapat mencapai dua kali panjang pohon (Yanti dkk., 2023). Daun Ketapang dapat dilihat pada Gambar 10.



Gambar 10. Daun ketapang (Rangkuti, 2024).

Daun ketapang memiliki ujung yang bulat, bertekstur kasar, mengkilap, dan berwarna hijau tua. Ukuran daun bervariasi, dengan lebar antara 3 - 11 cm dan panjang 10 - 32 cm. Daun berubah warna menjadi kuning atau merah saat pohon berbuah.

(Mahajani dkk., 2022). Daun ketapang berkhasiat untuk mengobati penyakit kulit yang disebabkan oleh infeksi bakteri dan jamur (Putriani dkk., 2024), sedangkan bijinya memiliki manfaat sebagai agen anti-penuaan yang membantu mencegah penuaan dini (Wiyati & Noviyanti, 2024).


2.3. *Deep Learning*

Deep Learning adalah salah satu cabang dari *machine learning* yang memungkinkan model untuk belajar secara mandiri melalui mekanisme komputasi yang menyerupai cara kerja otak manusia. Teknologi ini dirancang untuk menganalisis data secara terus-menerus, mendukung pengambilan keputusan yang lebih cerdas. Untuk meningkatkan kemampuannya, *Deep Learning* menggunakan algoritma *Artificial Neural Network* (ANN), yang terinspirasi dari struktur dan fungsi jaringan biologis otak manusia (Peryanto dkk., 2019). Jaringan ini terbentuk dari beberapa lapisan *neuron* yang saling berhubungan, di mana setiap *neuron* memiliki fungsi untuk memproses informasi. Dengan tujuan untuk menemukan fitur-fitur yang kompleks dan abstrak dari data *input*, *deep learning* memungkinkan sistem untuk menyelesaikan tugas-tugas seperti pengenalan gambar, pengenalan suara, dan pemrosesan bahasa alami dengan akurasi yang lebih tinggi (Zuhdi & Utama, 2024).

2.4. *Convolution Neural Network*

Convolution Neural Network merupakan algoritma *deep learning* yang dirancang khusus untuk memproses dan mengolah data berbentuk gambar dua dimensi (Dewi dkk., 2024). Keunggulan utama CNN terletak pada kemampuannya untuk secara otomatis mempelajari dan mengekstraksi fitur dari data gambar tanpa memerlukan prapemrosesan manual yang kompleks.

Algoritma ini mampu mendeteksi pola visual dalam berbagai skala dan orientasi, sehingga sangat andal untuk pengenalan gambar (Budi dkk., 2024). Secara umum, CNN terdiri dari beberapa lapisan utama yaitu *feature learning* dan *classification layer* yang dapat dilihat pada Gambar 11 berikut.



Gambar 11. Ilustrasi arsitektur CNN (Permadi & Gumilang, 2024).

Pada bagian *feature learning*, gambar *input* diterima dan diproses melalui beberapa lapisan, yaitu lapisan konvolusi dan *pooling*. Setiap lapisan ini menghasilkan *feature map* berupa angka-angka yang merepresentasikan gambar, yang selanjutnya diteruskan ke bagian klasifikasi untuk diproses lebih lanjut. Lapisan klasifikasi terdiri dari beberapa lapisan yang memiliki *neuron-neuron* yang saling terhubung sepenuhnya (*fully connected*) dengan lapisan lainnya. Lapisan ini menerima *input* dari *output* lapisan *feature learning*, yang kemudian diproses melalui *flatten* dengan tambahan beberapa *hidden layer* pada *fully connected*, hingga menghasilkan *output* berupa akurasi klasifikasi untuk setiap kelas (Permadi & Gumilang, 2024). Adapun penjelasan dari beberapa *layer* CNN meliputi *input layer*, *convolution layer*, *pooling layer*, *flatten layer*, *fully connected layer* dan *ouput layer* sebagai berikut.


2.4.1. *Input Layer*

Input layer merupakan titik awal dalam arsitektur *Convolutional Neural Network* (CNN) di mana citra dimasukkan sebelum melalui

proses klasifikasi. Lapisan ini berfungsi untuk menerima data mentah berupa gambar dan meneruskannya ke *layer* berikutnya untuk diproses lebih lanjut. Jika manusia melihat gambar sebagai objek utuh, komputer merepresentasikan gambar sebagai kumpulan nilai piksel. Pada *layer* ini, data citra akan disesuaikan ukurannya (*resizing*) dan diatur dalam bentuk *array* numerik sesuai format *input* yang dibutuhkan model, misalnya dimensi (224, 224, 3) untuk gambar RGB. Setelah itu, data akan diteruskan ke lapisan-lapisan seperti *convolutional* dan *pooling layer* untuk mengekstraksi fitur-fitur penting dari gambar (Triwinanto dkk., 2024).

2.4.2. Convolutional Layer

Convolutional layer merupakan lapisan penting dalam CNN yang terdiri dari sejumlah *filter* yang berfungsi untuk mengekstraksi fitur dari *input* yang diberikan. *Filter* ini didefinisikan berdasarkan lebar dan tingginya (Azmi dkk., 2023). *Filter* ini digeser ke seluruh bagian citra, dan pada setiap pergeseran dilakukan operasi perkalian titik antara nilai *input* dengan nilai *filter* untuk menghasilkan *output*, yang dikenal sebagai *activation map* atau *feature map*. Hasil ini memungkinkan CNN mengenali objek di berbagai posisi pada gambar (Prastowo, 2021). Proses konvolusi ini dapat dilihat pada Gambar 12.



Gambar 12. Proses konvolusi (Azmi dkk., 2023).

Adapun parameter yang memiliki peran signifikan dalam memengaruhi proses ekstraksi fitur pada lapisan konvolusi, yaitu:

a. Kernel

Kernel atau yang juga dikenal sebagai filter, merupakan matriks multidimensi dalam arsitektur *Convolutional Neural Network* (CNN) yang berfungsi untuk mengekstraksi fitur-fitur spesifik dari data *input*, seperti tepi, pola, atau tekstur. Kernel bergerak melintasi input secara spasial dan melakukan operasi konvolusi, yaitu perkalian elemen-per-elemen antara kernel dan bagian *input* yang dilalui, kemudian menjumlahkan hasilnya menjadi satu nilai. Nilai bias biasanya ditambahkan setelah operasi konvolusi untuk memperkuat representasi. Proses ini menghasilkan matriks *output* yang disebut *feature map* atau *activation map*, yang merepresentasikan fitur yang berhasil diekstraksi. Dimensi dari *feature map* bergantung pada ukuran kernel, *padding*, dan *stride* yang digunakan (Peryanto dkk., 2020).

b. Stride


Stride merupakan parameter dalam operator konvolusi yang menentukan jumlah langkah pergeseran kernel pada *input*. Dengan *stride* $s = 1$, kernel bergeser satu piksel secara horizontal dan vertikal, menghasilkan *feature map* yang lebih besar karena kernel mengevaluasi hampir setiap posisi pada input sehingga detail informasi yang diperoleh lebih banyak. Namun, hal ini meningkatkan beban komputasi. Sebaliknya, jika *stride* lebih besar, maka ukuran *output* lebih kecil dan proses komputasi lebih efisien, tetapi beberapa informasi detail dari *input* dapat hilang karena ada bagian yang tidak dievaluasi. Oleh karena itu, pemilihan nilai *stride* harus disesuaikan dengan kebutuhan (Prastowo, 2021).

c. *Padding*

Padding merupakan parameter dalam lapisan konvolusi yang digunakan untuk menambahkan nilai, biasanya berupa nol (*zero-padding*), pada setiap sisi data *input*. Tujuan utama *padding* adalah untuk mempertahankan atau mengontrol dimensi *output feature map* sehingga dapat disesuaikan agar sama atau mendekati dimensi *input*. Hal ini terjadi karena dimensi *layer* akan berkurang setiap kali melewati proses konvolusi, yang berisiko menghilangkan informasi penting pada tepi gambar. Dengan menambahkan *padding*, informasi di tepi gambar tidak hilang dan ukuran spatial *output* dapat dijaga tetap sama dengan *input*. Hal ini penting untuk memastikan fitur penting pada pinggiran data tetap terdeteksi dan tidak terabaikan selama konvolusi (Prastowo, 2021).


2.4.3. *Pooling Layer*

Pooling layer merupakan lapisan ekstraksi yang diterapkan setelah *convolutional layer* dengan prinsip kerja menggunakan *filter* dengan ukuran dan *stride* tertentu yang bergerak melintasi seluruh area *feature map*. Tujuan utama dari proses *pooling* adalah melakukan *down-sampling* untuk mengurangi kompleksitas pada lapisan berikutnya (Prastowo, 2021). Dalam pengolahan citra, hal ini dapat dianggap sebagai proses pengurangan ukuran matriks atau resolusi citra. Ilustrasi proses *pooling* dapat diamati pada Gambar 13.



Gambar 13. Ilustrasi proses *pooling* (Prastowo, 2021).

Sementara itu, metode *pooling* yang paling umum digunakan adalah *max pooling* dan *average pooling*. *Max pooling* mengekstrak nilai maksimum dari setiap pergerakan *filter*, sedangkan *average pooling* menghasilkan nilai rata-rata dari *filter* tersebut (Panjaitan & Simatupang, 2024). Representasi *pooling layer* ditunjukkan pada Gambar 14.




Gambar 14. Metode *pooling* (Panjaitan & Simatupang, 2024).

2.4.4. Flatten Layer

Flatten layer berfungsi untuk mempersiapkan data sebagai *input* ke lapisan berikutnya dengan menggabungkan dan mengekstrak fitur menjadi satu kesatuan. Data tersebut diubah ke dalam bentuk satu


dimensi, sehingga seluruh nilai dari *flatten layer* dapat diteruskan ke *fully connected layer* yang berbentuk satu dimensi (Pratiwi, 2024). Ilustrasi proses ini dapat dilihat pada Gambar 15.



Gambar 15. Ilustrasi *flatten layer* (Suriya dkk., 2022).

2.4.5. *Fully Connected Layer*


Fully connected layer atau dikenal *dense layer* adalah lapisan jaringan saraf di mana setiap *neuron* pada *layer* ini terhubung dengan seluruh *neuron* pada *layer* sebelumnya. Sebelum proses penghubungan, semua aktivasi dari *layer* sebelumnya diubah menjadi bentuk satu dimensi (Azmi dkk., 2023). Ilustrasi *layer* ini dapat diamati pada Gambar 16.



Gambar 16. Ilustrasi *fully connected layer* (Azmi dkk., 2023).

2.5. Dropout

Dropout merupakan salah satu metode regularisasi yang digunakan untuk mencegah terjadinya *overfitting* pada model jaringan saraf, termasuk *convolutional neural network* (CNN). Teknik *dropout* bekerja dengan cara menonaktifkan sejumlah unit *neuron* secara acak selama proses pelatihan. *Neuron* yang dinonaktifkan tidak akan berkontribusi dalam proses propagasi maju (*feedforward*) maupun pembaruan bobot selama propagasi balik (*backpropagation*). Dengan menghilangkan ketergantungan antar *neuron*, *dropout* mendorong jaringan untuk membentuk representasi yang lebih *robust* dan generalisasi yang lebih baik terhadap data baru. Pemilihan *neuron* yang dinonaktifkan dilakukan secara acak pada setiap *epoch*, dan seluruh *neuron* diaktifkan kembali pada tahap inferensi untuk menghasilkan prediksi akhir (Géron, 2019). Ilustrasi penerapan teknik *dropout* pada jaringan saraf tiruan ditunjukkan pada Gambar 17.



Gambar 17. Ilustrasi *dropout* (Géron, 2019).

2.6. Activation Functions

Activation Functions merupakan komponen penting dalam *convolutional neural network* yang berfungsi untuk memperkenalkan sifat non-linear ke dalam model. Dalam arsitektur CNN, fungsi aktivasi ini ditempatkan setelah operasi konvolusi maupun *pooling* untuk menentukan apakah suatu *neuron*

akan diaktifkan atau tidak berdasarkan hasil perhitungan sebelumnya (Suhardin dkk., 2021). Fungsi aktivasi yang digunakan dalam penelitian ini mencakup ReLu dan *Softmax*, yang akan dibahas secara rinci pada subbab berikut.

2.6.1. ReLu (*Rectified Linear Unit*)

ReLU (*Rectified Linear Unit*) merupakan salah satu fungsi aktivasi yang paling umum digunakan dalam arsitektur jaringan saraf dalam, khususnya *convolutional neural network* (CNN). Fungsi ini mengeluarkan nilai yang sama dengan nilai *input* jika *input* $x > 0$. Namun, jika nilai $x \leq 0$, maka *outputnya* adalah 0 (Suhardin dkk., 2021). Secara matematis, fungsi ini dapat dilihat pada persamaan 1 berikut.

$$f(x) = \max(0, x) \dots\dots\dots(1)$$


2.6.2. *Softmax*

Softmax merupakan fungsi non-linear yang umum digunakan pada layer *output* dalam jaringan saraf tiruan, khususnya untuk tugas klasifikasi multikelas. Fungsi ini bekerja dengan mengubah vektor *input* berupa bilangan *real* berdimensi K menjadi distribusi probabilitas berdimensi K , di mana setiap nilai berada pada rentang 0 hingga 1, dan jumlah seluruh komponennya sama dengan 1. Hal ini memungkinkan model untuk menginterpretasikan *output* sebagai probabilitas dari setiap kelas (Pangestu dkk., 2020). *Softmax* menghitung probabilitas p_i dari kelas ke- i dengan persamaan 2 berikut.

$$p_i = \frac{e^{x_i}}{\sum_{k=1}^K e^{x_k}} \dots\dots\dots(2)$$

2.7. *Transfer Learning*

Transfer learning merupakan suatu metode dalam pembelajaran mesin yang memanfaatkan model atau jaringan saraf yang telah dilatih sebelumnya pada suatu tugas tertentu untuk digunakan sebagai dasar dalam mempelajari tugas baru. Dengan pendekatan ini, fitur-fitur yang telah dipelajari oleh model sebelumnya dapat ditransfer dan digunakan kembali pada tugas yang berbeda, sehingga mengurangi kebutuhan akan jumlah data pelatihan yang besar (Faturrahman dkk., 2023).



Gambar 18. *Transfer Learning* (Wijaya dkk., 2021).

Gambar 18 menunjukkan perbedaan antara *machine learning* tradisional dan *transfer learning*, di mana *transfer learning* memanfaatkan model yang telah dilatih sebelumnya (*pre-trained model*) sebagai dasar untuk menyelesaikan tugas baru melalui proses transfer pengetahuan (*knowledge transfer*). Dalam metode ini, model *pre-trained* dimodifikasi dan disesuaikan dengan karakteristik permasalahan baru melalui teknik *fine-tuning* guna meningkatkan kinerja model dalam konteks yang berbeda (Wijaya dkk., 2021).

2.8. *MobileNetV2*

MobileNetV2 merupakan arsitektur *convolutional neural network* (CNN) yang diperkenalkan oleh Google pada tahun 2018 sebagai pengembangan dari arsitektur *MobileNet*. Arsitektur ini dirancang untuk meningkatkan efisiensi dalam aplikasi *computer vision* pada perangkat seluler tanpa mengurangi akurasi. Struktur dasar dari *MobileNetV2* ditunjukkan pada Gambar 19.


Input	Operator	t	c	n	s
$224^2 \times 3$	conv2d	-	32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	conv2d 1x1	-	1280	1	1
$7^2 \times 1280$	avgpool 7x7	-	-	1	-
$1 \times 1 \times 1280$	conv2d 1x1	-	k	-	-

Gambar 19. Rincian arsitektur *MobileNetV2* (Sandler dkk., 2018).

Arsitektur *MobileNetV2* mengutamakan efisiensi komputasi melalui penggunaan *depthwise separable convolution*, yang merupakan metode konvolusi yang lebih ringan dibandingkan konvolusi konvensional. Proses ini terdiri atas dua tahap utama, yaitu *depthwise convolution* yang menerapkan satu filter konvolusi pada setiap saluran (*channel*) input secara terpisah guna mengekstrak fitur spasial, serta *pointwise convolution* (konvolusi 1x1) yang menggabungkan hasil ekstraksi tersebut dengan melakukan kombinasi linier antar *channel* untuk membentuk fitur baru. Unit dasar dari arsitektur ini adalah *Bottleneck Residual Block*, yang tersusun atas tiga komponen utama, seperti yang ditunjukkan pada Gambar 20 yaitu *expansion layer* (konvolusi 1x1) yang berfungsi memperbesar jumlah *channel*, *depthwise convolution layer* (konvolusi 3x3) yang mengekstrak fitur spasial, dan *projection layer* (konvolusi 1x1) yang bertugas

menurunkan kembali jumlah *channel* ke ukuran semula (Annur dkk., 2023). Pada *expansion layer* dan *depthwise convolution*, *MobileNetV2* menggunakan fungsi aktivasi ReLU6, yaitu variasi dari fungsi ReLU yang membatasi *output* aktivasi maksimum hingga nilai 6. Penerapan ReLU6 ini bertujuan untuk menjaga kestabilan numerik dan mencegah nilai aktivasi menjadi terlalu besar, sehingga meningkatkan efisiensi komputasi serta performa model (Yong dkk., 2023). Fungsi ReLU6 dapat didefinisikan dengan persamaan 3 berikut.

$$ReLU6(x) = \min(6, \max(0, x)) \dots\dots\dots(3)$$




Gambar 20. *Bottleneck* pada *MobileNetV2* (Annur dkk., 2023).

Setelah melewati lapisan konvolusi awal yang terdiri dari 32 filter, *MobileNetV2* mengaplikasikan 17 blok *inverted residual bottleneck* secara berurutan untuk memproses fitur secara bertingkat dan kompleks. Rangkaian blok ini diakhiri dengan *pointwise convolution* yang menghasilkan output akhir berukuran 7x7x1280 piksel. Desain tersebut bertujuan untuk mengoptimalkan efisiensi parameter dan komputasi tanpa mengurangi kemampuan representasi model. Selain itu, *MobileNetV2* memperkenalkan dua inovasi utama yang berkontribusi pada peningkatan performa model, yaitu penerapan *linear bottleneck* dengan aktivasi linear pada *output projection layer* untuk menghindari hilangnya informasi penting akibat non-linearitas berlebih, serta penggunaan *shortcut connection* antar blok yang mendukung stabilitas pelatihan, mempercepat

proses konvergensi, serta meningkatkan akurasi model (Indraswari dkk., 2021).

Untuk mendukung proses pelatihan secara optimal, teknik regulasi seperti *batch normalization* dan *dropout* juga diintegrasikan dalam arsitektur ini. Penyesuaian ukuran *input* gambar menjadi 224x224 piksel dilakukan agar sesuai dengan struktur jaringan. Dengan kombinasi efisiensi dan inovasi tersebut, *MobileNetV2* menjadi arsitektur yang sangat cocok digunakan pada aplikasi *computer vision* di perangkat dengan keterbatasan daya dan memori, tanpa mengorbankan performa model (Shahi dkk., 2022). Ilustrasi arsitektur *MobileNetV2* dapat dilihat pada Gambar 21 berikut.



Gambar 21. Ilustrasi arsitektur *MobileNetV2* (Shahi dkk., 2022).

2.9. *Residual Neural Network50 (ResNet50)*


Residual Neural Network (ResNet) merupakan salah satu arsitektur *convolution neural network* (CNN) yang diperkenalkan oleh Kaiming He, Xiangyu Zhang, Shaoqing Ren dan Jian Sun pada tahun 2016 dan berhasil memenangkan kompetisi ILSVRC pada tahun 2015 (He dkk., 2016). ResNet memiliki berbagai variasi lapisan, yang mencakup model dengan

jumlah lapisan sebanyak 18, 34, 50, 101, hingga 152 lapisan, seperti yang ditunjukkan pada Gambar 22 berikut.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2.x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3.x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4.x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5.x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9


Gambar 22. *Residual neural network (ResNet)* (He dkk., 2016).

Arsitektur ini dirancang untuk mengatasi permasalahan *degradation problem* dan *vanishing gradient problem*. *Degradation problem* merujuk pada penurunan akurasi selama proses pelatihan pada jaringan dengan jumlah lapisan yang semakin banyak. Masalah ini terjadi karena semakin dalam jaringan, informasi yang diteruskan dari lapisan awal ke lapisan akhir menjadi semakin sulit, yang mengakibatkan penurunan performa model. Sementara itu, *vanishing gradient problem* muncul ketika gradien yang digunakan untuk memperbarui bobot jaringan menjadi sangat kecil pada lapisan-lapisan yang lebih dalam, sehingga proses pelatihan menjadi sangat lambat atau sbahkan terhenti. Permasalahan tersebut dapat diatasi melalui penerapan residual yang memanfaatkan *skip connection* atau *shortcut connections*. *Residual block* ini terbagi menjadi dua jenis, yaitu *convolutional block* dan *Identity Block* (Gunawan dkk., 2020). Adapun gambaran *residual block* dapat dilihat pada Gambar 23.



Gambar 23. *Residual block* (He dkk., 2016).

ResNet50 merupakan varian dari arsitektur *ResNet* yang terdiri dari 50 lapisan dan telah dilatih menggunakan lebih dari satu juta gambar dari basis data *ImageNet*. Arsitektur ini terbagi menjadi lima tahap, di mana setiap tahap mencakup blok konvolusi dan blok identitas. Setiap blok konvolusi terdiri dari dua lapisan konvolusi, sementara setiap blok identitas memiliki tiga lapisan konvolusi. Dengan lebih dari 23 juta parameter yang dapat dilatih, *ResNet50* menunjukkan kemampuan yang sangat tinggi dalam pengenalan pola (Berliani dkk., 2023). Gambar 24 memperlihatkan struktur arsitektur *ResNet50* yang terdiri dari lima tahap konvolusi tersebut.



Gambar 24. Ilustrasi arsitektur *ResNet50* (Nashrullah dkk., 2020).

2.10. Dataset


Dataset merupakan kumpulan data yang terorganisir dan terstruktur yang digunakan untuk keperluan analisis, pelatihan model, atau penelitian dalam berbagai bidang. *Dataset* dapat berupa data yang disusun dalam bentuk tabel, gambar, teks, sinyal, video, atau kombinasi dari berbagai format tersebut. Kualitas dan variasi *dataset* yang digunakan merupakan salah satu faktor penting yang memengaruhi tingkat akurasi sebuah model *machine learning*. Kualitas *dataset* dapat ditingkatkan melalui proses *preprocessing*,

seperti menghapus data yang tidak valid, tidak konsisten, duplikat, maupun augmentasi data.

Augmentasi data merupakan teknik yang digunakan untuk meningkatkan jumlah dan variasi data sampel dengan cara memodifikasi data yang sudah ada. Teknik ini bertujuan untuk memperluas representasi data tanpa perlu mengumpulkan data baru, sehingga dapat membantu mengurangi risiko *overfitting* pada model, terutama ketika *dataset* asli terbatas (Rhamadiyanti & Kusriani, 2024). Augmentasi yang dilakukan meliputi transformasi seperti *rotation*, *zoom*, *flipping*, *shift*, *shear* hingga pengisian area kosong setelah transformasi. Berikut adalah rincian dari setiap metode augmentasi yang digunakan.

a. *Rotation*

Rotation merupakan teknik augmentasi yang memutar citra pada suatu sumbu tertentu, sehingga memungkinkan model untuk mengenali objek meskipun sudut pandang atau orientasinya berubah. Dengan memutar citra ke berbagai arah, model dilatih agar lebih tangguh terhadap rotasi alami yang mungkin terjadi dalam kondisi nyata, seperti posisi kamera yang berbeda atau arah objek yang tidak seragam (Rhamadiyanti & Kusriani, 2024). Ilustrasi *rotation* dapat dilihat pada Gambar 25.




Gambar 25. Ilustrasi augmentasi rotasi.

b. *Zoom*

Zoom adalah teknik augmentasi yang mengubah skala citra dengan cara memperbesar atau memperkecil tampilan objek. Tujuan dari teknik ini adalah melatih model agar mampu mengenali objek dalam berbagai


ukuran dan tingkat kedekatan (Arnandito & Sasongko, 2024). Ilustrasi *zoom* dapat dilihat pada Gambar 26 berikut.



Gambar 26. Ilustrasi augmentasi *zoom*.

c. *Flipping*

Flipping merupakan teknik augmentasi yang membalik gambar secara horizontal maupun vertikal, sehingga menciptakan variasi orientasi yang membantu model mengenali objek dari berbagai sudut pandang. Teknik ini memperkaya data pelatihan dengan menghasilkan versi gambar yang berbeda tanpa mengubah label aslinya (Rhamadiyanti & Kusri, 2024). Contoh visual *flipping* ditampilkan pada Gambar 27.




Gambar 27. Ilustrasi augmentasi *flipping*.

d. *Shift*

Shift merupakan teknik augmentasi citra yang dilakukan dengan menggeser posisi objek dalam gambar, baik secara horizontal maupun vertikal. Pergeseran ini bertujuan untuk menciptakan variasi posisi objek dalam *frame* tanpa mengubah bentuk atau label dari objek tersebut. Teknik ini sangat bermanfaat dalam meningkatkan


kemampuan generalisasi model terhadap data nyata yang memiliki ketidakteraturan dalam penempatan objek (Arnandito & Sasongko, 2024). Ilustrasi penerapan teknik *shift* dapat dilihat pada Gambar 28.



Gambar 28. Ilustrasi augmentasi *shift*.

e. *Shear*


Shear merupakan teknik augmentasi citra yang mengubah bentuk gambar dengan cara menggeser sebagian dari gambar secara miring, sehingga menghasilkan distorsi geometris yang menyerupai efek kemiringan. Dengan menerapkan *shear*, model dilatih untuk mengenali objek meskipun mengalami distorsi perspektif atau kemiringan yang tidak sempurna, seperti yang mungkin terjadi dalam pengambilan gambar dunia nyata. Teknik ini sangat berguna untuk meningkatkan *robustnes* model terhadap perubahan bentuk minor yang tidak merusak makna visual dari objek tersebut (Rhamadiyanti & Kusri, 2024). Ilustrasi dari teknik *shear* ditunjukkan pada Gambar 29.



Gambar 29. Ilustrasi augmentasi *shear*.

f. *Fill Mode*

Dalam proses augmentasi citra, *fill mode* merupakan parameter yang berfungsi untuk menentukan cara sistem mengisi area kosong yang muncul akibat transformasi geometris seperti rotasi, translasi, atau *zooming*. Transformasi ini dapat menyebabkan sebagian piksel gambar berpindah keluar dari batas citra asli, sehingga menciptakan ruang kosong di tepi gambar yang perlu diisi agar struktur visual citra tetap utuh dan dapat diterima oleh model. Beberapa pilihan *fill mode* yang umum digunakan, yaitu *nearest* yang mengisi area kosong dengan piksel terdekat, *constant* yang mengisinya dengan nilai tetap (misalnya nol), *reflect* yang mencerminkan piksel dari batas citra, dan *wrap* yang mengisi area kosong dengan piksel dari sisi berlawanan gambar. Pemilihan *fill mode* yang tepat dapat meningkatkan kualitas data hasil augmentasi, sehingga membantu model dalam mempelajari fitur secara lebih akurat dan robust terhadap variasi posisi objek dalam citra (Rhamadiyanti & Kusrini, 2024). Representasi visual dari *fill mode* dapat dilihat pada Gambar 30.



Gambar 30. Ilustrasi *fill mode* pada augmentasi data.

2.11. *Preprocessing*

Preprocessing merupakan tahap awal dalam pengolahan data yang bertujuan untuk mempersiapkan data mentah menjadi bentuk yang lebih terstruktur, konsisten, dan siap digunakan dalam proses analisis atau pemrosesan lebih lanjut. Keberhasilan model dalam *deep learning* sangat

dipengaruhi oleh ketersediaan data yang mencakup jumlah dan variasi yang memadai. Namun, pengumpulan data sering kali menghadapi kendala, baik dari keterbatasan variasi subjek maupun kemampuan saat proses pengambilan data (Nurdiyansyah dkk., 2024). Secara umum, tahapan *preprocessing* meliputi pembersihan data, transformasi format, penghapusan data yang tidak relevan, serta penyesuaian data agar sesuai dengan kebutuhan sistem atau algoritma yang akan diterapkan. Proses ini sangat penting untuk meningkatkan efisiensi dan efektivitas model yang akan diterapkan pada *dataset* tersebut (Kohsasih & Situmorang, 2022). Berikut adalah penjelasan dari tahapan *preprocessing* yang dilakukan.

a. *Resize*

Resize merupakan proses penyesuaian dimensi citra agar seluruh data gambar memiliki ukuran yang seragam sesuai dengan kebutuhan lapisan *input* pada arsitektur model yang digunakan. Proses ini penting dilakukan dalam tahap *preprocessing* data guna memastikan bahwa setiap citra dapat diproses secara konsisten oleh jaringan saraf tanpa mengubah karakteristik visual utama yang terkandung di dalamnya (Hermanto dkk., 2024).

b. Normalisasi Data

Normalisasi data merupakan tahap dalam proses *preprocessing* data, khususnya dalam pelatihan model. Proses ini bertujuan untuk menyamakan skala nilai antar fitur dengan mentransformasikannya ke dalam rentang tertentu, seperti $[0, 1]$ atau $[-1, 1]$. Dengan mengurangi perbedaan skala, normalisasi memastikan bahwa setiap fitur memberikan kontribusi yang seimbang terhadap proses pembelajaran, sehingga menghindari dominasi fitur dengan skala nilai yang lebih besar. Selain itu, normalisasi dapat mempercepat proses konvergensi algoritma optimisasi, meningkatkan stabilitas numerik, serta menghasilkan performa model yang lebih konsisten dan akurat (Hermanto dkk., 2024).

c. *Splitting Data*

Splitting data merupakan proses pembagian *dataset* asli ke dalam beberapa *subset* yang berbeda, yaitu data latih (*training set*), data validasi (*validation set*), dan data uji (*testing set*). Tujuan dari proses ini adalah untuk memastikan bahwa model *deep learning* yang dibangun dapat belajar dari sebagian data dan diuji kemampuannya dalam menggeneralisasi terhadap data yang belum pernah dilihat sebelumnya. Dengan demikian, evaluasi performa model menjadi lebih objektif dan mencerminkan kinerja model di dunia nyata. Pemisahan data ini sangat penting dilakukan untuk menghindari *overfitting*, yaitu kondisi ketika model terlalu menyesuaikan diri dengan data latih dan gagal mengenali pola pada data baru (Hermanto dkk., 2024).

2.12. *Training Model*

Tahap *training* pada *convolutional neural network* (CNN) merupakan proses utama di mana model dilatih untuk mempelajari pola dalam data guna mencapai akurasi yang tinggi dalam klasifikasi. Proses ini terdiri dari dua langkah utama, yaitu *feedforward* dan *backpropagation*. Pada langkah *feedforward*, data *input* diproses melalui setiap lapisan jaringan untuk mereduksi ukuran citra sekaligus memperkaya jumlah *neuron* yang terhubung. Proses ini menghasilkan prediksi awal yang akan dievaluasi berdasarkan kesalahan dengan membandingkan hasil prediksi dan label sebenarnya. Selanjutnya, pada tahap *backpropagation*, kesalahan tersebut ditelusuri kembali dari lapisan *output* hingga lapisan awal untuk memperbarui bobot dan bias jaringan menggunakan perhitungan gradien. Proses pembaruan ini bertujuan untuk mengoptimalkan parameter model, sehingga pada iterasi berikutnya, prediksi yang dihasilkan menjadi lebih akurat. *Training* dilakukan secara berulang hingga model mencapai kinerja yang diinginkan (Mbaba dkk., 2022).

Pada proses pelatihan *convolutional neural network* (CNN), *hyperparameter* merupakan parameter yang tidak dipelajari oleh model, melainkan harus ditentukan terlebih dahulu oleh pengguna sebelum model dilatih. *Hyperparameter* ini memiliki peran yang sangat penting karena dapat mempengaruhi kinerja dan akurasi model secara signifikan. Pemilihan *hyperparameter* yang tepat sangat diperlukan untuk mengoptimalkan performa model CNN. Proses pemilihan *hyperparameter* umumnya dilakukan dengan menguji berbagai kombinasi *hyperparameter* dan memilih yang paling optimal berdasarkan hasil evaluasi pada data validasi. Beberapa *hyperparameter* yang sering digunakan dalam arsitektur CNN meliputi *epoch*, *batch size*, *optimizer*, dan *learning rate* (Rochmawati dkk., 2021).

2.12.1. *Epoch*

Epoch adalah satu siklus penuh pelatihan di mana model dilatih menggunakan seluruh *dataset*. Setiap *epoch* terdiri dari beberapa iterasi, tergantung pada ukuran *batch* dan jumlah data pelatihan yang tersedia. Dalam satu *epoch*, model akan memperbarui bobot-bobotnya berdasarkan hasil perhitungan *error* atau *loss* dari prediksi terhadap label yang benar. Jumlah *epoch* yang lebih tinggi memungkinkan model untuk belajar lebih banyak dari data, tetapi juga berisiko menyebabkan *overfitting* jika terlalu banyak (Julianto dkk., 2022).

2.12.2. *Batch Size*

Batch size adalah jumlah sampel data yang diproses dalam satu iterasi sebelum bobot model diperbarui. Dalam pelatihan model,

data pelatihan dibagi menjadi beberapa *batch*, dan setiap *batch* diproses secara terpisah. Pemilihan ukuran *batch* yang tepat dapat mempengaruhi kecepatan dan kestabilan pelatihan. Ukuran *batch* yang kecil memberikan pembaruan model yang lebih sering, tetapi bisa lebih bising, sementara ukuran *batch* yang besar dapat meningkatkan stabilitas tetapi memerlukan lebih banyak memori dan waktu komputasi (Rochmawati dkk., 2021).

2.12.3. *Optimizer*

Optimizer adalah algoritma yang digunakan untuk memperbarui bobot model berdasarkan *gradien error* yang dihitung selama proses pelatihan. Tujuannya adalah meminimalkan fungsi *loss* model sehingga dapat menghasilkan prediksi yang lebih akurat. Beberapa jenis *optimizer* yang umum digunakan dalam *deep learning* adalah *Stochastic Gradient Descent* (SGD), *Adam*, dan *RMSprop*. Pemilihan *optimizer* yang tepat dapat mempercepat konvergensi dan meningkatkan akurasi model (Julianto dkk., 2022).

2.12.4. *Learning Rate*

Learning rate adalah parameter yang mengatur seberapa besar perubahan yang dilakukan pada bobot model setiap kali pembaruan dilakukan selama pelatihan. *Learning rate* yang terlalu kecil dapat membuat proses pelatihan sangat lambat, sedangkan *learning rate* yang terlalu besar dapat menyebabkan model melompati solusi optimal atau bahkan tidak konvergen sama sekali. Oleh karena itu, pemilihan *learning rate* yang tepat sangat penting untuk mencapai hasil yang optimal dalam pelatihan model (Julianto dkk., 2022).

2.12.5. *Early Stopping*

Early Stopping merupakan mekanisme untuk menghentikan pelatihan ketika metrik validasi tidak menunjukkan peningkatan selama iterasi tertentu (Géron, 2019). Selama proses pelatihan, performa model terhadap data validasi dipantau di setiap *epoch*. *Early Stopping* bekerja dengan memanfaatkan suatu kondisi pemicu yang akan aktif jika kriteria tertentu terpenuhi. Beberapa kriteria atau parameter dalam *early stopping* yaitu *patience*, *monitor*, dan *mode* seperti yang ditunjukkan pada Tabel 2.

Tabel 2. Parameter pada *early stopping* (Surya dkk., 2025)

<i>Patience</i>	<i>Monitor</i>	<i>Mode</i>	<i>Restore Best Weights</i>
5	<i>loss</i>	<i>min</i>	<i>True</i>

Tabel 2 memuat parameter-parameter dari *callback EarlyStopping* yang digunakan dalam proses pelatihan model. Setiap parameter memiliki peran penting dalam mengatur kapan pelatihan harus dihentikan secara otomatis untuk menghindari *overfitting* serta menghemat waktu komputasi. Berikut penjelasan lebih lanjut dari parameter-parameter tersebut (Surya dkk., 2025).

a. *Patience*

Patience menunjukkan jumlah *epoch* yang diperbolehkan untuk berlangsung tanpa adanya perbaikan pada performa model sebelum proses pelatihan dihentikan secara otomatis (Surya dkk., 2025). Dalam penelitian ini, nilai *patience* ditetapkan sebesar 5, yang berarti jika tidak terjadi penurunan nilai *loss* selama 5 *epoch* berturut-turut, maka pelatihan akan dihentikan lebih awal.

b. *Monitor*

Monitor merupakan metrik evaluasi yang diamati selama proses pelatihan guna menentukan apakah model mengalami peningkatan kinerja. Pada konfigurasi ini, metrik yang dipantau adalah *loss*, sehingga nilai *loss* pada data validasi akan dievaluasi setiap *epoch* untuk memantau apakah model semakin membaik (Surya dkk., 2025).

c. *Mode*

Mode digunakan untuk menentukan arah optimasi dari metrik yang dipantau, apakah harus diminimalkan atau dimaksimalkan. Dalam penelitian ini, *mode* diatur ke min, karena tujuan utamanya adalah meminimalkan nilai *loss* (Surya dkk., 2025).

d. *Restore Best Weights*

Restore Best Weights merupakan parameter pada metode *early stopping* yang berfungsi untuk mengembalikan bobot model ke kondisi terbaiknya, yaitu saat model mencapai performa paling optimal terhadap data validasi berdasarkan metrik yang dipantau (*loss*) (Géron, 2019).

2.13. *Confusion Matrix*

Confusion matrix adalah sebuah tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan hasil prediksi model dengan hasil sebenarnya (A'yunnisa dkk., 2022). Tabel ini memberikan gambaran rinci mengenai jumlah prediksi yang benar dan salah untuk setiap kelas, sehingga memudahkan dalam menghitung metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*. *Confusion matrix* terdiri dari empat komponen utama yaitu *True Positive* (TP), *True Negative* (TN), *False*

Positive (FP), dan *False Negative* (FN), yang membantu memahami kekuatan dan kelemahan model dalam mengklasifikasi data yang tercantum pada Tabel 3.

Tabel 3. *Confusion matrix* (Supono & Suprayogi, 2021)

		<i>Actual</i>									
<i>Predicted</i>	<i>Classes</i>	A	B	C	D	E	F	G	H	I	J
	A	TP(A)	FN(A) FP(B)	FN(A) FP(C)	FN(A) FP(D)	FN(A) FP(E)	FN(A) FP(F)	FN(A) FP(G)	FN(A) FP(H)	FN(A) FP(I)	FN(A) FP(J)
	B	FN(B) FP(A)	TP(B)	FN(B) FP(C)	FN(B) FP(D)	FN(B) FP(E)	FN(B) FP(F)	FN(B) FP(G)	FN(B) FP(H)	FN(B) FP(I)	FN(B) FP(J)
	C	FN(C) FP(A)	FN(C) FP(B)	TP(C)	FN(C) FP(D)	FN(C) FP(E)	FN(C) FP(F)	FN(C) FP(G)	FN(C) FP(H)	FN(C) FP(I)	FN(C) FP(J)
	D	FN(D) FP(A)	FN(D) FP(B)	FN(D) FP(C)	TP(D)	FN(D) FP(E)	FN(D) FP(F)	FN(D) FP(G)	FN(D) FP(H)	FN(D) FP(I)	FN(D) FP(J)
	E	FN(E) FP(A)	FN(E) FP(B)	FN(E) FP(C)	FN(E) FP(D)	TP(E)	FN(E) FP(F)	FN(E) FP(G)	FN(E) FP(H)	FN(E) FP(I)	FN(E) FP(J)
	F	FN(F) FP(A)	FN(F) FP(B)	FN(F) FP(C)	FN(F) FP(D)	FN(F) FP(E)	TP(F)	FN(F) FP(G)	FN(F) FP(H)	FN(F) FP(I)	FN(F) FP(J)
	G	FN(G) FP(A)	FN(G) FP(B)	FN(G) FP(C)	FN(G) FP(D)	FN(G) FP(E)	FN(G) FP(F)	TP(G)	FN(G) FP(H)	FN(G) FP(I)	FN(G) FP(J)
	H	FN(H) FP(A)	FN(H) FP(B)	FN(H) FP(C)	FN(H) FP(D)	FN(H) FP(E)	FN(H) FP(F)	FN(H) FP(G)	TP(H)	FN(H) FP(I)	FN(H) FP(J)
	I	FN(I) FP(A)	FN(I) FP(B)	FN(I) FP(C)	FN(I) FP(D)	FN(I) FP(E)	FN(I) FP(F)	FN(I) FP(G)	FN(I) FP(H)	TP(I)	FN(I) FP(J)
	J	FN(J) FP(A)	FN(J) FP(B)	FN(J) FP(C)	FN(J) FP(D)	FN(J) FP(E)	FN(J) FP(F)	FN(J) FP(G)	FN(J) FP(H)	FN(J) FP(I)	TP(J)

Keterangan:

True Positive (TP): Data positif yang diprediksi benar sebagai positif.

True Negative (TN): Data negatif yang diprediksi benar sebagai negatif.

False Positive (FP): Data negatif yang salah diprediksi sebagai positif.

False Negative (FN): Data positif yang salah diprediksi sebagai negatif.

Pada *confusion matrix*, evaluasi kinerja model dilakukan dengan menghitung metrik seperti akurasi, presisi, *recall*, dan *F1-score*, yang didasarkan pada empat komponen utama pada Tabel 3.

2.13.1. Akurasi

Akurasi merupakan ukuran yang menggambarkan sejauh mana sistem berhasil melakukan klasifikasi dengan benar. Secara teknis, akurasi didefinisikan sebagai rasio jumlah prediksi yang benar terhadap keseluruhan jumlah data yang diuji. Nilai akurasi memberikan gambaran tingkat keandalan model dalam memprediksi hasil yang sesuai dengan data sebenarnya, baik untuk kelas positif maupun negatif (Supono & Suprayogi, 2021). Persamaan akurasi dapat dilihat pada Persamaan 3 berikut.

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(3)$$

2.13.2. Presisi

Presisi merupakan salah satu metrik evaluasi yang digunakan untuk mengukur tingkat keakuratan model dalam memprediksi kelas positif di antara seluruh prediksi positif yang dihasilkan. Presisi merepresentasikan persentase prediksi positif yang benar (*True Positive*) terhadap total prediksi positif, sehingga menjadi indikator kemampuan model dalam mengidentifikasi kelas positif secara akurat tanpa mengklasifikasikan kelas negatif sebagai positif (Fatmawati & Narti, 2022). Rumus perhitungan presisi dapat dilihat pada Persamaan 4.

$$presicion = \frac{TP}{TP+FP} \dots\dots\dots(4)$$

2.13.3. *Recall*

Recall merupakan metrik evaluasi yang digunakan untuk mengukur kemampuan model dalam mengidentifikasi seluruh data positif secara tepat. *Recall* dihitung sebagai proporsi *True Positive* terhadap total data yang sebenarnya positif (*Actual Positive*). Metrik ini menggambarkan efektivitas model dalam menghindari kesalahan prediksi berupa *False Negative* (Husen, 2024). Rumus perhitungan *recall* dapat dilihat pada Persamaan 5.

$$recall = \frac{TP}{TP+FN} \dots\dots\dots(5)$$

2.13.4. *F1-Score*

F1-Score merupakan metrik evaluasi yang mengukur keseimbangan antara presisi (*precision*) dan sensitivitas (*recall*). Metrik ini menggambarkan seberapa efektif model dalam mengklasifikasikan hasil prediksi positif dan negatif secara akurat (Supono & Suprayogi, 2021). Rumus perhitungan presisi dapat dilihat pada Persamaan 6.

$$F1 - Score = 2 \times \frac{Presicion \times Recall}{Presicion+Re} \dots\dots\dots(6)$$

2.14. *Streamlit*

Streamlit adalah *framework open-source* berbasis *Python* yang dirancang untuk mempermudah pembuatan aplikasi *web* interaktif di bidang data sains dan *machine learning* (Jauhari dkk., 2024). Salah satu keunggulan *streamlit* adalah pengembang tidak perlu mengatur tampilan *website* menggunakan

CSS, HTML, atau JavaScript, karena *framework* ini sudah menyediakan berbagai fungsi bawaan untuk keperluan tersebut (Putranto dkk., 2023).

2.15. *Black Box Testing*

Black box testing merupakan metode pengujian perangkat lunak yang mengevaluasi fungsionalitas sistem tanpa memperhatikan struktur internalnya. Pengujian dilakukan dengan menganalisis *input* dan *output* tanpa mengetahui kode sumber atau algoritma yang digunakan. Proses pengujian ini dilakukan dengan menguji program yang telah dikembangkan yakni memasukkan data ke dalam setiap *form* yang tersedia guna memastikan bahwa perangkat lunak beroperasi sesuai dengan spesifikasi yang ditetapkan (Baktiar dkk., 2021). Dalam *black box testing*, pengujian biasanya dilakukan oleh tim yang berbeda dari tim pengembang perangkat lunak. Hal ini bertujuan untuk memastikan bahwa hasil pengujian tetap objektif dan tidak terpengaruh oleh pihak yang mengembangkan sistem (Rachman dkk., 2023).

III. METODOLOGI PENELITIAN

3.4. Tempat dan Waktu Penelitian

3.2.1. Tempat Penelitian

Penelitian ini dilakukan di Laboratorium Rekayasa Perangkat Lunak, Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Laboratorium tersebut beralamat di Jalan Sumantri Brojonegoro No. 1, Gedung Meneng, Kecamatan Rajabasa, Kota Bandar Lampung, Lampung 35141, Indonesia.

3.2.2. Waktu Penelitian

Penelitian ini dilaksanakan pada bulan November 2024 hingga bulan Maret 2025, sebagaimana dijelaskan secara detail pada Tabel 4.

Tabel 4. Jadwal penelitian

Nama Kegiatan	2024		2025				
	Nov	Des	Jan	Feb	Mar	Apr	Mei
Pengumpulan <i>Dataset</i>							
<i>Preprocessing</i>							
Pelatihan model (<i>MobileNetV2</i> dan <i>ResNet50</i>)							
Evaluasi model (<i>MobileNetV2</i> dan <i>ResNet50</i>)							
Pengembangan Sistem							
Penulisan Laporan							

3.3. Perangkat Penelitian

3.3.1. Perangkat Keras

Penelitian ini memanfaatkan perangkat keras berupa laptop dan kamera, dengan spesifikasi yang dijelaskan sebagai berikut.

a. Laptop

Tipe : IdeaPad Gaming 3 15IMH05
 Processor : Core™ i7-10750H
 Ram : 16 GB
 Penyimpanan : SSD 512 GB

b. Kamera

Tipe : EOS 800D
 Resolusi Sensor : 24,4 MP
 Lensa : ES-F 18-55mm IS STM (*kit lens*)

3.3.2. Perangkat Lunak

Perangkat lunak yang digunakan dalam penelitian ini yaitu:


- a. Sistem Operasi Windows 10 *Home Single Language* 64-bit sebagai sistem operasi utama yang mendukung jalannya berbagai aplikasi dan perangkat lunak lain.
- b. *Google Drive* sebagai media penyimpanan berbasis *cloud* untuk menyimpan *dataset*, *file* kode program, dan dokumen penelitian.
- c. *Google Collab* dimanfaatkan sebagai *platform* berbasis *cloud* untuk pengembangan model *MobileNetV2* dan *ResNet50* menggunakan bahasa pemrograman *Python*.
- d. *Visual Studio Code* versi 1.96.0 digunakan sebagai *text editor* atau *Integrated Development Environment* (IDE) untuk

pengembangan aplikasi berbasis *web* dengan bahasa pemrograman *Python*.

- e. *Python 3.11.4* Digunakan sebagai bahasa pemrograman utama serta *library* pendukung dalam pengembangan model seperti *Tensorflow*, *Numpy*, *Matplotlib.pyplot*, dan lainnya.
- f. *Streamlit* digunakan sebagai *framework* untuk membangun antarmuka aplikasi berbasis *web* secara interaktif dan mudah.
- g. *Lucidspark* digunakan sebagai *platform* untuk merancang diagram, termasuk diagram *Unified Modeling Language* (UML), yang digunakan untuk memvisualisasikan desain dan alur sistem secara sistematis.

3.4. Tahapan Penelitian

Penelitian ini akan dilaksanakan melalui beberapa tahapan, dimulai dari studi literatur, pengumpulan *dataset*, hingga tahap *preprocessing* data. Proses *preprocessing* mencakup pengubahan ukuran (*resize*) data, normalisasi data, serta pembagian data (*splitting*). Selanjutnya, penelitian memasuki tahap *modelling* meliputi inisialisasi model, pelatihan (*training*), dan pengujian (*testing*) model. Setelah proses *modelling* selesai, dilakukan evaluasi untuk menentukan model terbaik antara *MobileNetV2* dan *ResNet50*. Langkah berikutnya adalah mengintegrasikan kedua model ke dalam aplikasi berbasis *web* serta melakukan pengujian sistem. Alur tahapan penelitian ini dapat dilihat pada Gambar 31 dan rincian setiap proses tahapan dijelaskan pada subbab berikutnya.



Gambar 31. Alur penelitian.

3.4.1. Studi Literatur

Tahapan studi literatur dalam penelitian ini bertujuan untuk mengumpulkan informasi dan referensi yang relevan dengan topik penelitian. Pada tahap ini, dilakukan tinjauan terhadap berbagai sumber, seperti penelitian terdahulu, buku, jurnal, artikel, dan materi lainnya yang membahas teori serta konsep yang mendukung penelitian ini. Tinjauan ini mencakup topik-topik seperti tumbuhan herbal, *deep learning*, *convolutional neural network* (CNN), serta arsitektur model seperti *MobileNetV2* dan *ResNet50*, dan hal terkait lainnya.

3.4.2. Pengumpulan *Dataset*

Dalam penelitian ini *dataset* yang digunakan terdiri atas dua jenis morfologi daun, yaitu jantung dan bulat telur, sebagai objek utama dalam analisis. *Dataset* tersebut berasal dari dua sumber utama, yaitu penelitian terdahulu dan pengambilan data secara langsung. *Dataset* dari penelitian terdahulu mencakup citra daun tumbuhan sirih hijau (*Piper betle* Linn), binahong (*Anredera cordifolia*), dan kejibeling (*Serycocalyx crispus* L) yang masing-masing terdiri atas 300 citra. Sementara itu, data yang diperoleh secara langsung meliputi citra daun tumbuhan salam (*Eugenia polyantha* Wight), pulai (*Alstonia scholaris*), kelor (*Moringa oleifera* Lam), bidara (*Ziziphus mauritiana*), cincau hijau (*Cyclea barbata* L. Miers), sambung nyawa (*Gynura procumbens*), dan ketapang (*Terminalia catappa*), dengan jumlah masing-masing sebanyak 300 citra. Secara keseluruhan, total *dataset* yang digunakan dalam penelitian ini adalah 3000 citra daun.

Dataset daun tumbuhan herbal ini akan dikumpulkan dari Kota Bandar Lampung dan Kota Metro, dengan rincian lokasi pengambilan setiap daun tercantum dalam Tabel 5. Proses pengambilan citra daun akan dilakukan di Jalan Raja Ratu, Gang Raja Ratu II, Labuhan Ratu, Kecamatan Kedaton, Kota Bandar Lampung. Citra daun akan diambil menggunakan kamera Canon dengan latar belakang berupa kertas HVS ukuran A4. Gambar-gambar tersebut akan disimpan dalam format JPG atau JPEG, kemudian diunggah ke *Google Drive* untuk memudahkan akses dan penggunaan data di *Google Colab*.

Tabel 5. Lokasi pengambilan *dataset*

Nama Tumbuhan	Lokasi
Bidara (<i>Ziziphus mauritiana</i>)	Jalan Dipo, Sumberrejo Sejahtera, Kec. Kemiling, Kota Bandar Lampung
Kelor (<i>Moringa oleifera</i> Lam)	Jalan Pattimura, Sumberrejo Sejahtera, Kec. Kemiling, Kota Bandar Lampung
Cincau Hijau (<i>Cyclea barbata</i> <i>L. Miers</i>)	Gang Sungkay, Hadimulyo Timur, Kec. Metro Pusat, Kota Metro
Sambung Nyawa (<i>Gynura</i> <i>procumbens</i>)	Gang Sungkay, Hadimulyo Timur, Kec. Metro Pusat, Kota Metro
Salam (<i>Eugenia polyantha</i> <i>Wight</i>)	Jalan Abdul Muis 9, Gedong Meneng, Kec. Rajabasa, Kota Bandar Lampung
Pulai (<i>Alstonia scholaris</i>)	FMIPA Universitas Lampung, Gedong Meneng, Kec. Rajabasa, Kota Bandar Lampung
Ketapang (<i>Terminalia</i> <i>catappa</i>)	Lokasi 1: Jalan Raja Ratu, Labuhan Ratu, Kec. Kedaton, Kota Bandar Lampung Lokasi 2: Jalan Bumi Manti, Gang M. Said, Kampung Baru, Kec. Kedaton, Kota Bandar Lampung

3.4.3. *Preprocessing*

Pada tahap *preprocessing*, citra daun tanaman herbal yang telah terkumpul akan diproses agar siap digunakan pada tahap pemodelan. Proses ini meliputi beberapa langkah, seperti *resize* dan *splitting* data.

a. *Resize*

Citra daun yang telah terkumpul akan diubah ukurannya (*resize*) untuk menyeragamkan dimensi seluruh citra. Citra tersebut akan diubah ukurannya menjadi 224 x 224 piksel untuk memastikan konsistensi dan meningkatkan efisiensi pemrosesan oleh model. Penentuan ukuran ini mengacu pada dimensi input yang digunakan oleh kedua arsitektur serta merujuk pada penelitian terdahulu yang dilakukan oleh Hermanto dan rekan pada tahun 2024 yang membandingkan arsitektur *MobileNetV2* dan *ResNet50* dengan ukuran tersebut. Proses *resize* citra ini akan dilakukan secara otomatis menggunakan *library Python*, yaitu *library PIL (Python Imaging Library)*.

b. Normalisasi Data

Normalisasi data dilakukan dengan tujuan untuk menyelaraskan distribusi nilai piksel sehingga mempercepat proses pelatihan, menstabilkan gradien, dan meningkatkan performa model. Dalam konteks citra RGB dengan nilai piksel antara 0 hingga 255, normalisasi ke rentang $[-1,1]$ dilakukan dengan membagi nilai piksel dengan 127.5, kemudian mengurangnya dengan 1.

c. *Splitting Data*

Langkah terakhir dalam proses *preprocessing* adalah pembagian *dataset* (*splitting data*). *Dataset* yang digunakan terdiri dari 3000 gambar, dengan rincian yang ditunjukkan pada Tabel 6. *Dataset* ini kemudian dipisahkan menjadi tiga bagian antara lain data pelatihan, data validasi, dan data pengujian. Dalam penelitian ini, terdapat dua skema pembagian data, yaitu:

- 1) Proporsi 80:10:10, yaitu 80% data latih, 10% data validasi dan 10% data uji.
- 2) Proporsi 70:20:10 yaitu 70% data latih, 20% data validasi dan 10% data uji.

Skema pembagian data 80:10:10, mengacu pada penelitian Hani Cita Lestari pada tahun 2023 yang menjadi acuan utama dalam penelitian ini. Sebagai pembandingan, digunakan pula skema 70:20:10 yang merujuk pada penelitian Mardiana dkk pada tahun 2023, yang menggunakan *dataset* serupa dengan jumlah data sekitar 3500 yang terdiri dari 10 kelas. Proses pemisahan data dilakukan secara otomatis menggunakan modul `'train_test_split'` dari pustaka *scikit-learn*, yang memungkinkan pembagian data secara acak namun tetap proporsional. Rincian jumlah data untuk masing-masing jenis citra tumbuhan herbal ditunjukkan pada Tabel 6.

Tabel 6. Pembagian *dataset*

Tumbuhan Herbal	Jumlah Data	Data Latih	Data Validasi	Data Uji
Sirih Hijau	300	240	30	30
Binahong	300	240	30	30
Kejibeling	300	240	30	30

Tabel 6. Lanjutan

Tumbuhan Herbal	Jumlah Data	Data Latih	Data Validasi	Data Uji
Salam	300	240	30	30
Pulai	300	240	30	30
Kelor	300	240	30	30
Bidara	300	240	30	30
Cincau Hijau	300	240	30	30
Sambung Nyawa	300	240	30	30
Ketapang	300	240	30	30
Total Data	3000	2400	300	300

3.4.4. *Modelling MobileNetV2*

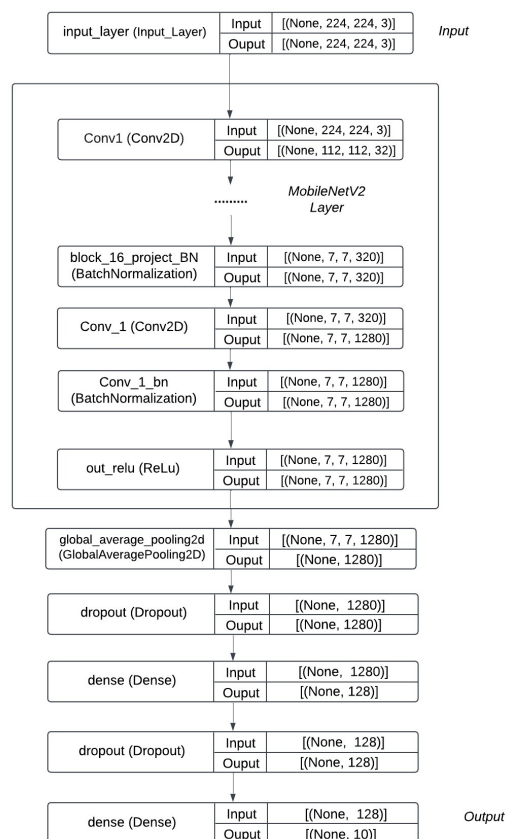
Pada tahap pemodelan dengan arsitektur *MobileNetV2*, data yang telah diproses melalui tahap *preprocessing* akan digunakan sebagai *input* untuk pelatihan model. Proses ini dilakukan secara sistematis, meliputi beberapa langkah berikut.

a. Inisialisasi Model

Pada langkah ini, arsitektur *MobileNetV2* diinisialisasi menggunakan *library TensorFlow* dan diterapkan dengan pendekatan *transfer learning*. Model *pre-trained MobileNetV2* yang telah dilatih sebelumnya pada *dataset ImageNet* diambil untuk memanfaatkan bobot awalnya. Lapisan-lapisan awal dari model ini dinonaktifkan (*set trainable=False*) untuk memastikan pengetahuan yang telah dipelajari sebelumnya tidak berubah selama proses pelatihan ulang. Selanjutnya, arsitektur model dimodifikasi untuk menyesuaikan dengan *dataset* klasifikasi citra daun herbal. Modifikasi dilakukan dengan mengganti *layer output* aslinya, yang dirancang untuk

1000 kelas *ImageNet*, dengan *layer dense* baru yang memiliki jumlah *neuron* sesuai dengan jumlah kelas pada *dataset* ini, yaitu 10 kelas dan menggunakan aktivasi *softmax* untuk menghasilkan probabilitas setiap kelas.

Selain itu, *layer GlobalAveragePooling2D* ditambahkan untuk merangkum fitur spasial menjadi vektor satu dimensi, sehingga jumlah parameter dapat dikurangi tanpa mengurangi informasi penting. Untuk mengurangi risiko *overfitting*, *layer Dropout* dengan nilai tertentu disisipkan sebelum *layer output*. *Layer Dense* dengan 128 unit ditambahkan untuk memperkuat kemampuan model dalam menangkap pola-pola kompleks, menjaga keseimbangan antara akurasi dan kompleksitas model agar terhindar dari *overfitting*. Arsitektur *MobileNetV2* dalam penelitian ini dapat dilihat pada Gambar 32.



Gambar 32. Arsitektur *MobileNetV2*.

b. *Training Model*

Proses pelatihan model dengan arsitektur *MobileNetV2* dilakukan menggunakan 2400 citra daun tumbuhan herbal (skema 1) dan 2100 citra daun sebagai data latih (skema 2). Tahapan ini bertujuan untuk mengembangkan model yang mampu mengenali pola visual serta karakteristik dari setiap jenis daun dalam *dataset*. Dalam pelatihan ini, sejumlah *hyperparameter* yang berperan penting, seperti ukuran *batch*, jumlah *epoch*, fungsi optimasi, tingkat pembelajaran (*learning rate*) telah dirancang untuk memastikan kinerja model yang optimal. Rincian lebih lanjut mengenai *hyperparameter* yang digunakan ditampilkan pada Tabel 7. Setelah seluruh proses pelatihan selesai, model yang telah terlatih disimpan dalam *file* berformat *.h5*, yang memungkinkan model tersebut untuk digunakan lebih lanjut dalam proses evaluasi, validasi, atau implementasi.

Tabel 7. *Hyperparameter training* arsitektur *MobileNetV2*

Nama Parameter	Nilai
<i>Input Size</i>	224 x 224 x 3
<i>Batch Size</i>	16
<i>Epoch</i>	30
<i>Learning Rate</i>	0.0001
<i>Optimizer</i>	Adam

c. *Testing Model*

Setelah proses pelatihan model selesai, tahap selanjutnya adalah menguji kinerja model menggunakan data uji yang telah disiapkan pada tahap pembagian *dataset*. Proses pengujian ini mencakup evaluasi akurasi menggunakan *confusion matrix*

serta pengukuran waktu eksekusi untuk menilai efisiensi kinerja model.

3.4.5. *Modelling ResNet50*


Pada tahap pemodelan menggunakan arsitektur *ResNet50*, data yang telah melalui proses *preprocessing* digunakan sebagai *input* untuk pelatihan model. Proses pemodelan dilakukan secara terstruktur dan mencakup beberapa tahapan berikut.

a. Inisialisasi Model

Pada langkah ini, arsitektur *ResNet50* diinisialisasi menggunakan *library TensorFlow* dan diterapkan dengan pendekatan *transfer learning*. Model *pre-trained ResNet50* yang telah dilatih sebelumnya pada *dataset ImageNet* diambil untuk memanfaatkan bobot awalnya. Lapisan-lapisan awal dari model ini dinonaktifkan (*set trainable=False*) untuk memastikan pengetahuan yang telah dipelajari sebelumnya tidak berubah selama proses pelatihan ulang. Selanjutnya, arsitektur model dimodifikasi untuk menyesuaikan dengan *dataset* klasifikasi citra daun herbal. Modifikasi dilakukan dengan mengganti *layer output* aslinya, yang dirancang untuk 1000 kelas *ImageNet*, dengan *layer dense* baru yang memiliki jumlah *neuron* sesuai dengan jumlah kelas pada *dataset* ini, yaitu 10 kelas dan menggunakan aktivasi *softmax* untuk menghasilkan probabilitas setiap kelas.

Selain itu, *layer GlobalAveragePooling2D* ditambahkan untuk merangkum fitur-fitur spasial menjadi vektor satu dimensi, sehingga mengurangi jumlah parameter tanpa kehilangan informasi penting. Untuk mengurangi risiko *overfitting*, *layer*

Dropout dengan nilai tertentu disisipkan sebelum *layer output*. Setelah itu, terdapat layer *Dense* dengan 128 neuron yang berfungsi sebagai lapisan *fully connected* untuk menangkap pola lebih kompleks. Arsitektur *ResNet50* dalam penelitian ini dapat dilihat pada Gambar 33.



Gambar 33. Arsitektur *ResNet50*.

b. *Training Model*

Proses pelatihan model dengan arsitektur *ResNet50* dilakukan menggunakan 2400 citra daun (skema 1) dan 2100 citra daun

tumbuhan herbal (skema 2) sebagai data latih. Tahapan ini bertujuan untuk mengembangkan model yang mampu mengenali pola visual serta karakteristik unik dari setiap jenis daun dalam *dataset*. Dalam pelatihan ini, sejumlah *hyperparameter* yang berperan penting, seperti ukuran *batch*, jumlah *epoch*, fungsi optimasi, tingkat pembelajaran (*learning rate*) telah dirancang untuk memastikan kinerja model yang optimal. Rincian lebih lanjut mengenai *hyperparameter* yang digunakan ditampilkan pada Tabel 8. Setelah seluruh proses pelatihan selesai, model yang telah terlatih disimpan dalam *file* berformat *.h5*, yang memungkinkan model tersebut untuk digunakan lebih lanjut dalam proses evaluasi, validasi, atau implementasi.

c. *Testing Model*

Setelah proses pelatihan model selesai, tahap selanjutnya adalah menguji kinerja model menggunakan data uji yang telah disiapkan pada tahap pembagian *dataset*. Proses pengujian ini mencakup evaluasi akurasi menggunakan *confusion matrix* serta pengukuran waktu eksekusi untuk menilai efisiensi kinerja model.

Tabel 8. *Hyperparamater training* arsitektur *ResNet50*

Nama Parameter	Nilai
<i>Input Size</i>	224 x 224 x 3
<i>Batch Size</i>	16
<i>Epoch</i>	30
<i>Learning Rate</i>	0.0001
<i>Optimizer</i>	Adam

3.4.6. Evaluasi

Pada tahap evaluasi, hasil akurasi dan waktu eksekusi dari arsitektur *MobileNetV2* dan *ResNet50* akan dibandingkan untuk menentukan arsitektur yang paling optimal. Perbandingan antara kedua model ini akan memberikan gambaran mengenai keseimbangan antara akurasi dan efisiensi komputasi.

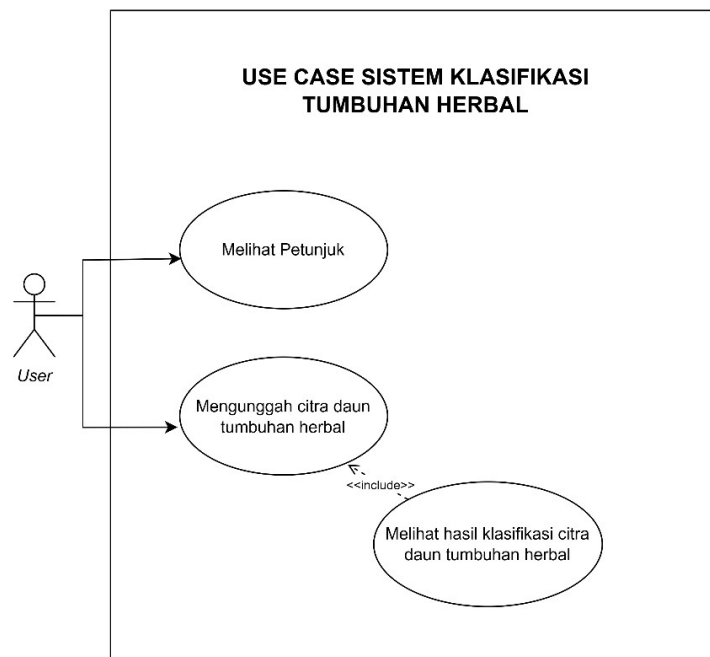
3.4.7. Pengembangan Sistem

Pada tahap ini, model akan diintegrasikan ke dalam aplikasi berbasis *web*. Proses pengembangan sistem ini melibatkan beberapa langkah, yaitu:

a. Desain *Unified Modeling Language* (UML)


Langkah pertama dalam pengembangan sistem adalah merancang dan menggambarkan alur kerja sistem menggunakan *unified modeling language* (UML). UML yang digunakan mencakup *use case diagram* dan *activity diagram*. *Use case diagram* untuk sistem ini dapat dilihat pada Gambar 34.

Sistem klasifikasi daun tumbuhan herbal memiliki satu aktor utama, yaitu *user*. *User* memiliki tiga aktivitas utama dalam sistem ini antara lain melihat petunjuk penggunaan sistem, mengunggah gambar daun, dan melihat hasil klasifikasi. Aktivitas ini dijelaskan dalam *use case diagram* dan dua *activity diagram* terpisah.




Gambar 34. *Use case diagram.*

Gambar 35 menunjukkan alur melihat panduan, dimana *user* dapat mengetahui cara penggunaan sistem. Sementara Gambar 36 menunjukkan proses unggah gambar hingga hasil klasifikasi ditampilkan. Pembagian ini mempermudah pemahaman alur sistem secara keseluruhan.



Gambar 35. *Activity diagram* petunjuk penggunaan.



Gambar 36. *Activity diagram* klasifikasi.

b. Implementasi Sistem

Sistem ini akan dikembangkan menggunakan bahasa pemrograman Python dengan dukungan dari *library Streamlit*

dan *TensorFlow*. *Streamlit* akan digunakan untuk membangun antarmuka pengguna, sementara *TensorFlow* akan digunakan untuk mengimplementasikan dan menjalankan model *deep learning* yang telah dikembangkan.

c. Pengujian Sistem

Pengujian dalam penelitian ini diawali dengan menyusun *test case* untuk menguji aplikasi berbasis *web* klasifikasi tumbuhan herbal berdasarkan citra daun menggunakan metode *black box testing*. Pengujian dilakukan oleh lima *software developer* berpengalaman yang terpisah dari tim pengembang untuk menjaga objektivitas hasil. Pengujian dilakukan dengan berbagai skenario untuk memastikan sistem mampu memproses setiap kemungkinan *input* dengan tepat. Formulir pengujian dibagikan kepada para penguji sebagai pedoman dalam menjalankan setiap *test case*. Rincian pengujian disajikan dalam Tabel 9 berikut.

Tabel 9. Rancangan pengujian

Kode Uji	Skenario	Input	Ekspektasi Output
A1	Mengunggah gambar dalam format valid (.jpg, .jpeg, .png)	Unggah gambar .jpg, .jpeg, .png	Sistem menerima citra, menampilkan pratinjau
A2	Mengunggah gambar rusak atau tidak terbaca	Unggah <i>file</i> corrupt	Muncul pesan <i>error</i> “✗ File tidak dapat dibaca sebagai gambar. Pastikan <i>file</i> tidak <i>corrupt</i> dan benar-benar berformat gambar”

Tabel 9. Lanjutan

Kode Uji	Skenario	Input	Ekspektasi Output
A3	Tombol klasifikasi hanya muncul setelah pengguna berhasil mengunggah gambar dengan format valid (.jpg, .jpeg, .png)	Sebelum gambar diunggah, tombol klasifikasi belum ditampilkan. Setelah gambar berhasil diunggah, tombol klasifikasi akan muncul secara otomatis.	Tombol klasifikasi muncul otomatis di UI, setelah gambar berhasil diunggah
A4	Gambar berhasil diklasifikasikan oleh sistem	Klik tombol klasifikasi setelah unggah gambar	Muncul hasil klasifikasi dari dua model meliputi gambar pohon tumbuhan, klasifikasi ilmiah, dan keakuratan
A5	Pengguna mengganti gambar yang sudah diklasifikasikan dengan gambar baru melalui fitur unggah	Unggah gambar lain untuk menggantikan gambar yang sebelumnya sudah diunggah	Gambar lama akan terganti dengan gambar baru, dan hasil prediksi sebelumnya tidak lagi ditampilkan
A6	Mengunggah <i>file</i> format tidak valid (gif, pdf, txt, dan lainnya)	Unggah <i>file</i> format tidak valid (gif, pdf, txt, dan lainnya)	Sistem menolak unggahan, menampilkan pesan <i>error</i> "✗ Format file tidak valid. Hanya file .jpg, .jpeg, dan .png yang diperbolehkan"

V. SIMPULAN DAN SARAN

5.1. Simpulan

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan sebagai berikut

- a. Arsitektur *MobileNetV2* dan *ResNet50* berhasil digunakan dalam klasifikasi citra daun tumbuhan herbal dengan pendekatan *transfer learning* menggunakan bobot *pre-trained* ImageNet.
- b. *MobileNetV2* menunjukkan akurasi lebih tinggi pada data uji internal maupun external dibandingkan *ResNet50* dengan selisih akurasi terbaik sebesar 0,33% serta memiliki waktu pemrosesan (*inference time*) yang lebih cepat dibandingkan *ResNet50* dengan selisih waktu maksimum sebesar 463,63 detik.
- c. Penelitian ini berhasil mengembangkan sebuah *website* yang memungkinkan pengguna mengunggah citra daun tumbuhan herbal dan secara otomatis memperoleh hasil klasifikasi, sehingga dapat berperan sebagai alat bantu dalam proses klasifikasi tumbuhan herbal.

5.2. Saran

Saran yang dapat diberikan untuk melanjutkan penelitian ini sebagai berikut:

- a. Melakukan perbaikan terhadap teknik akuisisi data lapangan untuk memastikan akurasi dan keterwakilan data yang lebih tinggi.

- b. Menambahkan jumlah kelas agar model mampu mengklasifikasikan lebih banyak jenis tumbuhan herbal.
- c. Mengembangkan pendekatan penanganan data di luar cakupan distribusi pelatihan agar model lebih *robust* terhadap *input* yang tidak dikenali atau tidak relevan.
- d. Menerapkan teknik augmentasi data dengan metode yang berbeda untuk meningkatkan jumlah dan keragaman data, sehingga model dapat belajar dari variasi bentuk dan kondisi pencahayaan yang lebih luas.
- e. Mengembangkan fitur *feedback* pada *website*, sehingga pengguna dapat memberikan masukan terhadap hasil klasifikasi yang ditampilkan.

DAFTAR PUSTAKA

- A'ayunnisa, N., Salim, Y., & Azis, H. (2022). Analisis performa metode Gaussian Naïve Bayes untuk klasifikasi citra tulisan tangan karakter arab. *Indonesian Journal of Data and Science (IJODAS)*, 3(3), 115–121.
- Adeliansyah. (2024). *Beberapa Manfaat Daun Kelor bagi Kesehatan*. Radio Republik Indonesia. Diakses pada tanggal 12 Desember 2024, dari <https://www.rri.co.id/kesehatan/951285/beberapa-manfaat-daun-kelor-bagi-kesehatan>
- Adisti, Y., Vanesa, T., Wahyuni, & Khairani, M. (2024). Pemanfaatan Daun Kelor (*Moringa oleifera*) untuk Bahan Dasar Pembuatan Cendol Jelly sebagai Minuman Tradisional. *Sci-Tech Journal*, 3(1), 1–9. <https://doi.org/10.56709/stj.v3i1.120>
- Ambarwati, D., Nugraheni, D. R., Fadiyah, I., & Inggawana, N. S. (2024). Identifikasi Tumbuhan Obat Yang Terdapat Di Kebun Raya Purwodadi Pasuruan. *Jurnal Konservasi Sumber Daya Alam dan Lingkungan (CONSERVA)*, 2(1), 32–48. <https://conserva.unmuhbabel.ac.id/index.php>
- Andora, N., & Haryanti, R. P. (2021). Perbedaan Pengaruh Pemberian Air Kelapa Muda Dan Cincau Hijau Terhadap Perubahan Tekanan Darah Pada Penderita Hipertensi. *Dinamika Kesehatan Jurnal Kebidanan dan Keperawatan*, 12(1), 199–209. <https://doi.org/10.33859/dksm.v12i1.718>
- Anhar, & Putra, R. A. (2023). Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN). *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(2), 466–478. <https://doi.org/10.26760/elkomika.v11i2.466>
- Annur, I. F., Umami, J., Annaflii, Moch. N., Trisnaningrum, N., & Putra, O. V. (2023). Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetv2. *Fountain of Informatics Journal*, 8(1), 7–14. <https://doi.org/10.21111/fij.v8i1.9419>
- Apidianti, S. P., & Widia, S. R. (2022). Pengaruh Pemberian Daun Sirih Hijau terhadap Penurunan Gejala ISPA pada Balita. *Journal Of Health Science*, 7(1), 28–33. <https://www.ejournalwiraraja.com/index.php/JIK>
- Ardiansyah. (2022). *Perkembangan Obat dan Pengobatan Tradisional Dalam Kesehatan Masyarakat dan Pemanfaatannya di Rumah Sakit*. Kementerian

Kesehatan Republik Indonesia. Diakses pada tanggal 12 Desember 2024, dari https://yankes.kemkes.go.id/view_artikel/13/perkembangan-obat-dan-pengobatan-tradisional-dalam-kesehatan-masyarakat-dan-pemanfaatannya-di-rumah-sakit

- Arnandito, S., & Sasongko, T. B. (2024). Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks. *Journal of Applied Informatics and Computing (JAIC)*, 8(1), 176–185. <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Ayundari, P., & Rahman, S. (2023). Pengaruh Pemberian Ekstrak Daun Salam (Eugenia Polyantha) Terhadap Kadar Asam Urat Pada Pasien Prolanis di Klinik Iman. *Jurnal Pendidikan Tambusai*, 7(3), 20497–20504.
- Azizan, N., Adawiyah, S., & Lubis, M. A. (2023). Apotek Hidup Untuk Masyarakat di Desa Lobung. *Khidmat Almujtamae: Jurnal Pengabdian Masyarakat*, 1(2), 21–27. <https://ejournal.stai-br.ac.id/index.php/KHAMU>
- Azmi, K., Defit, S., & Sumijan. (2023). *Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat*. 16(1), 28–40.
- Baktiar, A. R., Mulainsyah, D., Sasgoro, E. C., & Sumiati, E. (2021). Pengujian Menggunakan Black Box Testing dengan Teknik State Transition Testing Pada Perpustakaan Yayasan Pendidikan Islam Pakualam Berbasis Web. *Jurnal Kreativitas Mahasiswa Informatika (JATIMIKA)*, 2(1), 142–145. <https://doi.org/10.37676/jmi.v14i1.472>
- Berliani, T., Rahardja, E., & Septiana, L. (2023). Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16. *Journal of Medicine and Health*, 5(2), 123–135. <https://doi.org/10.28932/jmh.v5i2.6116>
- Budi, E. S., Chan, A. N., Alda, P. P., & Idris, M. A. F. (2024). Optimasi Model Machine Learning untuk Klasifikasi dan Prediksi Citra Menggunakan Algoritma Convolutional Neural Network. *RESOLUSI: Rekayasa Teknik Informatika dan Informasi*, 4(5), 502–509. <https://djournals.com/resolusi>
- Cahyanti, F. A., Eskundari, R. D., & Purwanto, A. (2024). Wild Edible Plants as an Alternative Food Source for The Community of Pakis Baru Village, Nawangan, Pacitan. *Jurnal Biologi Tropis*, 24(2), 352–367. <https://doi.org/10.29303/jbt.v24i2.6779>
- Dewi, S., Ramadhani, F., & Djasmayena, S. (2024). Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network). *Jurnal Ilmu Komputer*, 3(2), 68–73. <https://doi.org/10.56211/helloworld.v3i2.518>

- Dudi, B., & Rajesh, V. (2019). Medicinal Plant Recognition based on CNN and Machine Learning. *International Journal of Advanced Trends in Computer Science and Engineering*, 8(4), 999–1003. <https://doi.org/10.30534/ijatcse/2019/03842019>
- Fardiyah, Q., Suprpto, Kurniawan, F., Ersam, T., Slamet, A., & Suyanta. (2020). Preliminary Phytochemical Screening and Fluorescence Characterization of Several Medicinal Plants Extract from East Java Indonesia. *IOP Conference Series: Materials Science and Engineering*, 833(1), 1–7. <https://doi.org/10.1088/1757-899X/833/1/012008>
- Fatmawati, F., & Narti, N. (2022). Perbandingan Algoritma C4.5 dan Naive Bayes Dalam Klasifikasi Tingkat Kepuasan Mahasiswa Terhadap Pembelajaran Daring. *JTIM: Jurnal Teknologi Informasi dan Multimedia*, 4(1), 1–12. <https://doi.org/10.35746/jtim.v4i1.196>
- Faturrahman, R., Hariyani, Y. S., & Hadiyoso, S. (2023). Klasifikasi Jajanan Tradisional Indonesia berbasis Deep Learning dan Metode Transfer Learning. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(4), 945–957. <https://doi.org/10.26760/elkomika.v11i4.945>
- Géron, A. (2019). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow* (N. Tache, Ed.; 2 ed.). O'Reilly Media.
- Gunawan, I. K., Bayupati, I. P. A., & Wibawa, K. S. (2020). Segmentasi Buah Apel Menggunakan Framework YOLACT Arsitektur Resnet-101. *JITTER-Jurnal Ilmiah Teknologi dan Komputer*, 1(2).
- Haris, M., Fauzi, A., & Khair, H. (2024). Pemilihan Tanaman Herbal Untuk Meningkatkan Imun Tubuh Manusia Menggunakan Metode Weighted Product. *Indonesian Journal of Science, Technology and Humanities*, 1(3), 139–147.
- Hasbullah, U. H. A. (2016). Kandungan senyawa Saponin pada daun, batang dan umbi tanaman Binahong (*Anredera cordifolia* (Ten) Steenis). *Planta Tropika: Journal of Agro Science*, 4(1), 20–24. <https://doi.org/10.18196/pt.2016.052.20-24>
- Hastuti, Alang, H., & Adriani. (2023). Pemanfaatan Tumbuhan sebagai Obat oleh Masyarakat di Desa Lor-Lor, Kepulauan Aru, Provinsi Maluku. *Spizaetus: Jurnal Biologi dan Pendidikan Biologi*, 4(1), 47–56. <https://doi.org/10.55241/spibio.v4i1.108>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 770–778. https://openaccess.thecvf.com/content_cvpr_2016/papers/He_Deep_Residual_Learning_CVPR_2016_paper.pdf

- Herdiansah, A., Borman, R. I., Nurnaningsih, D., Sinlae, A. A. J., & Al Hakim, R. R. (2022). Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk. *JURIKOM (Jurnal Riset Komputer)*, 9(2), 388–395. <https://doi.org/10.30865/jurikom.v9i2.4066>
- Hermanto, A. R., Aziz, A., & Sudianto, S. (2024). Perbandingan Arsitektur MobileNetV2 dan RestNet50 untuk Klasifikasi Jenis Buah Kurma. *JUSTIN: Jurnal Sistem dan Teknologi Informasi*, 12(4), 630–637. <https://doi.org/10.26418/justin.v12i4.80358>
- Husen, D. (2024). Klasifikasi Citra MRI Tumor Otak Menggunakan Metode Convolutional Neural Network. *bit-Tech*, 7(1), 143–152. <https://doi.org/10.32877/bt.v7i1.1576>
- Indraswari, R., Rokhana, R., & Herulambang, W. (2021). Melanoma Image Classification based on MobileNetV2 Network. *Procedia Computer Science*, 198–207. <https://doi.org/10.1016/j.procs.2021.12.132>
- Isman, Andani Ahmad, & Abdul Latief. (2021). Perbandingan Metode KNN Dan LBPH Pada Klasifikasi Daun Herbal. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(3), 557–564. <https://doi.org/10.29207/resti.v5i3.3006>
- Jamal, N. A., Putri, R., Ulandhari, D., Masyururah, E. R., Demis, M. A., & Duprah, N. (2022). *Kekayaan dan Pemanfaatan Tumbuhan Obat* (M. Wiharto, O. Jumadi, M. Junda, Mu'nisa, & E. I. Yasmin, Ed.).
- Jauhari, N. M. I., Wulanningrum, R., & Setiawan, A. B. (2024). Sistem Deteksi Kendaraan Menggunakan StreamLit Metode Yolo Universitas Nusantara PGRI Kediri. *Seminar Nasional Inovasi Teknologi*, 8(3), 1331–1336.
- Julianto, A., Sunyoto, A., & Wibowo, F. W. (2022). Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi. *TEKNIMEDIA*, 3(2), 98–105.
- Kariani, N. K., Fadhli, W. M., Masikki, M. F. D. D., Pratiwi, S., Aini, N., Kristika, A., Lawi, L. A. A., Nurfadhillah, Ragi, W. A., & Antarik Ragi, W. (2024). Pendampingan Kelompok Belajar Pendidikan H.Sahlan Dalam Menjaga Biodiversitas Tumbuhan Obat Keluarga. *Jubaedah: Jurnal Pengabdian dan Edukasi Sekolah*, 4(1), 221–226. <https://doi.org/10.46306/jub>
- Kementerian Kesehatan. (2017). *Kementerian Kesehatan Republik Indonesia* (HK.01.07/MENKES/187/2017). <https://peraturan.infoasn.id/keputusan-menteri-kesehatan-nomor-hk-01-07-menkes-187-2017/>
- Kementerian Kesehatan Republik Indonesia. (2015). *100 Top tanaman obat Indonesia* (kedua). Kementerian Kesehatan RI.

- Kohsasih, K. L., & Situmorang, Z. (2022). Analisis Perbandingan Algoritma C4.5 dan Naïve Bayes Dalam Memprediksi Penyakit Cerebrovascular. *Jurnal Informatika*, 9(1), 13–17. <https://doi.org/10.31294/inf.v9i1.11931>
- Komaruddin, Miwada, & Lindawati. (2019). Evaluasi Kemampuan Ekstrak Daun Bidara (*Zizipus mauritiana* Lam.) sebagai Pengawet Alami pada Daging Ayam Broiler. *Journal of Tropical Animal Science*, 7(2), 899–910.
- Kumontoy, G. D., Deeng, D., & Mulianti, T. (2023). Pemanfaatan Tanaman Herbal Sebagai Obat Tradisional Untuk Kesehatan Masyarakat di Desa Guaan Kecamatan Mooat Kabupaten Bolaang Mongondow Timur. *Jurnal Holistik*, 16(3), 1–16.
- Lathifah, K. (2024). *Manfaat Daun Cincau Hijau untuk Kesehatan*. Radio Republik Indonesia. Diakses pada tanggal 12 Desember 2024, dari <https://rri.co.id/lain-lain/831808/manfaat-daun-cincau-hijau-untuk-kesehatan>
- Latif, A. R., & Damayanti, R. (2024). Pengaruh Pemberian Rebusan Daun Kelor Terhadap Produksi Asi: Literatur Review. *KOLONI: Jurnal Multidisiplin Ilmu*, 3(3), 32–39.
- Lestari, H. C. (2023). *Klasifikasi Citra Daun Tumbuhan Obat Menggunakan Deteksi Tepi Canny Dan Metode K-Nearest Neighbor (KNN)* [Skripsi Sarjana, Universitas Lampung]. <http://digilib.unila.ac.id/id/eprint/74983>
- Lovadi, I., Budihandoko, Y., Handayani, N. W., Setyaningsih, D., & Setiawan, I. (2021). Survey Etnobotani Tumbuhan Obat pada Masyarakat Dayak Salako di Sekitar Cagar Alam Raya Pasi Provinsi Kalimantan Barat. *Bioscientist : Jurnal Ilmiah Biologi*, 9(1), 29–44. <https://doi.org/10.33394/bjib.v9i1.3584>
- Mahajani, I., Anapia, S., Hulalata, W., Latif, S., Husin, I. S., Kaya, V., Malasugi, R. R., Kandowanko, N. Y., Ahmad, J., & Febriyanti. (2022). Identifikasi Morfologi Tumbuhan Tingkat Tinggi di Kawasan Pesisir Pantai Batu Pinagut Kecamatan Kaidipang Kabupaten Bolaang Mongondow Provinsi Sulawesi Utara. *Seminar Nasional Teknologi, Sains dan Humaniora*, 319–330.
- Makarim, F. R. (2023). *7 Manfaat Daun Bidara bagi Kesehatan Tubuh yang Jarang Diketahui*. Halodoc. Diakses pada tanggal 12 Desember 2024, dari <https://www.halodoc.com/artikel/7-manfaat-daun-bidara-bagi-kesehatan-tubuh-yang-jarang-diketahui>
- Mardiana, B. D., Utomo, W. B., Oktaviana, U. N., Wicaksono, G. W., & Minarno, A. E. (2023). Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16. *Jurnal Resti (Rekayasa Sistem dan Teknologi Informasi)*, 7(1), 20–26. <https://doi.org/10.29207/resti.v7i1.4550>
- Marhaeni, L. S. (2021). Daun Kelor (*Moringa oleifera*) sebagai Sumber Pangan Fungsional dan Antioksidan. *Jurnal Agrisia*, 13(2), 40–53.

- Marhawati, Azus, F., Nurdiana, Arafah, M., & Hadijah. (2023). Pemanfaatan Daun Kelor Sebagai Masker Wajah Menjadi Peluang Usaha bagi Ibu Rumah Tangga. *Carmin: Journal of Community Service*, 3(1), 22–28.
- Marpaung, F., Khairina, N., & Muliono, R. (2024). *Klasifikasi Daun Teh Siap Panen Menggunakan Convolutional Neural Network Arsitektur MobileNetV2*. 18(1), 215–225. <https://ejurnal.teknokrat.ac.id/index.php/teknoinfo/index>
- Maturahmah, E., Revisika, Baharuddin, W., Prafiadi, S., & Abidin, N. (2024). Pemanfaatan Tumbuhan Berkhasiat Obat Hipertensi di Kampung Amban, Provinsi Papua Barat Sebagai Buku Referensi Botani. *Journal Syntax Idea*, 6(4), 1940–1953.
- Maulani, N., & Nababan, L. (2022). Pengaruh Kompres Daun Sirih Hijau (Piper betle Linn) Terhadap Penurunan Pembengkakan Payudara pada Ibu Pasca Seksiosesarea di Wilayah Puskesmas Jalan Gedang. *Journal Of Midwifery*, 10(1), 35–40. <https://doi.org/10.37676/jm.v10i1.2315>
- Maya, P. P., Rahmadhani, F. A., Dewi, A. R., & Suryandari, A. S. (2022). Studi Efektivitas Disinfektan Alami dari Ekstrak Daun Pulai (Alstonia Scholaris) untuk Menghambat Jumlah Bakteri di Toilet Umum. *Distilat: Jurnal Teknologi Separasi*, 8(1), 154–160.
- Mayor, J. M. K., & Wattimena, L. (2022). Pemanfaatan Pohon Pulai (Alstonia Scholaris) oleh Masyarakat Kampung Puper Distrik Waigeo Timur Kabupaten Raja Ampat. *J-MACE*, 2(1), 68–81.
- Mbaba, P., Anwar, K., Rahayu, S., & Kartawati, E. A. (2022). Penerapan Metode Convolution Neural Networks Untuk Mengidentifikasi Wajah Kelelahan. *JNATIA: Jurnal Nasional Teknologi Informasi dan Aplikasinya*, 1(1), 107–114.
- Misyilla, A. I., Setiawan, D., Putri, A., Asri, A., Indah, N. S., Ramana, R., Yurnaliza, Yusman, Indriani, Ronald, C. P., Manurung, M. K., Patricia, B., Shanty, & Asat, S. M. (2023). Pemanfaatan Daun Salam, Batang Serai dan Buah Pepaya Sebagai Inovasi Dalam Produk Makanan Sehat dan Potensi Dalam Pengembangan UMKM di Desa Sungai Pinang. *Jurnal Pengabdian Inovasi dan Teknologi Kepada Masyarakat*, 3(2), 1–8.
- Nanda, S. D., Emanauli, & Sari, F. P. (2024). Pengaruh Konsentrasi Ekstrak Daun Bidara (Ziziphus mauritiana Lamk) Terhadap Mutu Sabun Mandi Padat. *Baselang: Jurnal Ilmu Pertanian, Peternakan, Perikanan dan Lingkungan*, 4(2), 342–352.
- Nariswari, S. L. (2023). *Ternyata Rutin Minum Seduhan Kejibeling Bawa Banyak Manfaat*. Kompas.com. Diakses pada tanggal 12 Desember 2024, dari <https://lifestyle.kompas.com/read/2021/03/12/145450020/ternyata-rutin-minum-seduhan-kejibeling-bawa-banyak-manfaat>

- Nashrullah, F., Wibowo, S. A., & Budiman, G. (2020). The Investigation of Epoch Parameters in ResNet-50 Architecture for Pornographic Classification. *Journal of Computer, Electronic, and Telecommunication*, 1(1). <https://doi.org/10.52435/complete.v1i1.51>
- Nasrullah. (2024). *Daun Sambung Nyawa, Bumbu Masakan Penuh Khasiat untuk Kesehatan*. Radio Republik Indonesia. Diakses pada tanggal 8 Juli 2025, dari <https://www.rri.co.id/kesehatan/710308/daun-sambung-nyawa-bumbu-masakan-penuh-khasiat-untuk-kesehatan>
- Nugraha, S. N., Pebrianto, R., & Fitri, E. (2023). Penerapan Deep Learning Pada Klasifikasi Tanaman Paprika Berdasarkan Citra Daun Menggunakan Metode CNN. *Information System For Educators And Professionals*, 8(2), 133–142.
- Nurdiana. (2020). *Morfologi Tumbuhan* (E. M. Jayadi, Ed.; 1 ed.). Sanabil.
- Nurdiyansyah, F., Kadir, S. F., Akbar, I., & Ursaputra, L. (2024). Penerapan Convolutional Neural Network Untuk Deteksi Kualitas Telur Ayam Ras Berdasarkan Warna Cangkang. *Jurnal MNEMONIC*, 7(1), 40–47.
- Pamungkas, W. G., Wardhana, M. I. P., Sari, Z., & Azhar, Y. (2023). Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease. *Jurnal RESTI*, 7(2), 326–333. <https://doi.org/10.29207/resti.v7i2.4736>
- Pangestu, H. A., & Kusriani. (2024). Peningkatan Kinerja Arsitektur ResNet50 untuk Menangani Masalah Overfitting dalam Klasifikasi Penyakit Kulit. *TEMATIK Jurnal Teknologi Informasi Komunikasi*, 11(1), 65–71. <https://doi.org/10.38204/tematik.v11i1.1876>
- Pangestu, R. A., Rahmat, B., & Anggraeny, F. T. (2020). Implementasi Algoritma CNN Untuk Klasifikasi Citra Lahan dan Perhitungan Luas. *Jurnal Informatika dan Sistem Informasi (JIFoSI)*, 1(1), 166–174.
- Panjaitan, G. H. A., & Simatupang, F. (2024). Pemodelan Klasifikasi Penyakit Daun Tanaman Tomat dengan Convolutional Neural Network Algorithm. *KLIK: Kajian Ilmiah Informatika dan Komputer*, 4(5), 2667–2675. <https://doi.org/10.30865/klik.v4i5.1646>
- Permadi, M. L. B., & Gumilang, R. (2024). Penerapan Algoritma CNN (Convolution Neural Network) Untuk Deteksi Dan Klasifikasi Target Militer Berdasarkan Citra Satelit. *Jurnal Sosial dan Teknologi (SOSTECH)*, 4(2), 134–143.
- Peryanto, A., Yudhana, A., & Umar, D. R. (2019). *Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network*. 8(2), 138–147.
- Peryanto, A., Yudhana, A., & Umar, R. (2020). Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation. *Journal of*

- Applied Informatics and Computing (JAIC)*, 4(1), 45–51.
<http://jurnal.polibatam.ac.id/index.php/JAIC>
- Prastowo, E. Y. (2021). Pengenalan Jenis Kayu Berdasarkan Citra Makroskopik Menggunakan Metode Convolutional Neural Network. *Jurnal Teknik Informatika dan Sistem Informasi*, 7(2), 489–497.
<https://doi.org/10.28932/jutisi.v7i2.3706>
- Pratiwi, I. R. (2024). Implementasi Face Recognition Menggunakan Metode Convolution Neural Network Untuk Rekomendasi Model Kacamata Secara Online. *Kohesi: Jurnal Multidisiplin Saintek*, 8(8).
<https://ejournal.warunayama.org/kohesi>
- Prawira, A. B., Jayanta, & Widiastiwi, Y. (2021). Penerapan Metode Gray Level Co-Occurance Matrix dan Algoritma Support Vector Machine Pada Klasifikasi Tanaman Bidara Berdasarkan Tekstur Daun. *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)*, 569–578.
- Putra, R. P. S., Aditya, C. S. K., & Wicaksono, G. W. (2024). Herbal Leaf Classification Using Deep Learning Model EfficientNetV2B0. *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, 9(2), 301–307.
<https://doi.org/10.33480/jitk.v9i2.5119>
- Putranto, A., Azizah, N. L., Ratna, I., Astutik, I., Sains, F., & Teknologi, D. (2023). Sistem Prediksi Penyakit Jantung Berbasis Web Menggunakan Metode SVM dan Framework Streamlit. *KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)*, 4(2), 442–452.
- Putri, I. E., Putra, A. C., Rosanti, J., Puspitawati, I. N., & Sani. (2023). Studi Kajian Hasil Ekstraksi Daun Sirih Hijau Sebagai Produk Antiseptik Alami. *Seminar Nasional Teknik Kimia Soeardjo Brotohardjono XIX*, 137–142.
<http://snsb.upnjatim.ac.id/>
- Putriani, K., Sari, K., & Sugara, B. (2024). Aktivitas Antibakteri Ekstrak Daun Ketapang (*Terminalia Catappa* L.) Terhadap *Staphylococcus Aureus*. *Innovative: Journal of Social Science Research*, 4(1), 4178–4187. <https://j-innovative.org/index.php/Innovative>
- Rachman, A. F., Ridwan, D. A., Kartono, Damarudin, S., & Saifudin, A. (2023). Kecerdasan Buatan Dalam Otomatisasi Pengujian Perangkat Lunak E-Commerce. *OKTAL : Jurnal Ilmu Komputer dan Science*, 2(6), 1742–1746.
<https://journal.mediapublikasi.id/index.php/oktal>
- Rahman, I. U., Afzal, A., Iqbal, Z., Ijaz, F., Ali, N., Shah, M., Ullah, S., & W.Bussman, R. (2019). Historical perspectives of ethnobotany. *Clinics in Dermatology*. <https://doi.org/10.1016/j.clindermatol.2018.03.018>
- Rainio, O., Tamminen, J., Venäläinen, M. S., Liedes, J., Knuuti, J., Kemppainen, J., & Klén, R. (2024). Comparison of thresholds for a convolutional neural

- network classifying medical images. *International Journal of Data Science and Analytics*. <https://doi.org/10.1007/s41060-024-00584-z>
- Ramdha, I., & Azizah, N. (2021). Formulasi Spray Gel Anti Luka Dari Ekstrak Daun Binahong (Anredera Cordifolin (Tenore) Steen). *Journal of Herbs and Farmacological*, 1, 1–8. <http://ojs.stikes-muhammadiyahku.ac.id/index.php/herbapharma>
- Ramdhani, M. N., Firdaus, A., Reine, H. F., & Supriyatna, A. (2024). Analisis Morfo-Anatomi Daun Sirih dari Famili Piperaceae dan Araceae di Kampung Warung Peuteuy, Kecamatan Cicalengka. *Polygon : Jurnal Ilmu Komputer dan Ilmu Pengetahuan Alam*, 2(4), 70–82. <https://doi.org/10.62383/polygon.v2i4.142>
- Rangkuti, M. (2024). *15 Manfaat Daun Ketapang*. Universitas Muhammadiyah Sumatera Utara. Diakses pada tanggal 6 Januari 2025, dari <https://umsu.ac.id/artikel/15-manfaat-daun-ketapang/>
- Rhamadiyanti, D. T., & Kusrini. (2024). Analisa Performa Convolutional Neural Network dalam Klasifikasi Citra Apel dengan Data Augmentasi. *KLIK: Kajian Ilmiah Informatika dan Komputer*, 5(1), 154–162. <https://doi.org/10.30865/klik.v5i1.2023>
- Riska, A., Purnawansyah, Darwis, H., & Astuti, W. (2023). Studi Perbandingan Kombinasi GMI, HSV, KNN, dan CNN pada Klasifikasi Daun Herbal. *Indonesian Journal of Computer Science*, 12(3), 1201–1215.
- Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtijas, H. P. A., Yustanti, W., & Prihanto, A. (2021). Analisa Learning rate dan Batch size Pada Klasifikasi Covid Menggunakan Deep learning dengan Optimizer Adam. *Journal Information Engineering and Educational Technology*, 5(2), 44–48.
- Royyani, M. F., Setiawan, M., Keim, A. P., Hasanah, I. F., & Efendy, O. (2024). Pengantar Penelitian Etnobotani. Dalam *Pengantar Penelitian Etnobotani* (1 ed.). Penerbit BRIN. <https://doi.org/10.55981/brin.624>
- Sabahiyah, S., Wahyuni, S., Hafizin, M., Ihwan, I., & Akrom, M. (2024). Pembibitan dan Pemanfaatan Daluman (Cyclea Barbata Miers) Sebagai Alternatif Minuman Sehat di Dusun Karang Anyar Timuk Desa Mamben Lauk. *Jurnal Pengabdian Pendidikan IPA Kontekstual*, 2(2), 22–28. <https://doi.org/10.29303/jppik.v2i2.625>
- Sadiyah, H. H., Cahyadi, A. I., & Windria, S. (2022). Kajian Potensi Daun Sirih Hijau (Piper betle L) sebagai Antibakteri. *Jurnal Sain Veteriner*, 40(2), 128–138. <https://doi.org/10.22146/jsv.58745>
- Salim, E., Suryati, Ramadani, R., & Sukrila, W. (2022). Isolasi Senyawa Metabolit Sekunder dari Ekstrak Etil Asetat Daun Pulai (Alstonia scholaris (L.) R. Br.) Berdasarkan Sifat Toksisitas dengan Metode BSLT (Brine Shrimp Lethality

- Test). *Akta Kimia Indonesia*, 7(2), 120–132. <https://doi.org/10.12962/j25493736.v7i2.14532>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). *MobileNetV2: Inverted Residuals and Linear Bottlenecks*.
- Sanjaya, I. G. M., Ismono, Ishma, E. F., & Mufid, M. F. (2021). Perbedaan Karakter Fisiko-Kimia Ekstrak Daun Binahong Berbatang Merah dan Daun Binahong Berbatang Hijau. *Indonesian Chemistry And Application Journal*, 4(2), 16–20. <https://doi.org/10.26740/icaj.v4n2.p16-20>
- Sari, I. K. (2024). Pengaruh Terapi Rendam Rebusan Air Daun Binahong terhadap Penyembuhan Luka Hemoroidektomi. *Open Access Jakarta Journal of Health Sciences*, 3(1), 1039–1049. <https://doi.org/10.53801/oajjhs.v3i1.227>
- Sartika, B. L. (2024). *Binahong, Dari Obat Tradisional Menjadi Andalan Kesehatan Modern*. Radio Republik Indonesia. Diakses pada tanggal 12 Desember 2024, dari <https://www.rri.co.id/kesehatan/788996/binahong-dari-obat-tradisional-menjadi-andalan-kesehatan-modern>
- Setyaningsih, E. P., & Febriyanti, R. (2023). Etnobotani Tanaman Obat Sebagai Imunomodulator di Desa Adi Luhur Kecamatan Panca Jaya Provinsi Lampung. *Saintech Farma: Jurnal Ilmu Kefarmasian*, 16(2), 103–108.
- Shahi, T. B., Sitaula, C., Neupane, A., & Guo, W. (2022). Fruit Classification Using Attention-based MobileNetV2 for Industrial Applications. *PLoS ONE*, 17(2), 1–21. <https://doi.org/10.1371/journal.pone.0264586>
- Sharma, J., Al-Huqail, A. A., Almogren, A., Doshi, H., Jayaprakash, B., Bharathi, B., Ur Rehman, A., & Hussien, S. (2025). Deep Learning based Ensemble Model for Accurate Tomato Leaf Disease Classification by Leveraging ResNet50 and MobileNetV2 Architectures. *Scientific Reports*, 15(1), 1–24. <https://doi.org/10.1038/s41598-025-98015-x>
- Silalahil, M. (2020). Urena Lobata (Pemanfaatan Sebagai Obat Tradisional dan Bioaktivitasnya). *Jurnal Kesehatan Masyarakat*, 6(2), 114–120. <https://doi.org/10.35329/jkesmas.v6i2>
- Silviani, Y., Harningsih, T., Kusumaningrum, S., Anjaswari, V. C., & Yulianti, W. R. I. (2024). Penyuluhan Pencegahan Faringitis Menggunakan Obat Kumur Rebusan Daun Sirih Hijau. *Jurnal Peduli Masyarakat*, 6(1), 41–46. <http://jurnal.globalhealthsciencegroup.com/index.php/JPM>
- Simamora, A. A., & Hasibuan, A. S. (2021). Pemanfaatan Tanaman Daun Sambung Nyawa Terhadap Hipertensi di Desa Simirik Kecamatan Padangsidimpuan Batunadua Kota Padangsidimpuan. *Jurnal Pengabdian Masyarakat Aufa (JPMA)*, 3(1), 46–52.
- Soe, S. C., Kalalo, J. G. K., & Melpin, R. (2024). Uji Aktivitas Antibakteri Ekstrak Etanol Daun Sambung Nyawa *Gynura procumbens* (Lour) Merr terhadap

- Bakteri Propionibacterium Acnes Penyebab Jerawat. *Pharmacy Research Journal*, 1(1), 13–17.
- Suhardin, I., Patombongi, A., & Islah, A. M. (2021). Mengidentifikasi Jenis Tanaman Berdasarkan Citra Daun Menggunakan Algoritma Convolutional Neural Network. *Jurnal Sistem Informasi dan Teknik Komputer*, 6(2), 100–108.
- Supono, R. A., & Suprayogi, M. A. (2021). Perbandingan Metode TF-Abs dan TF-IDF Pada Klasifikasi Teks Helpdesk Menggunakan K-Nearest Neighbor. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(5), 911–918. <https://doi.org/10.29207/resti.v5i5.3403>
- Suprpto, H. (2020). *10 Manfaat daun salam yang wajib kamu tahu, untuk pria dan wanita*. Hops.ID. Diakses pada tanggal 13 Desember 2024, dari <https://www.hops.id/fit/pr-2942100276/10-manfaat-daun-salam-yang-wajib-kamu-tahu-untuk-pria-dan-wanita>
- Suriya, M., Chandran, V., & Sumithra, M. G. (2022). Enhanced deep convolutional neural network for malarial parasite classification. *International Journal of Computers and Applications*, 44(12), 1113–1122. <https://doi.org/10.1080/1206212X.2019.1672277>
- Surya, I. M. A., Cahyanto, T. A., & Muharom, L. A. (2025). Deep Learning dengan Teknik Early Stopping untuk Mendeteksi Malware pada Perangkat IoT. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 12(1), 21–30. <https://doi.org/10.25126/jtiik.2025128267>
- Tjong, A., Assa, Y. A., & Purwanto, D. S. (2021). Kandungan Antioksidan Pada Daun Kelor (Moringa Oleifera) dan Potensi sebagai Penurun Kadar Kolesterol Darah. *eBiomedik*, 9(2), 248–254. <https://doi.org/10.35790/ebm.9.2.2021.33452>
- Triwinanto, M. A., Murtopo, A. A., Syefudin, & Gunawan. (2024). Penerapan Algoritma Convolutional Neural Network (CNN) Untuk Identifikasi Lahan Kosong Di Kota Tegal Berdasarkan Citra Google Earth. *Jurnal Minfo Polgan*, 13(1), 303–314. <https://doi.org/10.33395/jmp.v13i1.13626>
- Wahyudi, W., Hsb, H. L. P., Hasanah, N., & Sitorus, R. A.-H. (2022). Studi Literatur: Daun Bidara (Ziziphus Mauritiana) Sebagai Herbal Indonesia Dengan Berbagai Kandungan Dan Efektivitas Farmakologi. *Farmanesia*, 9(1), 22–27.
- WHO. (2022). *WHO establishes the Global Centre for Traditional Medicine in India*. World Health Organization. Diakses pada tanggal 12 Desember 2024, dari <https://www.who.int/news/item/25-03-2022-who-establishes-the-global-centre-for-traditional-medicine-in-india>

- Wibisono, N., & Martino, Y. A. (2023). Uji Aktivitas Antidiabetes Kulit Batang Pulai (*Alstonia scholaris*) melalui Studi In Silico dan Prediksi Profil Farmakokinetika. *Jurnal Ilmiah Biosaintropis (Bioscience-Tropic)*, 8(2), 59–64. <https://doi.org/10.33474/e-jbst.v8i2.511>
- Wijaya, A. E., Swastika, W., & Kelana, O. H. (2021). Implementasi Transfer Learning Pada Convolutional Neural Network Untuk Diagnosis Covid-19 Dan Pneumonia Pada Citra X-Ray. *SAINSBERTEK Jurnal Ilmiah Sains & Teknologi*, 2(1).
- Wiyati, E. P., & Noviyanti, Y. (2024). Explorasi Biji Ketapang Menjadi Oalahan Berkhasiat Anti Aging Dari Peyek Biji Ketapang (Pey Ji Pang). *Jurnal Pengabdian*, 3(1), 35–42. <https://journal.bengkuluinstitute.com/index.php/jp>
- Yanti, I., Amelia, D., Rafi'ah, Sukmawati, & Swandayani, R. E. (2023). Identifikasi Jenis dan Manfaat Pohon di Kawasan Universitas Islam Al-Azhar. *Lombok Journal of Science (LJS)*, 5(1), 10–25.
- Yong, L., Ma, L., Sun, D., & Du, L. (2023). Application of MobileNetV2 to waste classification. *PLoS ONE*, 18(3), 1–16. <https://doi.org/10.1371/journal.pone.0282336>
- Zuhdi, A., & Utama, M. S. (2024). Prediksi Wilayah Rawan Kebakaran Menggunakan Deep Learning. *Jurnal Teknik*, 18(1), 127–138.